

基于改进结构保持数据降维方法的故障诊断研究

韩敏¹ 李宇¹ 韩冰²

摘要 传统基于核主成分分析 (Kernel principal component analysis, KPCA) 的数据降维方法在提取有效特征信息时只考虑全局结构保持而未考虑样本间的局部近邻结构保持问题, 本文提出一种改进全局结构保持算法的特征提取与降维方法. 改进的特征提取与降维方法将流形学习中核局部保持投影 (Kernel locality preserving projection, KLPP) 的思想融入核主成分分析的目标函数中, 使样本投影后的特征空间不仅保持原始样本空间的整体结构, 还保持样本空间相似的局部近邻结构, 包含更丰富的特征信息. 上述方法通过同时进行的正交化处理可避免局部子空间结构发生失真, 并能够直观显示出低维结果, 将低维数据输入最近邻分类器, 以识别率和聚类分析结果作为衡量指标, 同时将所提方法应用于故障诊断中. 使用 AVL Boost 软件模拟的柴油机故障数据和田纳西 (Tennessee Eastman, TE) 化工数据仿真, 验证了所提方法的有效性.

关键词 特征提取, 数据降维, 核主成分分析, 局部保持投影法, 故障诊断

引用格式 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. 自动化学报, 2021, 47(2): 338–348

DOI 10.16383/j.aas.c180138

Research on Fault Diagnosis of Data Dimension Reduction Based on Improved Structure Preserving Algorithm

HAN Min¹ LI Yu¹ HAN Bing²

Abstract The traditional data reduction method based on kernel principal component analysis (KPCA) only considers the global structure preservation when extracting effective feature information, but does not take the problem of local neighbor structure retention between samples into consider. An improved feature extraction and dimension reduction of global structure preservation algorithm is proposed which integrates the idea of kernel locality preserving projection (KLPP) of manifold learning into the objective function of kernel principal component analysis, so that the feature space after the sample projection not only remains the whole original sample space. But also maintains a local neighbor structure with similar sample space which contains more feature information. Distortion of the local subspace structure can be avoided by simultaneous orthogonalization, and the low-dimensional results can be visually displayed. The low-dimensional data is inputted into the nearest neighbor classifier, using the recognition rate and cluster analysis results as a measurement. At the same time, the proposed method is applied to fault diagnosis. The diesel engine fault data simulation simulated by AVL Boost software and Tennessee Eastman (TE) chemical data simulation verify the effectiveness of the proposed algorithm.

Key words Feature extraction, data dimension reduction, kernel principal component analysis, locality preserving projection, fault diagnosis

Citation Han Min, Li Yu, Han Bing. Research on fault diagnosis of data dimension reduction based on improved structure preserving algorithm. *Acta Automatica Sinica*, 2021, 47(2): 338–348

收稿日期 2018-03-09 录用日期 2018-09-06
Manuscript received March 9, 2018; accepted September 6, 2018

国家自然科学基金 (61773087), 中央高校基本科研业务费 (DUT17ZD216), 上海启明星 (15QB1400800) 资助
Supported by National Natural Science Foundation of China (61773087), Fundamental Research Funds for the Central Universities (DUT17ZD216), and Shanghai Rising-Star Program (15QB1400800)

本文责任编辑 曾志刚

Recommended by Associate Editor ZENG Zhi-Gang

1. 大连理工大学电子信息与电气工程学部 大连 116023 2. 上海船舶航运研究院航海与安全技术国家重点实验室 上海 200135

1. Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023 2. National Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Sciences, Shanghai 200135

数据降维方法在众多领域应用广泛, 其划分依据也不尽相同, 按照数据结构特征保持与否的准则进行划分, 则可根据数据的全局结构保持和局部结构保持分成两类^[1], 前者反映了数据的外部形状, 后者反映了数据的内在属性, 可以寻找出高维观测数据中所隐藏的低维流形结构. 其中, 主成分分析 (Principal component analysis, PCA)^[2]、独立元分析^[3] 和人工神经网络^[4] 等方法均为数据全局特征结构保持的代表方法, 核主成分分析 (Kernel principal component analysis, KPCA)^[5] 通过非线性映射函数将线性不可分的原始样本数据输入空间通过投影变换到线性可分的高维特征空间, 然后在

新的特征空间中利用线性方法完成主成分分析, 从而实现数据整体方差最大化, 但 KPCA 方法只能提取数据的全局结构信息, 若数据中低维局部结构中包含较多特征信息的话, 则效果较差. 另外, 流形学习能够从高维历史信息中获取数据间有效的内部联系, 从而得以保持局部结构特征, 具有良好的非线性数据内部属性的处理能力^[6-7], 代表性的流形学习^[8]方法主要包括等距特征映射算法 (Isometric feature mapping, ISOMAP)^[9], 拉普拉斯特征映射算法 (Laplacian eigenmaps, LE)^[10], 局部线性嵌入算法 (Locally linear embedding, LLE)^[11], 局部保持投影算法 (Locality preserving projections, LPP)^[12]等, 其中, 有学者在 LPP 算法中引入核方法, 提出核局部保持投影 (Kernel locality preserving projection, KLPP)^[13], 其在保持局部结构特征的同时实现线性计算, 反映出数据的局部结构特征, 但本质上 KLPP 是一种基于局部结构保持的降维方法, 它并不能有效提取出数据的全局特征信息^[14].

针对以上问题, 本研究拟对 KPCA 与 KLPP 相结合的降维方法进行探讨, 提出了本文的解决办法, 并把新提出的算法命名为改进全局与局部结构保持算法 (Global and local structure preserving, GLSP), 在进行原始数据的投影变换时, 既考虑全局结构得以保持, 也兼顾保持局部近邻结构. 首先使用局部与全部特征提取方法, 解决数据有效降维的问题, 使用聚类分析中类内距离与类间距离等作为衡量指标, 并使用 K 近邻 (K -nearest neighbor, KNN) 方法进行故障的检测^[15]. 本文数据使用柴油机仿真故障数据^[16]和 TE 过程公共数据集, 用于验证方法的有效性.

1 改进结构保持方法

作为非线性特征提取的经典方法, KPCA 通过非线性映射将线性不可分的原始数据从低维空间变换到一个线性可分的高维特征空间, 运用线性方法进行数据降维与特征提取, 其目标是使得数据方差最大化, 但数据方差指标主要用来描述数据集的全局结构信息. 此外, KLPP 是通过建立样本点之间的近邻关系来保持数据集的局部结构, 本质是保持原始数据局部结构和内部属性. 综合考虑 KPCA 与 KLPP 两种投影保持方法的思想, 本文提出 GLSP, 其目标函数可以理解为由全局目标函数和局部目标函数共同组成.

1.1 局部结构保持算法描述

KLPP 通过非线性投影映射, 在投影空间建立近邻图, 最大限度地保持了数据集的近邻结构, 其局部结构保持目标函数定义如下^[17]: 假设数据集 $\mathbf{X} =$

$[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T \in \mathbf{R}^{n \times m}$, n 为样本个数, m 为数据维数, 通过非线性映射 Φ 将原始数据映射到高维空间中, 记为 $\Phi(\mathbf{x}_i)$, $\mathbf{J}_{\text{local}}(\mathbf{w})$ 的目标是在特征空间中找到投影向量 \mathbf{w} , 使得投影 $\mathbf{y}_i = \Phi^T(\mathbf{x}_i)\mathbf{w}$ 在高维特征空间保持数据点之间的近邻关系, 可以认为, 如果 $\Phi(\mathbf{x}_i)$ 和 $\Phi(\mathbf{x}_j)$ 是近邻, 那么 $\mathbf{y}_i = \Phi^T(\mathbf{x}_i)\mathbf{w}$ 和 $\mathbf{y}_j = \Phi^T(\mathbf{x}_j)\mathbf{w}$ 也是近邻的. 其局部结构保持的目标函数定义为:

$$\begin{aligned} \mathbf{J}_{\text{local}}(\mathbf{w}) &= \min_{\mathbf{w}} \sum_{i=1}^n \sum_{j=1}^n \|\mathbf{y}_i - \mathbf{y}_j\|^2 \mathbf{s}_{ij} = \\ &= \min_{\mathbf{w}} \sum_{i=1}^n \sum_{j=1}^n \left\| \Phi^T(\mathbf{x}_i)\mathbf{w} - \Phi^T(\mathbf{x}_j)\mathbf{w} \right\|^2 \mathbf{s}_{ij} = \\ &= \min_{\mathbf{w}} \left\{ \mathbf{w}^T \Phi^T(\mathbf{x}_i) (\mathbf{D} - \mathbf{S}) \Phi(\mathbf{x}_j) \mathbf{w} \right\} \quad (1) \end{aligned}$$

式中, \mathbf{s}_{ij} 为权重参数, 表示数据点之间的近邻关系, \mathbf{S} 为权重矩阵, \mathbf{D} 为对角矩阵, $D_{ii} = \sum_{j=1}^n \mathbf{s}_{ij}$, \mathbf{s}_{ij} 取值一般为:

$$\mathbf{s}_{ij} = \begin{cases} \frac{\exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2)}{t}, & \mathbf{x}_i \in \Omega_{\mathbf{x}_j}^k, \mathbf{x}_j \in \Omega_{\mathbf{x}_i}^k \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中, $\Omega_{\mathbf{x}_i}^k$ 为 \mathbf{x}_i 的 k 邻域.

引入核函数 $\mathbf{K}_{ij} = \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \Phi^T(\mathbf{x}_i)\Phi(\mathbf{x}_j)$, 并存在系数 $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]$ 对特征空间中的样本线性表示为 $\mathbf{w} = \sum_{i=1}^n \alpha_i \Phi(\mathbf{x}_i)$, 局部结构保持的目标函数转化为:

$$\begin{aligned} \mathbf{J}_{\text{local}}(\boldsymbol{\alpha}) &= \min_{\boldsymbol{\alpha}} \left\{ \boldsymbol{\alpha}^T \Phi^T(\mathbf{x}_i) \Phi^T(\mathbf{x}_j) \right. \\ &= (\mathbf{D} - \mathbf{S}) \Phi^T(\mathbf{x}_i) \Phi^T(\mathbf{x}_j) \boldsymbol{\alpha} \left. \right\} = \\ &= \min_{\boldsymbol{\alpha}} \left\{ \boldsymbol{\alpha}^T \Phi^T(\mathbf{x}_i) \Phi^T(\mathbf{x}_j) \mathbf{L} \Phi(\mathbf{x}_i) \Phi^T(\mathbf{x}_j) \boldsymbol{\alpha} \right\} = \\ &= \min_{\boldsymbol{\alpha}} \boldsymbol{\alpha}^T \mathbf{K} \mathbf{L} \mathbf{K} \boldsymbol{\alpha} = \min_{\boldsymbol{\alpha}} \boldsymbol{\alpha}^T \mathbf{L}' \boldsymbol{\alpha} \quad (3) \end{aligned}$$

式中, $\mathbf{L} = \mathbf{D} - \mathbf{S}$ 为 Laplacian 矩阵, $\mathbf{L}' = \mathbf{K} \mathbf{L} \mathbf{K}$.

KLPP 算法的目的是使数据在高维映射空间中, 仍能保持数据之间的近邻结构, 但是算法本身忽略了对数据集的整体结构特征描述. 其本质是因为局部目标函数表达式中没有显式地考虑样本点的全局特征, 只是利用局部结构来代替全局信息, 导致了数据在低维映射中全局特征的扭曲显示.

1.2 全局结构保持算法描述

PCA 算法常用于数据主要成分的分析与维度约简, 其本质是将线性数据变换为各个维度线性无关表示的几组数据, 便于对数据中主要特征分量的

提取. KPCA 算法由核映射将数据映射到高维核空间, 然后使用 PCA 方法, 与 KLPP 算法类似, 通过非线性映射 Φ 将原始数据 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T \in \mathbf{R}^{n \times m}$ 映射到高维空间, 记为 $\Phi(\mathbf{x}_i)$, 经过投影向量 \mathbf{w} 投影后的映射 $\mathbf{y}_i = \Phi^T(\mathbf{x}_i)\mathbf{w}$, 在投影方向上保证数据方差最大化, 这样可以充分利用高阶统计信息和全局特征结构保持. 其全局结构目标函数定义为:

$$\begin{aligned} J_{\text{global}}(\mathbf{w}) &= \max_{\mathbf{w}} \sum_{i=1}^n \mathbf{y}_i^2 = \\ &= \max_{\mathbf{w}} \sum_{i=1}^n \left(\Phi^T(\mathbf{x}_i)\mathbf{w} \right)^2 \end{aligned} \quad (4)$$

式中, $\mathbf{w}^T\mathbf{w} = 1$.

引入核函数 $K_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \Phi^T(\mathbf{x}_i)\Phi(\mathbf{x}_j)$, 可看出即使不确定核函数的具体表达形式, 但是其转化为映射后的数据的内积运算, 存在系数 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]$ 对特征空间中的样本线性表示为 $\mathbf{w} = \sum_{i=1}^n \alpha_i \Phi(\mathbf{x}_i)$, 全局结构保持的目标函数转化为:

$$\begin{aligned} J_{\text{global}}(\alpha) &= \max_{\alpha} \sum_{i=1}^n \left(\Phi^T(\mathbf{x}_i) \sum_{j=1}^n \alpha_j \Phi(\mathbf{x}_j) \right)^2 = \\ &= \max_{\alpha} \sum_{i=1}^n \left(\sum_{j=1}^n \alpha_j \Phi^T(\mathbf{x}_i)\Phi(\mathbf{x}_j) \right)^2 = \\ &= \max_{\alpha} \alpha^T \mathbf{K} \mathbf{K} \alpha = \max_{\alpha} \alpha^T \mathbf{C} \alpha \end{aligned} \quad (5)$$

式中, $\alpha^T \mathbf{K} \alpha = 1, \mathbf{C} = \mathbf{K} \mathbf{K}$.

因为 KPCA 是一种面向全局的变换方法, 由于其保持了原始数据的大部分方差信息, 所以实现了全局结构的特征提取. 然而, 保持全局结构的目标函数中没有考虑各类数据点之间的内部联系, 在低维空间里, 数据点之间的局部几何关系与内在属性可能被忽视, 甚至导致重要信息的丢失.

1.3 改进的整体目标函数

全局结构目标保持函数的思想是在最大程度保持全局信息方差不变的情况下, 提取出样本数据的非线性特征; 而局部结构保持目标函数的思想是在投影中保持样本对之间的远近亲疏关系, 在低维空间中最小化近邻样本间的距离加权平方和, 即尽量避免样本集的发散.

结合全局结构保持目标函数和局部结构保持目标函数的意义, 构造一种新的结构保持目标函数, 使得映射后的特征空间能够保留全局结构的同时, 又可以保持数据间的局部近邻结构^[18-19], 构造出如式(6)的最大值选择问题, 由于局部结构保持的目标函

数为求取最小值, 所以式(6)中引入其相反数:

$$\mathbf{J}(\alpha) = \max_{\alpha} \{ \mathbf{J}_{\text{global}}(\alpha), -\mathbf{J}_{\text{local}}(\alpha) \} \quad (6)$$

由于式(6)只从两个目标函数中选择其一, 是一个典型的多目标求取最值问题, 由于未考虑两个目标函数的综合效果, 通常很难求解到全局最优解, 因此, 将式(6)中两个目标函数进行求和操作, 求和后的目标函数如式(7)所示:

$$\begin{aligned} \mathbf{J}(\alpha) &= \max_{\alpha} (\mathbf{J}_{\text{global}}(\alpha) - \mathbf{J}_{\text{local}}(\alpha)) = \\ &= \max_{\alpha} (\alpha^T \mathbf{C} \alpha - \alpha^T \mathbf{L}' \alpha) = \\ &= \max_{\alpha} (\alpha^T (\mathbf{C} - \mathbf{L}') \alpha) \end{aligned} \quad (7)$$

同理, 这两个目标函数很难同时达到最佳效果. 考虑到两个目标函数之间的差异, 所以, 引入一个权重参数 β 来平衡上述两个目标函数, β 是一个介于 0 和 1 之间的值, 其值的大小对于新的目标函数 $\mathbf{J}(\alpha)$ 有很大影响, 因为它决定着两个原始目标函数的重要性问题^[20]. 实际上 β 可以看作是平衡两个目标函数的能量变化. β 越小越侧重于全局特征的提取, β 越大越侧重于局部特征的提取, β 值的选取按照如下准则:

$$\beta S_{\text{global}} = (1 - \beta) S_{\text{local}} \quad (8)$$

其中, S_{global} 和 S_{local} 分别表示 $\mathbf{J}_{\text{global}}(\mathbf{w})$ 和 $\mathbf{J}_{\text{local}}(\mathbf{w})$ 的规模大小, 受到参考文献^[18, 21]启发, 定义为:

$$S_{\text{global}} = \rho(\mathbf{C}) \quad (9)$$

$$S_{\text{local}} = \rho(\mathbf{L}') \quad (10)$$

式中, $\rho(\cdot)$ 是相关矩阵谱半径. 结果表明, 该平衡参数的引入策略能够很好地平衡全局和局部的行为, GLSP 的降维性能也可以得到保证. 事实上, 权重参数也可以根据不同背景下原始数据的特性, 赋予不同定义, 而不仅限于本文所提方法, 这使得改进的结构保持算法更加灵活. 结合式(8)~(10), 可得到权重参数 β 的计算公式如下:

$$\beta_{\mathbf{C}} = \frac{\rho(\mathbf{C})}{\rho(\mathbf{C}) + \rho(\mathbf{L}')}, \beta_{\mathbf{L}'} = 1 - \beta_{\mathbf{C}} \quad (11)$$

因此, 改进的整体目标函数表示为:

$$\begin{aligned} \mathbf{J}(\alpha) &= \max_{\alpha} (\beta_{\mathbf{C}} \mathbf{J}_{\text{global}}(\alpha) - \beta_{\mathbf{L}'} \mathbf{J}_{\text{local}}(\alpha)) = \\ &= \max_{\alpha} (\alpha^T (\beta_{\mathbf{C}} \mathbf{C} - \beta_{\mathbf{L}'} \mathbf{L}') \alpha) = \\ &= \max_{\alpha} \alpha^T \mathbf{M} \alpha \end{aligned} \quad (12)$$

式中 $\mathbf{M} = \beta_{\mathbf{C}} \mathbf{C} - \beta_{\mathbf{L}'} \mathbf{L}', 0 \leq \beta_{\mathbf{C}} \leq 1, 0 \leq \beta_{\mathbf{L}'} \leq 1$.

最后将上述目标函数的优化问题转化为求解特征向量问题. 确定权重参数 β 的值之后, 结合式 (5) 中的条件, 引入拉格朗日乘法, 求解特征向量:

$$\mathbf{L} = \boldsymbol{\alpha}^T \mathbf{M} \boldsymbol{\alpha} - \lambda (\boldsymbol{\alpha}^T \mathbf{K} \boldsymbol{\alpha} - 1) \quad (13)$$

当 $\frac{\partial \mathbf{L}}{\partial \boldsymbol{\alpha}} = 0$, 可得:

$$\mathbf{M} \boldsymbol{\alpha} = \lambda \mathbf{K} \boldsymbol{\alpha} \quad (14)$$

非线性问题的求解过程中, 引入正则化方法, 我们用 $\mathbf{K} + \eta \mathbf{I}_n$ 来代替式 (14) 中的 \mathbf{K} , 其中, η 是一个很小的正整数, \mathbf{I}_n 是一个 $n \times n$ 的单位向量.

与 PCA 类似, 本文使用累积方差贡献率准则选取满足贡献率达到要求的主成分个数, 依据式 (15) 选取前 p 个特征值确定主成分个数, 本研究中贡献率选定为 85%.

$$\frac{\sum_{k=1}^p \lambda_k}{\sum_{k=1}^N \lambda_k} > 85\% \quad (15)$$

2 降维方法实现

原始数据在降维时, 将面临难以全面提取有用信息的困难, 为解决这一问题, 本文提供一种结合全局与局部结构保持的数据降维思想, 实现方法为: 采集原始数据, 建立能够从多角度反映数据信息的高维数据集, 并加以验证; 再将数据集输入所提全局与局部结构保持算法中进行降维处理: 将低维特征子集输入 KNN 最近邻分类器, 计算 KNN 的识别率, 并将聚类分析中类间距与类内距的比值 S_B/S_W 作为衡量降维效果指标^[22].

2.1 降维评价指标

Fisher 判别分析是模式识别方法中的一种数据降维与分类方法. 其通过投影将测试数据映射到不同方向, 使得不同类别的测试样本的投影的类间离散度最大, 类内离散度最小^[23]. 类内距 S_W 描述同一类样本内部分布的紧密程度, 而类间距 S_B 用反映不同类别之间的分离程度, 定义如下^[15, 24]:

$$\mathbf{S}_B = \frac{1}{N} \sum_{i=1}^C N_i (\mathbf{m}_i - \mathbf{m}) (\mathbf{m}_i - \mathbf{m})^T \quad (16)$$

$$\mathbf{S}_W = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} [\Phi(\mathbf{x}_i^j) - \mathbf{m}_i] \times [\Phi(\mathbf{x}_i^j) - \mathbf{m}_i]^T \quad (17)$$

其中, \mathbf{m}_i 表示特征空间中第 i 类采样均值, \mathbf{m} 表示所有样本点在特征空间中的均值. 显然, S_B/S_W 越

大说明该方法的分类与聚类效果越好, 因此将该指标作为降维效果的综合衡量指标之一.

KNN 是对不同类别的数据信息根据训练样本特征进行分类的方法, 具有操作直观、效果稳定、时效性强等优点, 广泛应用到各类数据分类领域, 尤其是故障数据的诊断与分类中. 原始数据进行降维操作, 其最终目的是实现不同故障类别的准确分类, 故 KNN 方法的识别率越高, 其反映出对数据的初始降维方法越好^[25-26].

2.2 降维方法流程

总结局部与全局结构保持算法的流程图如图 1 所示.

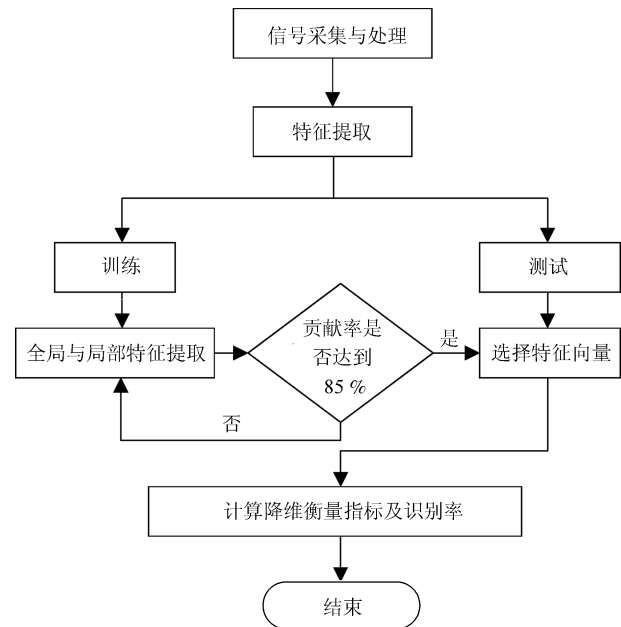


图 1 数据降维方法流程

Fig. 1 The dimension reduction process of data

算法主要流程如下.

步骤 1. 对于数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]^T \in \mathbf{R}^{n \times m}$, 构造局部结构保持函数 $J_{\text{local}}(\boldsymbol{\alpha})$.

步骤 2. 构造全局方差最大目标函数 $J_{\text{global}}(\boldsymbol{\alpha})$.

步骤 3. 构造整体目标函数 $J(\boldsymbol{\alpha})$.

步骤 4. 根据式 (14) 求解特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 与对应的特征向量 $\mathbf{A} = [\alpha_1, \alpha_2, \dots, \alpha_n]$.

步骤 5. 根据式 (15) 求解前 p 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_p$ 与对应的特征向量 $\mathbf{A}' = [\alpha_1, \alpha_2, \dots, \alpha_p]$.

步骤 6. 根据公式 $\mathbf{T} = \mathbf{K}^T \mathbf{A}'$, 获得样本集在低维正交特征子空间的投影.

步骤 7. 通过映射矩阵对训练及测试样本进行维数约简, 再将得到的低维特征子集输入到 KNN, 并计算低维特征子集的 S_B, S_W 及 S_B/S_W 指标.

3 仿真实验与分析

3.1 柴油机故障数据仿真

船舶柴油机广泛应用于实际航运工程中,其安全稳定的运行状态对整个系统起着至关重要的影响。因此,在船舶柴油机发生故障时,如果能够准确将故障信号的有效特征提取并分析,则可提供足够多有效信息,便于故障的分类和诊断^[27-28]。

1) 模型设计

本文以 MAN 公司 S35ME-B9 型柴油机为主要研究对象,利用专业模拟软件 AVL Boost 完成柴油机故障模型仿真模拟系统,图 2 为柴油机仿真模型。

图 2 中,SB1、SB2、SB3 为系统边界,外界气体通过 SB1 进入系统,系统工质通过 SB3 排出系统,MP1~MP8 为测点,MP1 和 MP2 测量中冷器前后的气体压力、温度,MP3 和 MP4 测量气体进入和流出进气管 PL1 的气体压力、温度,MP5 和 MP6 测量进入和流出 1 号缸的气体压力、温度,MP7 和 MP8 测量废气进入和流出涡轮增压的气体压力、温度,C1~C6 为气缸,1~29 为管道连接,PL1 为进气管,CO1 为中冷器,TC1 为涡轮增压器。

本文对正常工况以及三种常见的船舶柴油机故障进行仿真模拟,包括空冷器冷却不足,排气口堵塞以及涡轮增压器效率降低,如表 1 所示,由于本文采用的数值仿真模型,因此采用设置关键参数的方式对故障进行模拟。在每种工况下,记录模型中 8 个测量点的 15 个状态参数作为原始数据,分别为功率 (kW),最大爆发压力 (100 kPa),压力机流量 (kg/c),压力机出口温度 (°C),压力机出口压力 (100 kPa),中冷器后温度 (°C),中冷器温差 (°C),中冷器后压力 (100 kPa),中冷器压差 (100 kPa),扫气温度 (°C),扫气压力 (100 kPa),排气管温度 (°C),排气管压力 (100 kPa),废气进涡轮机温度 (°C),涡

轮增压出口温度 (°C)。

表 1 正常工况与故障工况模拟

Table 1 The simulation of normal and fault conditions

No.	工况类型	样本个数	数据维数
1	正常工况	960	15
2	故障 1. 空冷器冷却不足	960	15
3	故障 2. 排气口堵塞	960	15
4	故障 3. 涡轮增压效率降低	960	15

将故障数据集经本文所提降维方法进行处理,选取 KPCA、KLPP、核 Fisher 判别分析 (Kernel fisher discriminant analysis, KFDA)^[29]、局部和全局主成分分析 (Local and global principal component analysis, LGPCA)^[30]、全局-局部结构张量分析 (Tensor global-local structure analysis, TGLSA)^[20] 和本文共 6 种算法进行对比,在本研究中选取的目标维数为 3 维,研究中采用了交叉验证方法选取最优高斯核参数,实验从降维效果可视化、降维效果综合衡量指标和特征提取速度分析三方面验证方法的有效性。

2) 模型验证

使用 AVL Boost 进行柴油机工作状态仿真模型的建立,选择台架实验的关键状态参数数据和 AVL Boost 对应状态参数进行对比验证。以柴油机功率、排气温度对柴油机模型正确性进行验证,以排气阀堵塞和空冷器冷却不足等故障对柴油机模型进行故障模拟验证。

表 2 是使用三种不同的工作状态的特工作参数平均值与台架实验中对应参数的比较,可以发现台架实验数据与 AVL Boost 相差较小,可以认为使用 AVL Boost 建立的柴油机模型与台架实验使用柴油机具有相同的工作参数。




图 2 柴油机模型仿真

Fig. 2 The diesel engine simulation

表 2 AVL Boost 数据与台架实验数据多工况对比

Table 2 The data contrast between AVL Boost and bench test under multiple working conditions

负荷	排气温度 (°C)		相对误差 (%)	功率 (kW)		相对误差 (%)
	模型数据	台架实验数据		模型数据	台架实验数据	
90% 负荷	329.89	328.50	0.42	3 281.40	3 277.00	0.13
75% 负荷	304.39	307.30	0.95	2 839.20	2 844.00	0.17
75% 推进	319.23	320.90	0.37	2 866.85	2 864.00	0.10

排气口堵塞是采用逐渐减小单个气缸的排气口直径的方法进行仿真验证, 排气口堵塞会造成排气效率不佳, 气缸内废气无法及时排出, 会造成气缸内气体逐渐增加, 缸内压力逐渐增大, 引起扫气压力增大, 进气逐渐减少, 也就是压力机流量减小. 排气口堵塞还会造成气缸内高速积碳, 引起后燃现象, 使得排气温度上升, 燃烧效率下降, 但由于上述故障因素只是增加在一个气缸中, 其余五个气缸的燃烧过程影响不大, 因此对柴油机的功率影响不大. 使用 AVL Boost 仿真这种故障, 上述提到的理论上的参数变化均获得了较好的验证.

空冷器冷却不足是使用逐渐增加冷却液温度, 逐渐降低空冷器冷却效率的方法仿真验证. 这种故障最直观反映就是空冷器前后温差降低, 另外由于空冷器冷却效率下降, 增压之后的气体无法较好地得到冷却, 扫气温度上升, 进入气缸内的气体质量会下降, 随之扫气压力上升, 流经压力机的空气流量会相应减小, 由于进入气缸的新鲜空气减少, 功率和最大爆发压力都会出现下降趋势, 同时由于进入气缸的空气温度上升, 排气温度也会上升.

3) 降维效果可视化

为验证本文降维方法的有效性, 将故障数据集经 KPCA、KLPP、KFDA、LGPCA、TGLSA 和本文所提降维方法进行处理, 选取前 480 个样本作为训练样本, 后 480 个样本作为测试样本. 根据本文所提算法选取降维后的前三个主成分即可较为直观有效的表现降维效果, 图 3 为根据贡献率原则, 选择不同降维维数与对应的主元贡献率, 由图中可知, 本文中选取主成分为前三维, 其贡献率之和即可达到总贡献率的 85%, 因此仿真实验中的贡献率选择为 85% 即可. 得到降维后的测试样本三维特征量分布见图 4 ~ 9.

从图 4 可以看出, KPCA 可以分辨正常工况与故障 1, 但对于故障 2 和故障 3 有较严重的数据重叠现象. 从图 5 可以看出, KLPP 对于 4 种工况均不能较为有效地进行区分.

图 6 ~ 8 分别为 KFDA、LGPCA、TGLSA 三种不同降维方法的对比实验效果图, KFDA 效果

较差, 样本数据大部分呈现混叠状态, LGPCA 和 TGLSA 算法也综合保持了全局结构和局部结构, 因此其效果略好于 KFDA、LGPCA 和 TGLSA 三种算法, 但由于其主要应用于维数较低的数据, 因此对于船舶柴油机的高维复杂数据, 效果一般.




图 3 不同维度贡献率统计图

Fig. 3 The contribution rate of different dimensions




图 4 KPCA 降维结果

Fig. 4 The dimension reduction based on KPCA




图 5 KLPP 降维结果

Fig. 5 The dimension reduction based on KLPP




图6 KFDA 降维结果

Fig. 6 The dimension reduction based on KFDA




图7 LGPCA 降维结果

Fig. 7 The dimension reduction based on LGPCA




图8 TGLSA 降维结果

Fig. 8 The dimension reduction based on TGLSA




图9 GLSP 降维结果

Fig. 9 The dimension reduction based on GLSP

本文所提降维方法效果图如图9所示,其中,权重参数根据计算得到 $\beta_C = 0.79$, $\beta_L = 0.21$,可见对于柴油机故障数据, KPCA 方法所侧重的全局特征占主导地位. 由于全局和局部结构特征提取过程

的综合考虑,在完成数据约简和可视化的同时,有效地分离了四种状态,同时具有良好的聚类能力. 因此,本文提出的方法能够提取故障特征,解决了数据降维可视化问题.

4) 降维效果综合衡量指标

为直观有效地可视化各类方法的降维效果,将类间距 S_B , 类内距 S_W 及二者的比值 S_B/S_W 作为衡量指标,类间距 S_B 及二者的比值 S_B/S_W 越大,表明分类效果明显,得到的评价结果见图10,从图中可以看出,六种方法中,本文所提 GLSP 方法对应的类间距及二者的比值具有最大值. 分析如下:

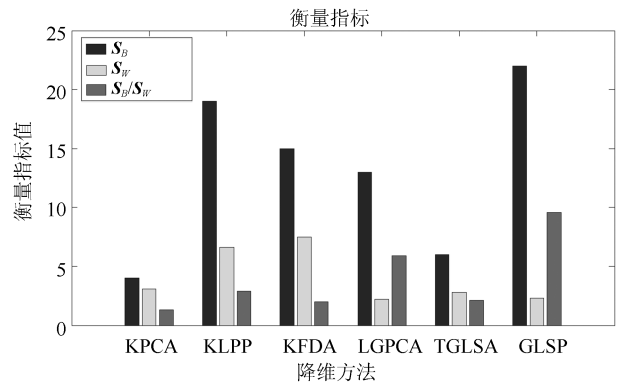


图10 六类算法降维效果衡量指标

Fig. 10 The dimension reduction performance of 6 methods

a) KPCA 降维效果及识别率一般,虽然可以去除特征空间中的数据冗余信息,但并未达到能够有效表达最佳情况的条件; KLPP 局部结构保持的方法的类间距明显提高,该方法能有效提取出数据集中局部结构,但对于综合全局与结构方法所得到的类间距与类内距的比值,还有一定差距; KFDA 方法具有较高类内距,但是对于类内距没有很好的聚合效果; LGPCA 和 TGLSA 两种方法均具有较好类内聚合作用,但是由于不同类别的类间距离较小,导致综合类间距与类内距比值较小.

b) 本文所提方法的降维效果及识别率要高于其他对比方法,该方法能够避免子空间重构,更利于故障类别的划分,且具有较强的全局与局部判别信息的挖掘能力.

故障诊断的实质是模式识别,考虑船舶柴油机故障诊断的实船应用性,选择 极限学习机 (Extreme learning machine, ELM)、支持向量机 (Support vector machine, SVM)、相关向量机 (Relevance vector machine, RVM)、KNN 四种基础有效的分类方法进行检验,将低维样本分别应用于上述四种方法进行分类效果比较,表3~5给出了测试样本的故障诊断结果,可知相较传统的分类方法,对于仿真所得故障数据的诊断率均不高,但是所提出的

GLSP 降维方法所获得的低维有效数据在大部分情况下获得最高的故障识别精度, 未获得最高识别精度情况下, 其精度与最高精度相差不大。

表 3 故障 1 识别准确率 (%)

Table 3 The accuracy of fault1 diagnosis (%)

方法	Fault1					
	KPCA	KLPP	KFDA	LGPCA	TGLSA	GLSP
ELM	55.32	61.38	60.58	54.21	58.69	62.97
SVM	58.69	70.61	71.68	65.34	68.49	69.27
RVM	72.77	69.59	74.21	68.98	63.40	76.35
KNN	72.26	66.86	70.38	75.49	77.36	78.53

表 4 故障 2 识别准确率 (%)

Table 4 The accuracy of fault2 diagnosis (%)

方法	Fault2					
	KPCA	KLPP	KFDA	LGPCA	TGLSA	GLSP
ELM	80.95	76.85	79.65	77.49	70.28	82.62
SVM	78.36	77.32	77.05	74.39	72.15	80.09
RVM	79.74	74.16	78.66	85.68	81.29	83.62
KNN	82.35	82.63	75.39	78.91	86.54	88.84

表 5 故障 3 识别准确率 (%)

Table 5 The accuracy of fault3 diagnosis (%)

方法	Fault3					
	KPCA	KLPP	KFDA	LGPCA	TGLSA	GLSP
ELM	70.65	72.39	77.16	74.29	70.53	79.26
SVM	66.34	68.29	68.49	65.39	60.87	66.58
RVM	59.38	62.58	55.21	59.86	60.13	66.34
KNN	58.62	62.38	65.98	63.24	61.09	65.08

5) 降维效果综合衡量指标

时间性能比较是在实验室台式机电脑上进行, 其配置为 Intel Core i3 CPU 3.3 GHz, RAM 4 GB, Win7 操作系统, 仿真软件为 MATLAB 2010a, 计算结果如表 6 所示。由表 6 可知, 本文所提方法降

表 6 特征提取所需时间 (s)

Table 6 Feature extraction time (s)

维度	特征提取方法					
	KPCA	KLPP	KFDA	LGPCA	TGLSA	GLSP
3	0.651	1.155	1.039	2.598	2.134	1.596
5	0.795	1.159	1.118	2.019	1.495	1.632
8	0.815	1.209	0.975	1.069	1.396	1.885
10	0.867	1.344	1.185	1.563	2.098	1.962

维所需时间相对于其他方法有所增加, 但是都在一个数量级, 且运行速度均在 5s 以内, 满足实际情况中对于实时的要求。

3.2 TE 数据仿真

TE 过程是一个公认的对比各种控制和监控方案的平台, 为验证本文所提方法的通用性, 将本文算法应用于故障检测与诊断领域被广泛使用的 TE 化工数据集上。TE 过程是基于真实工业过程的仿真平台, 包含了一组正常状态和 21 组不同故障状态, 分别涵盖了 12 个操纵变量和 41 个测量变量, 每组状态包含 480 组训练数据和 960 组测试数据, 每一组故障从第 160 个数据点引入, 过程的详细描述、工艺流程图以及其故障形式的具体介绍见文献 [31]。

从 TE 数据集中选取 1 组正常工况数据和 3 组故障数据 (故障 4、故障 8 和故障 14), 使用本文所提 GLSP 算法得到降维后的前两维特征矢量, 对于 TE 数据, 前两维即可较好体现降维效果, 本文权重参数根据计算得到 $\beta_C = 0.64$, $\beta_L = 0.36$, 并将本文算法与 KPCA、KLPP、KFDA、LGPCA 和 TGLSA 五种降维方法进行比较, 如图 11 至图 16。

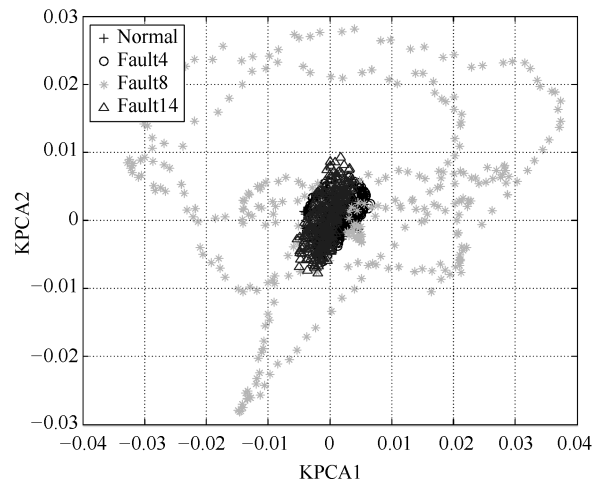


图 11 TE 数据下 KPCA 算法降维效果

Fig. 11 The dimension reduction performance of KPCA on TE data

从图 11 和图 12 前两维降维效果可以看出, KPCA 和 KLPP 对于 4 类数据分离效果较差, 特别是正常工况与故障 4 和故障 14 存在大量重合现象; 图 13 和图 14 中 KFDA 和 LGPCA 方法对于正常工况和故障 14 难以有效区分; 图 15 和图 16 的特征提取效果略好于前几种方法, 但 TGLSA 方法虽然能够较好地地区分故障 4 和故障 14, 但是正常工况和故障 8 仍有较大重叠, 而本文所提算法提取了更为丰富的全局与局部结构信息, 在完成数据降维可视化的同时能够将四类数据有效分离。

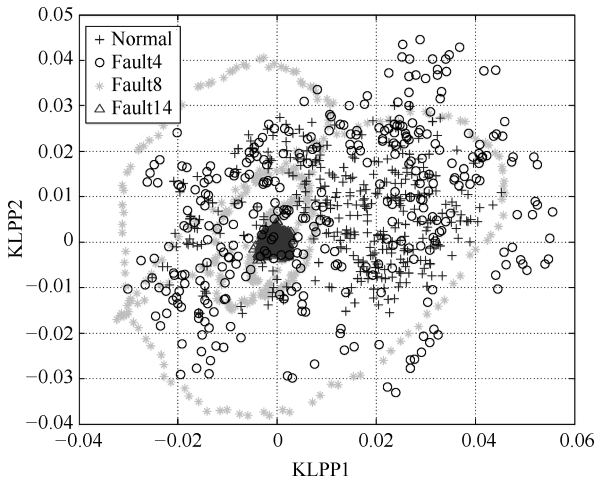


图 12 TE 数据下 KLPP 算法降维效果

Fig. 12 The dimension reduction performance of KLPP on TE data




图 15 TE 数据下 TGLSA 算法降维效果

Fig. 15 The dimension reduction performance of TGLSA on TE data

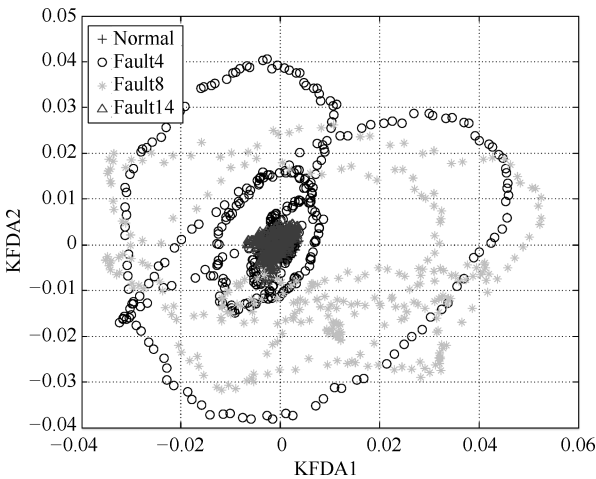


图 13 TE 数据下 KFDA 算法降维效果

Fig. 13 The dimension reduction performance of KFDA on TE data




图 16 TE 数据下 GLSP 算法降维效果

Fig. 16 The dimension reduction performance of GLSP on TE data




图 14 TE 数据下 LGPCA 算法降维效果

Fig. 14 The dimension reduction performance of LGPCA on TE data

4 结论

本文通过融合全局特征提取 KPCA 与局部特征提取 KLPP 两种降维方法, 提出一种结合两种降维方法的数据维数约简方法 GLSP, 增强了数据低维可视化效果, 同时提高了识别精度, 并将其应用于故障诊断中. 所提方法将流形学习保持局部结构的思想融入核主成分分析的目标函数中, 使得到的特征空间不仅具有原始样本空间的整体结构, 还保持样本空间相似的局部近邻结构, 可以包含更丰富的特征信息. 使用 AVL Boost 软件对船舶柴油机工作过程进行故障仿真, 提取正常工况与故障工况下的仿真数据, 并将 AVL Boost 软件仿真数据和 TE 化工公共故障数据应用到所提方法中, 实验结果证明, 本文所提 GLSP 算法具有较好的维度约简效果, 并

具有较高分类精度的优势。

References

- 1 Zhao Xiao-Li, Zhao Rong-Zhen. A method of dimension reduction of rotor faults data set based on fusion of global and local discriminant information. *Acta Automatica Sinica*, 2017, **43**(4): 560–567
(赵孝礼, 赵荣珍. 全局与局部判别信息融合的转子故障数据集降维方法研究. *自动化学报*, 2017, **43**(4): 560–567)
- 2 Garcia-Alvarez D, Fuente M J, Sainz G I. Fault detection and isolation in transient states using principal component analysis. *Journal of Process Control*, 2012, **22**(3): 551–563
- 3 Han M, Jiang L W. Endpoint prediction model of basic oxygen furnace steelmaking based on PSO-ICA and RBF neural network. In: Proceedings of the 2010 IEEE International Conference on Intelligent Control and Information Processing. Dalian, China: IEEE, 2010. 388–393
- 4 Han M, Zhong K, Qiu T, Han B. Interval type-2 fuzzy neural networks for chaotic time series prediction: a concise overview. *IEEE Transactions on Cybernetics*, DOI: 10.1109/TCYB.2018.2834356
- 5 Zhang Y W, Zhou H, Qin S J. Decentralized fault diagnosis of large-scale processes using multiblock kernel principal component analysis. *Acta Automatica Sinica*, 2010, **36**(4): 593–597
- 6 Zhang Xiao-Tao, Tang Li-Wei, Wang Ping, Deng Shi-Jie. Fault feature enhancement method based on multiscale orthogonal PCA-LPP manifold learning algorithm. *Journal of Vibration and Shock*, 2015, **34**(13): 66–70
(张晓涛, 唐力伟, 王平, 邓士杰. 基于多尺度正交 PCA-LPP 流形学习算法的故障特征增强方法. *振动与冲击*, 2015, **34**(13): 66–70)
- 7 Li Juan, Wang Yu-Ping. A fast neighbor prototype selection algorithm based on local mean and class global information. *Acta Automatica Sinica*, 2014, **40**(6): 1116–1125
(李娟, 王宇平. 考虑局部均值和类全局信息的快速近邻原型选择算法. *自动化学报*, 2014, **40**(6): 1116–1125)
- 8 Wang Jian, Feng Jian, Han Zhi-Yan. Locally preserving PCA method based on manifold learning and its application in fault detection. *Control and Decision*, 2013, **28**(5): 683–687
(王健, 冯健, 韩志艳. 基于流形学习的局部保持 PCA 算法在故障检测中的应用. *控制与决策*, 2013, **28**(5): 683–687)
- 9 Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, **290**(5500): 2319–2323
- 10 Sprekeler H. On the relation of slow feature analysis and Laplacian eigenmaps. *Neural Computation*, 2011, **23**(12): 3287–3302
- 11 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, **290**(5500): 2323–2326
- 12 He X F, Yan S C, Hu Y X, Niyogi P, Zhang H J. Face recognition using laplacianfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(3): 328–340
- 13 Deng X G, Tian X M. Sparse kernel locality preserving projection and its application in nonlinear process fault detection. *Chinese Journal of Chemical Engineering*, 2013, **21**(2): 163–170
- 14 Yuan Min, Cheng Lei, Zhu Ran-Gang, Lei Ying-Ke. A new supervised manifold learning algorithm based on MMC and LSE. *Acta Automatica Sinica*, 2013, **39**(12): 2077–2089
(袁警, 程雷, 朱然刚, 雷迎科. 一种新的基于 MMC 和 LSE 的监督流形学习算法. *自动化学报*, 2013, **39**(12): 2077–2089)
- 15 Zhao Xu, Yan Wei-Wu, Shao Hui-He. Nonlinear statistical process monitoring and fault diagnosis based on kernel Fisher discriminant analysis. *Journal of Chemical Industry and Engineering (China)*, 2007, **58**(4): 951–956
(赵旭, 阎威武, 邵惠鹤. 基于核 Fisher 判别分析方法的非线性统计过程监控与故障诊断. *化工学报*, 2007, **58**(4): 951–956)
- 16 Kahveci N E, Impram S T, Genc A U. Boost pressure control for a large diesel engine with turbocharger. In: Proceedings of the 2014 American Control Conference. Portland, OR, USA: IEEE, 2014. 2108–2113
- 17 Han Min, Zhang Zhan-Kui. Fault detection and diagnosis method based on modified kernel principal component analysis. *CIESC Journal*, 2015, **66**(6): 2139–2149
(韩敏, 张占奎. 基于改进核主成分分析的故障检测与诊断方法. *化工学报*, 2015, **66**(6): 2139–2149)
- 18 Zhang M G, Ge Z Q, Song Z H, Fu R W. Global-local structure analysis model and its application for fault detection and identification. *Industrial & Engineering Chemistry Research*, 2011, **50**(11): 6837–6848
- 19 Deng X G, Tian X M, Chen S. Modified kernel principal component analysis based on local structure analysis and its application to nonlinear process fault diagnosis. *Chemo-metrics and Intelligent Laboratory Systems*, 2013, **127**(16): 195–209
- 20 Luo L J, Bao S Y, Gao Z L, Yuan J Q. Batch process monitoring with tensor global-local structure analysis. *Industrial & Engineering Chemistry Research*, 2013, **52**(50): 18031–18042
- 21 Liu Q S, Tang X O, Lu H Q, Ma S D. Face recognition using kernel scatter-difference-based discriminant analysis. *IEEE Transactions on Neural Networks*, 2006, **17**(4): 1081–1085
- 22 Dufrenois F. A one-class kernel fisher criterion for outlier detection. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, **26**(5): 982–994
- 23 Mika S, Ratsch G, Weston J, Scholkopf B, Mullers K R. Fisher discriminant analysis with kernels. In: Proceedings of the 1999 IEEE Signal Processing Society Workshop. Madison, WI, USA: IEEE, 1999. 41–48

- 24 Bo L F, Wang L, Jiao L C. Feature scaling for kernel fisher discriminant analysis using leave-one-out cross validation. *Neural Computation*, 2006, **18**(4): 961–978
- 25 Chen Fa-Fa, Tang Bao-Ping, Su Zu-Qiang. Rotating machinery fault diagnosis based on isometric mapping and weighted KNN. *Chinese Journal of Scientific Instrument*, 2013, **34**(1): 215–220
(陈法法, 汤宝平, 苏祖强. 基于等距映射与加权 KNN 的旋转机械故障诊断. 仪器仪表学报, 2013, **34**(1): 215–220)
- 26 Wang Ze-Jie, Hu Hao-Min. On parameter selection in manifold learning algorithm. *Computer Applications and Software*, 2010, **27**(6): 84–85, 102
(王泽杰, 胡浩民. 流形学习算法中的参数选择问题研究. 计算机应用与软件, 2010, **27**(6): 84–85, 102)
- 27 Yang Y S, Ming A B, Zhang Y Y, Zhu Y S. Discriminative non-negative matrix factorization (DNMF) and its application to the fault diagnosis of diesel engine. *Mechanical Systems and Signal Processing*, 2017, **95**: 158–171
- 28 Su Zu-Qiang, Tang Bao-Ping, Liu Zi-Ran, Qin Yi. Fault diagnosis method based on orthogonal semi-supervised local Fisher discriminant analysis. *Journal of Mechanical Engineering*, 2014, **50**(18): 7–13
(苏祖强, 汤宝平, 刘自然, 秦毅. 基于正交半监督局部 Fisher 判别分析的故障诊断. 机械工程学报, 2014, **50**(18): 7–13)
- 29 Cho H W. Nonlinear feature extraction and classification of multivariate data in kernel feature space. *Expert Systems with Applications*, 2007, **32**(2): 534–542
- 30 Yu J B. Local and global principal component analysis for process monitoring. *Journal of Process Control*, 2012, **22**(7): 1358–1373
- 31 Li G, Qin S J, Ji Y D, Zhou D H. Reconstruction based fault prognosis for continuous processes. *Control Engineering Practice*, 2010, **18**(10): 1211–1219



韩敏 大连理工大学电子信息与电气工程学部教授. 主要研究方向为模式识别, 复杂系统建模与分析及时间序列预测. 本文通信作者.

E-mail: minhan@dlut.edu.cn

(**HAN Min** Professor at the Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology.

Her research interest covers pattern recognition, modeling and analysis of complex system, and time series prediction. Corresponding author of this paper.)



李宇 大连理工大学电子信息与电气工程学部硕士研究生. 主要研究方向为柴油机故障诊断技术.

E-mail: liyu0512@mail.dlut.edu.cn

(**LI Yu** Master student at the Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology. His main research interest is

diesel engine fault diagnosis.)



韩冰 上海船舶航运研究院航海与安全技术国家重点实验室研究员. 主要研究方向为船舶动力平台故障诊断和故障预测. E-mail: hanbing@sssri.com

(**HAN Bing** Researcher at the State Key Laboratory of Navigation and Safety Technology, Shanghai Ship and Shipping Research Institute. His

research interest covers fault diagnosis and prognostic of ship power plant.)