

流形结构化半监督扩展字典学习的旋转设备故障诊断

周杰, 陈晓方[†], 谢永芳, 邓紫晴, 谢世文

(中南大学 自动化学院, 湖南 长沙 410083)

摘要: 针对有标签数据不足及传统故障诊断模型判别性差的问题, 本文提出一种流形结构化半监督扩展字典学习(MS-SSEDL)的故障诊断方法. 首先, 为改善缺少有标签数据而导致模型的识别性能较差问题, 在MS-SSEDL模型中提出无标签数据重构误差项, 利用无标签数据学习置信度矩阵, 从而学习得到扩展字典以增强字典学习的表示性. 然后, 为增强MS-SSEDL模型的判别性, 通过保存数据的流形结构, 学习数据中内在几何信息的稀疏表示, 增强信号表示能力及字典判别性. 最后, 在数字图像、轴承故障及齿轮故障公共数据集的实验表明所提MS-SSEDL方法比其他先进方法的识别性能更优越.

关键词: 字典学习; 故障诊断; 半监督学习; 流形学习; 机器学习

引用格式: 周杰, 陈晓方, 谢永芳, 等. 流形结构化半监督扩展字典学习的旋转设备故障诊断. 控制理论与应用, 2023, 40(6): 1069 – 1078

DOI: 10.7641/CTA.2022.20163

Manifold structured semi-supervised extended dictionary learning for rotating machinery fault diagnosis

ZHOU Jie, CHEN Xiao-fang[†], XIE Yong-fang, DENG Zi-qing, XIE Shi-wen

(College of Automation, Central South University, Changsha Hunan 410083, China)

Abstract: Aiming at the problems of insufficient labeled data and poor discriminability of traditional fault diagnosis models, a manifold structured semi-supervised extended dictionary learning for rotating machinery fault diagnosis (MS-SSEDL) is proposed. First, in order to improve the problem of poor recognition performance due to the lack of labeled data, an unlabeled data reconstruction error term is proposed in the MS-SSEDL model, and the unlabeled data is used to learn the confidence matrix, so as to learn the extended dictionary to enhance the representation of dictionary learning. Then, in order to enhance the discriminativeness of the MS-SSEDL model, by preserving the manifold structure of the data, a sparse representation of the intrinsic geometric information in the data is learned, and the signal representation ability and dictionary discrimination ability are enhanced. Finally, experiments on public datasets of digital images, bearing faults and gear faults show that the proposed MS-SSEDL method outperforms other state-of-the-art methods.

Key words: dictionary learning; fault diagnosis; semi-supervised learning; manifold learning; machine learning

Citation: ZHOU Jie, CHEN Xiaofang, XIE Yongfang, et al. Manifold structured semi-supervised extended dictionary learning for rotating machinery fault diagnosis. *Control Theory & Applications*, 2023, 40(6): 1069 – 1078

1 引言

随着工业的快速发展, 机械设备变得越来越复杂. 由于严峻的工业环境、设备的长期运行等原因, 机械设备在运行过程中不可避免地发生故障, 则可能导致整个工业流程停产. 因而故障诊断技术显得尤其重要, 利用有效的故障诊断技术, 可以有效识别出故障类型. 旋转设备是工业环境中最重要的部件之一. 旋转机械设备的一些关键部件, 比如齿轮箱、滚动轴承等会经

常发生故障^[1].

因为旋转设备故障诊断的频发性及重要性, 旋转设备故障诊断一直是热门的研究领域. 旋转设备故障诊断方法一般分为故障特征提取方法和模式识别方法^[2]. 特征提取方法主要是利用信号分析方法分析故障特征频率与理论故障频率的关系, 进而确定故障类型^[3-4]. 但是特征提取方法需要计算信号中心频率或者带宽, 这样会容易受到噪声干扰, 导致估计故障频

收稿日期: 2022-03-07; 录用日期: 2022-09-16.

[†]通信作者. E-mail: xiaofangchen@csu.edu.cn; Tel.: +86 13787276890.

本文责任编辑: 吴敏.

国家自然科学基金项目(62133016)资助.

Supported by the National Natural Science Foundation of China (62133016).

率较困难^[5].

与特征提取方法相比较,模式识别方法不需要研究信号的故障特征频率,只需要建立相关模型便可有效实现对设备故障诊断.近年来,深度学习、机器学习方法受到广泛关注,模式识别方法在故障诊断领域应用越来越广泛. Jiang等人^[6]将多尺度方法与卷积神经网络结合,提出了一种多尺度卷积神经网络方法,将其应用在自动识别风机齿轮箱的不同健康状况. Sun等人^[7]提出了一种基于卷积鉴别特征学习模型应用于感应电机故障诊断. Sadoughi和Hu^[8]将深度学习融合物理方法提出一种基于物理的卷积神经网络.虽然这些方法能够取得较好的效果,但是深度学习方法可解释性差,且学习过程计算量大,所耗时间长^[9].

近年来,一种新兴的稀疏编码(sparse coding, SC)方法在故障诊断领域取得较好的效果.稀疏编码的主要思想是在满足一定的约束条件下,将信号用字典中的少数字典原子线性表示.字典学习的字典将决定分类的性能,因而需要探索比较有效的字典学习方法.近年来也提出了一些有效的字典学习方法,例如判别字典学习(discriminative K-singular value decomposition, DKSVD)^[10]、标签一致字典学习(label consistent dictionary learning, LCDL)^[11]、Fisher判别字典学习(fisher discriminant dictionary learning, FDDL)^[12]等,这些方法都能取得不错的效果.因为字典学习的良好信号表示能力以及分类性能,字典学习在故障诊断领域得到了广泛的应用. Wang等人^[13]提出一种加权字典学习方法应用于机械设备故障诊断. Zhou等人^[14]提出一种低维多尺度Fisher判别字典学习,并将其应用于齿轮故障诊断. Liu等人^[15]提出一种自适应特征提取字典学习方法,将其应用于轴承故障诊断.虽然上述字典学习方法都能够取得一定的效果,但是这些方法都需要大量的有标签数据,有标签数据却难以获得,有标签数据不足则会导致字典的泛化能力较差、精度较低、模型不可靠等问题.

然而,无标签数据较易获得,半监督学习可以综合利用有标签数据以及无标签数据,学习得到具有较强泛化能力以及表示能力的字典.研究者们提出了一些半监督字典学习, Wang等人^[16]利用标记样本和未标记样本之间的结构稀疏关系从而提出了结构稀疏保存字典学习(dictionary learning via structural sparse preserving, SSP-DL)方法. Chen和Yang^[17]利用基于类特定重建误差的标签传播算法来准确估计未标记数据的标签,提出标签传播半监督字典学习(semi-supervised dictionary learning with label propagation, SSD-LP)方法. Shrivastava等人^[18]在FDDL基础上添加无标签数据重构误差,提出一种半监督判别字典学习(semi-supervised discriminative dictionaries, S2D2)方法.虽然上述方法相对监督字典学习方法能取得较好

效果,但是仍然存在缺点.首先,上述方法缺少从无标签数据学习特征来完善整体字典,因而字典的表示能力、泛化能力、鲁棒性较弱;其次,由于有标签数据不足,字典的判别性较差,仅仅依赖数据域特征来提高识别能力,效果较差.

为解决有标签数据缺少和整体字典完备性不足的问题,本研究提出一种新的半监督字典学习方法.为了有效从无标签数据学习特征,所提流行结构化半监督扩展字典学习(manifold structured semi-supervised extended dictionary learning, MS-SSEDL)模型利用无标签数据学习置信度矩阵,置信度矩阵可以让置信度越高的样本对相应类别的扩展字典贡献越大,从而保证从无标签数据学习到的扩展字典的可靠性,提高标签分配错误的鲁棒性,从无标签数据学习到的扩展字典与从有标签数据学习得到的字典共同组成整体字典,扩展字典包含丰富的无标签数据特征,因此扩展字典可以改善由于有标签数据缺少而导致的整体字典完备性不足的问题.此外,传统字典学习方法只学习了数据本身存在的数据域特征,流形学习的研究发现数据本身还存在内部几何结构特征^[19-20],通过保存数据的内部几何结构特征,可以加强模型的判别性^[21].

本文的贡献主要有:

- 1) 本研究将字典学习与半监督学习结合,可以有效解决由于工业环境有标签数据缺少而导致模型学习效果不理想的问题;
- 2) 为无标签数据引入置信度矩阵,确保学习到扩展字典的可靠性,有效学习无标签数据特征;
- 3) 利用局部线性嵌入方法考虑了数据的内部几何结构特征,增强模型的判别性及可靠性.

本文的其余部分结构如下:第2节详细介绍了所提出的方法;第3节是实验结果与分析部分;第4节对论文进行了总结.

2 MS-SSEDL模型

2.1 流形结构保存

传统的字典学习方法没有考虑数据的几何结构,然而通过考虑数据的内部几何结构,可以提高模型的判别能力^[21].局部线性嵌入^[19]是一种有效的流形学习方法,利用该方法可以保存数据的局部几何结构.本研究利用局部线性嵌入将流形结构从原始数据保存到稀疏编码空间,这可以认为是对稀疏编码的正则化,最后将其简化成稀疏编码的图正则化形式.利用这种方法可以有效保存数据的流形结构,学习数据的内部几何结构特征,增强字典的判别性能以及信号表示能力.

本文保存流形结构的主要做法是,首先假设观察到的数据是从平滑流形采样得到,并假设采样足够密

集,则可以假设数据在整个数据集的小范围内是线性的^[19].此时,可以利用局部线性嵌入方法计算数据的流形结构,计算主要步骤如下所示:

步骤 1 用 K 近邻方法计算每个样本 x_i 的近邻点 $knn(i)$;

步骤 2 通过求解式(1)优化问题,计算每一个近邻点权重系数矩阵,即

$$\hat{w}_i = \arg \min_{w_i \in R^k} \|x_i - \sum_{j \in knn(i)} w_{i,j} x_j\|_2^2, \quad (1)$$

$$\text{s.t.} \quad \sum_{j \in knn(i)} w_{i,j} = 1,$$

其中: $knn(i)$ 代表样本 x_i 的 k 个近邻样本, w_i 是包含 k 个 $w_{i,j}$ 元素的向量, $j \in knn(i)$;

步骤 3 将这种局部线性结构映射到低维空间,为了尽可能保留原始空间性质,则可以定义

$$\Gamma(A) = \alpha \sum_{i=1}^N \|a_i - \sum_{j \in knn(i)} \hat{w}_{i,j} a_j\|_2^2, \quad (2)$$

式中: α 是一个正常数, a_i 表示稀疏编码;

步骤 4 为进一步简化优化问题,引进矩阵 $V \in R^{N \times N}$, 有

$$V[i, j] = \begin{cases} \hat{w}_{i,j}, & j \in knn(i), \\ 0, & \end{cases} \quad (3)$$

因此, $\Gamma(A)$ 可转化成 $\Gamma(A) = \alpha \|A - AV\|_2^2 = \alpha \text{tr}(A \cdot L_A A^T)$, 其中 $L_A = I_N - V^T - V + V^T V V^T V$, I_N 是单位矩阵, L_A 是一个拉普拉斯矩阵,因而最后将函数 $\Gamma(A)$ 转化成是拉普拉斯图的形式.

2.2 目标函数

本文提出的流形结构化半监督扩展字典学习的目标函数如下:

$$\min_{D, E, P, A, y} \sum_{i=1}^C (\|X_i - [D_i E_i] A_i\|_F^2 + \alpha \text{tr}(A_i L_{A_i} A_i^T) + \beta \|A_i\|_1) + \sum_{j=1}^{N_u} (\sum_{i=1}^C P_{i,j} \|b_j - [D_i E_i] y_j^i\|_F^2 + \beta \|y_j^i\|_1), \quad (4)$$

$$\text{s.t.} \quad \sum_{i=1}^C P_{i,j} = 1.$$

式中: $X = [X_1 \cdots X_i \cdots X_C]$ 是有标签训练集,一共包含 C 类不同的样本,第 i 类训练样本 $X_i = [x_1^i \cdots x_{N_i}^i]$; $B = [b_1 \cdots b_i \cdots b_{N_u}]$ 是包含 N_u 个无标签训练样本. $[D_i E_i]$ 表示学习到的字典,这与传统字典学习有所不同,本文将需要的字典分为两部分, $D = [D_1 \cdots D_i \cdots D_C]$ 以及 $E = [E_1 \cdots E_i \cdots E_C]$, D_i 代表第 i 类监督字典, E 是扩展字典, E_i 代表第 i 类扩展字典,扩展字典是为了挖掘无标签数据的判别性特征,作为整体字典的补充. $A = [A_1 \cdots A_i \cdots A_C]$ 表示有标签数据稀疏编码. y_j^i 是无标签数据

稀疏编码,表示第 j 个数据的第 i 类稀疏编码. $P_{i,j}$ 表示第 j 个无标签数据属于第 i 类的置信度. L_A 是在局部线性嵌入方法中利用数据样本计算得到的拉普拉斯矩阵. 约束条件 $\sum_{i=1}^C P_{i,j} = 1$ 表示第 j 类无标签数据属于每一类样本置信度的和为 1. α, β 都是正参数,用于控制目标函数对应项的权重. 本文框架如图 1 所示.

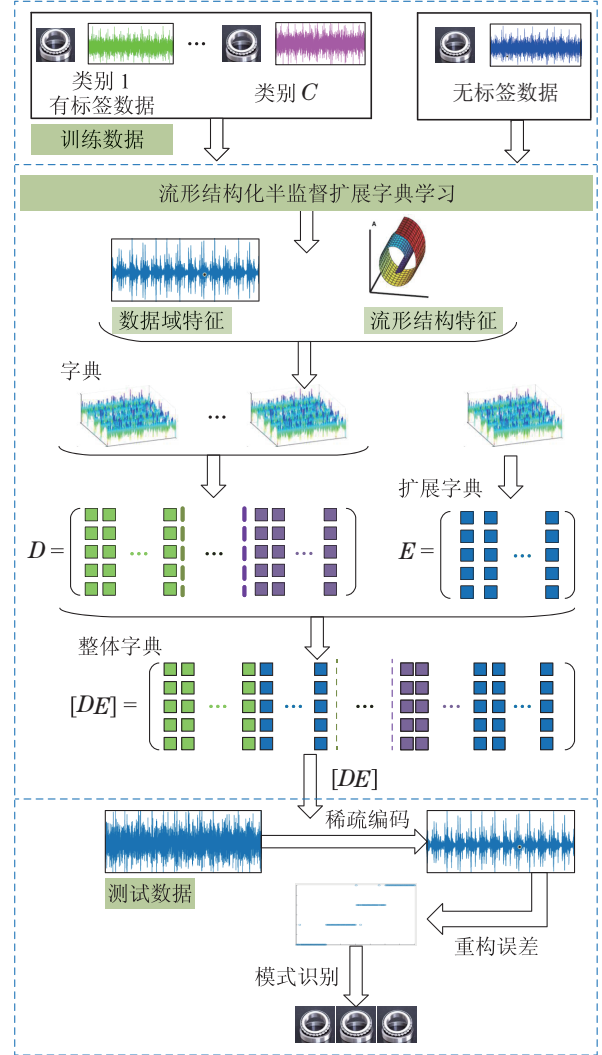


图 1 框架

Fig. 1 Framework

目标函数中 $\|X_i - [D_i E_i] A_i\|_F^2$ 表示有标签数据重构误差项; $\alpha \text{tr}(A_i L_{A_i} A_i^T)$ 表示图正则化稀疏编码,为了保存数据的流形结构,通过局部线性嵌入方法保存数据的流形结构; $P_{i,j} \|b_j - [D_i E_i] y_j^i\|_F^2$ 表示无标签数据的重构误差项,应尽量让字典 $[D_i E_i]$ 较好表示数据,满足重构误差尽量小的要求;置信度 $P_{i,j}$ 可以保证置信度高的无标签样本影响更大,而使得置信度低的无标签样本影响更小,则能确保所提方法更有弹性地利用无标签数据,对标签分配错误更具有鲁棒性; $\beta \|A_i\|_1, \beta \|y_j^i\|_1$ 分别是有标签数据稀疏编码以及无标签数据稀疏编码.

2.3 优化过程

由于目标函数包含 D, E, P, X, y 多个变量, 不能直接求解, 可以采取迭代优化求解, 求解过程是一个凸优化问题. 本文采用交替优化求解, 本研究的优化过程如下所示:

初始化: 在迭代优化之前, 需要初始化字典 D 以及无标签稀疏编码 y . 字典 D 的初始化是一个典型的(K-singular value decomposition, K-SVD)问题, 本文首先利用K-SVD^[22]算法初始化字典 D ; 初始化 D 后, 再固定其他项, 无标签数据稀疏编码初始化问题则可以看出成式(5), 式(5)中的优化问题是一个最小绝对收缩和选择算法(least absolute shrinkage and selection operator, LASSO)问题, 众多学者提出针对该问题的求解方法, 包括贪婪法和松弛法, 如最小角回归法(least angle regression, LARS)和匹配追踪算法(orthogonal matching pursuit, OMP)^[23-24], 考虑到信号的重建精度以及方法的整体精确度^[25-26], 本文利用OMP^[27]初始化无标签数据稀疏编码 y .

$$\begin{aligned} \min_{Y^i} & \|B_i - D_i Y^i\|_F^2, \\ \text{s.t.} & \|Y^i\|_0 \leq T_0. \end{aligned} \quad (5)$$

更新置信度矩阵 P : 通过计算每一个样本属于不同类的置信度 $P_{i,j}$ 来更新置信度矩阵 P , 第 j 个无标签数据属于第 i 类的置信度更新如下:

$$P_{i,j} = \exp\{-\varepsilon_j^i / o\} / \sum_{i=1}^C \exp\{-\varepsilon_j^i / o\}, \quad (6)$$

其中 $\varepsilon_j^i = \|b_j - [D_i E_i] y_j^i\|_F^2$ 表示第 j 个无标签数据的第 i 类重构误差, o 是正参数.

更新扩展字典 E_i : $\sum_{j=1}^N P_{i,j} \|b_j - [D_i E_i] y_j^i\|_F^2$ 改写成

$$\begin{aligned} & \|[\sqrt{P_{i,1}} b_1 \cdots \sqrt{P_{i,j}} b_j \cdots \sqrt{P_{i,N_u}} b_{N_u}] - \\ & [D_i E_i][\sqrt{P_{i,1}} y_1 \cdots \sqrt{P_{i,j}} y_j \cdots \sqrt{P_{i,N_u}} y_{N_u}]\|_F^2, \end{aligned} \quad (7)$$

则利用奇异值分解有

$$[U, S, V] = \text{svd}([\sqrt{P_{i,1}} b_1 \cdots \sqrt{P_{i,N_u}} b_{N_u}]), \quad (8)$$

因此字典 E_i 的更新为 $E_i = U(:, n)$, 其中的 n 是扩展字典原子的数量.

更新稀疏编码 y_j : 通过固定其他项, 只更新稀疏编码 y_j , 优化问题转化为

$$\begin{aligned} \min_y & \|[\sqrt{P_{i,1}} b_1 \cdots \sqrt{P_{i,j}} b_j \cdots \sqrt{P_{i,N_u}} b_{N_u}] - \\ & [D_i E_i][\sqrt{P_{i,1}} y_1 \cdots \sqrt{P_{i,j}} y_j \cdots \sqrt{P_{i,N_u}} y_{N_u}]\|_F^2 + \\ & \beta \|y\|_1, \end{aligned} \quad (9)$$

式(9)改写为

$$\begin{aligned} \min_{Y^i} & \|B_i - [D_i E_i] Y^i\|_F^2, \\ \text{s.t.} & \|Y^i\|_0 \leq T_0, \end{aligned}$$

改写后的式中 B_i 表示所有样本属于第 i 类的置信度与对应无标签样本的乘积 $B_i = [\sqrt{P_{i,1}} b_1 \cdots \sqrt{P_{i,j}} b_j \cdots \sqrt{P_{i,N_u}} b_{N_u}]$, Y^i 表示所有样本属于第 i 类的置信度与其对应稀疏编码的乘积 $Y^i = [\sqrt{P_{i,1}} y_1 \cdots \sqrt{P_{i,j}} y_j \cdots \sqrt{P_{i,N_u}} y_{N_u}]$, 这样可以很容易的更新稀疏编码 Y^i , 本文采用OMP^[24]求解 $Y^i = [D_i E_i] \times ([D_i E_i]^T [D_i E_i])^{-1} [D_i E_i]^T B_i$.

更新稀疏编码 A_i : 先固定其他项, 只更新稀疏编码 A_i , 则优化问题是凸的, 优化问题转化为

$$\begin{aligned} \min_A & \sum_{i=1}^C (\|X_i - [D_i E_i] A_i\|_F^2 + \alpha \text{tr}(A_i L_{A_i} A_i^T) + \\ & \beta \|A_i\|_1), \end{aligned} \quad (10)$$

利用一种快速迭代收缩阈值算法(a fast iterative shrinkage-thresholding algorithm, FISTA)^[28]反向传播可以有效的求解稀疏编码, 当迭代至 n 次, 即

$$A_i^{n+1} = Z_i^n + v(Z_i^{n+1} - Z_i^n), \quad (11)$$

式中: $v = 1 + \frac{t_n - 1}{t_n + 1}$, $t_{n+1} = \frac{1 + \sqrt{4t_n^2 + 1}}{2}$, $Z_i^{n+1} =$

$\text{sgn} H \circ \max(|H| - \frac{\lambda}{\tau}, 0)$, $\lambda \tau > 0$, $H = A_i^n - \tau^{-1} \nabla f(A_i^n)$, $\nabla f(A_i^n)$ 是 $f(A_i^n)$ 对 A_i^n 的导数, 其中 $f(A_i) = \|X_i - [D_i E_i] A_i\|_F^2 + \alpha \text{tr}(A_i L_{A_i} A_i^T)$.

更新字典 D_i : 先固定其他项, 只更新字典 D_i , 优化问题转化为

$$\begin{aligned} \min_{D_i} & \sum_{i=1}^C \|X_i - [D_i E_i] A_i\|_F^2 + \\ & \sum_{j=1}^{N_u} \sum_{i=1}^C P_{i,j} \|b_j - [D_i E_i] y_j^i\|_F^2. \end{aligned} \quad (12)$$

本文利用 Metaface^[29]按类更新字典原子, 有效求解字典 D_i , 求解得到第 i 类字典的第 l 个字典原子 $d_l^i = (\|a_l^i\|_2^2 + \|y_l^i\|_2^2)^{-1} \{(X_i - \sum_{r \neq l} d_r^i a_r^i)(a_r^i)^T + (B_i - \sum_{r \neq l} d_r^i y_r^i)(y_r^i)^T\}$. 其中 $D_i = [d_1^i \cdots d_j^i \cdots d_k^i]$ 表示第 i 类字典; 稀疏编码 $A = [A_1 \cdots A_i \cdots A_C]$ 共包含 C 类稀疏编码; 无标签数据第 i 类稀疏编码 $Y^i = [\sqrt{P_{i,1}} y_1 \cdots \sqrt{P_{i,N_u}} y_{N_u}] = [y_1^i \cdots y_{N_u}^i]$; X_i 是第 i 类有标签样本, B_i 表示所有样本属于第 i 类的置信度与对应无标签样本的乘积 $B_i = [\sqrt{P_{i,1}} b_1 \cdots \sqrt{P_{i,j}} b_j \cdots \sqrt{P_{i,N_u}} b_{N_u}]$.

2.4 分类模型

本文分类模型如下所示:

$$\min_{A_i} \sum_{i=1}^C \|X - [D_i E_i] A_i\|_2^2, \quad (13)$$

$$\varepsilon_i = \|b - [D_i E_i] y^i\|_2^2, \quad (14)$$

$$C = \min\{\varepsilon\}. \quad (15)$$

将所提字典学习方法求解得到的字典 $[D_i E_i]$ 代入式(13)分类模型, 利用字典稀疏表示测试集信号, 再利用OMP^[24]算法求解测试集样本的稀疏编码 A_i . 求解得到测试样本稀疏编码后, 利用式(14)计算样本的重构误差 $\varepsilon = [\varepsilon_1 \cdots \varepsilon_C]$, ε_i 表示样本的第 i 类重构误差, 根据式(15)利用重构误差便可有效识别样本的类别.

3 实验结果

为验证方法的有效性, 本研究将所提方法在3个数据集进行验证. 考虑到其他先进论文方法已经在数字图像做了实验, 为证明方法相对其他方法的优越性, 首先将所提方法在数字图像验证并与其他先进论文方法作比较; 再将所提方法应用在轴承数据、齿轮数据, 进而实现机械设备的故障诊断. 在实验中, 通过 K 折交叉验证方法选取对应的参数, 以实现较好的模型效果.

3.1 数字图像实验

本文验证了在修改后的国家标准技术研究所(modified national institute of standards and technology, MNIST)数据集^[30]和美国邮政服务(united states postal service, USPS)数据集^[31]上的效果, 本实验与DKSVD, FDDL, 标签一致字典学习(label consistent K-singular value decomposition, LC-KSVD)^[11], 在线半监督判别字典学习(online semi-supervised discriminative dictionary learning, OSSDL)^[32], SD2D^[18], 半监督鲁棒字典学习(semi-supervised robust dictionary learning, S-SR-D)^[27], SSP-DL, 判别半监督字典学习(discriminative semi-supervised dictionary learning, DSSDL)^[17], 图正则半监督字典学习(semi-supervised dictionary learning with graph regularized, SSDL-GA)^[33]相比较, 其中基准实验设置与对比方法一样.

在MNIST数据集, 从每一类样本中任意选择200个样本, 然后随机选取20张图像作为标记样本, 80张作为未标记样本, 其余样本用于测试. USPS的数据集, 本文从每类随机选择110张图像, 随机选择20张图像作为标记样本, 40张图像作为未标记样本, 50张图像作为测试样本.

表1列出了10种方法的实验结果. 观察表中的实验结果, 可以发现MS-SSEDL方法相对其他方法具有更优越的识别精度. 与表中其他的判别字典学习以及半监督字典学习对比, MS-SSEDL整体上能取得更好的效果, 且只有在MNIST数据集的精度低于SSDL-GA方法.

3.2 轴承数据实验

本实验数据集来自凯斯西储大学轴承数据. 数据集共包含4种类型: 正常、内圈故障、外圈故障、滚动

体故障. 故障尺寸包含0.007英寸、0.014英寸、0.021英寸、0.028英寸4种故障尺寸. 在本实验中, 因为考虑到正常数据的采样频率都是12 kHz, 以及0.021英寸故障尺寸的外圈故障数据更为完整, 本文选取了12 kHz采样频率下的0.021英寸的数据, 并在0马力和2马力的数据予以验证. 在实验中, 从每一类选取5到50个不等的样本作为有标签训练样本, 无标签训练样本设置为40个样本, 测试集样本设置为40个样本. 本实验与DKSVD, LC-KSVD, FDDL, 支持向量机引导字典学习(support vector guided dictionary learning, SVG-DL)^[34]、核映射K奇异值压缩(kernel K-singular value decomposition, KKSVD)^[35]、SSDL-GA方法相比较.

表1 数字图像实验结果

Table 1 Experimental results of digital images

方法	数据集	
	USPS	MNIST
DKSVD	67.5±1.8	71.4±1.7
FDDL	85.2±1.2	82.5±1.3
LC-KSVD	76.9±1.3	73.0±1.3
OSSDL	80.8±2.8	73.2±1.8
S2D2	86.6±1.6	77.6±0.8
SSR-D	87.2±0.5	83.8±1.2
SSP-DL	87.8±1.1	85.8±1.2
DSSDL	90.2±0.9	88.3±1.5
SSDL-GA	93.6±1.0	90±0.8
MS-SSEDL	94.5±0.7	88.6±0.6

表2和表3描述了不同方法在负载分别为0 Hp和2 Hp滚动轴承数据集的准确度. 从表2和表3可知, 与其他6种方法相比, MS-SSEDL能取得更好的效果, 且MS-SSEDL最好效果能达到98.12%的精度. FDDL方法因为考虑了模型的判别性能, 因而相对能取得较好的效果. 从整体上分析, MS-SSEDL能取得更高的精度, 特别是当有标签数据较少时, MS-SSEDL具有更大优势. 图2为几种不同方法的准确率随有标签数据数量的变化, 从图2能够更直观感受到有标签数据数量对模型性能的影响, 当有标签数据较少时MS-SSEDL能取得更好的效果.

图3为不同类别的重构误差结果. 若信号能够较好的由对应类别字典表示, 则信号的重构误差就越小. 从图3的重构误差图能够知道, 图3(a)为正常信号的重构误差, 正常信号的能够较好的由正常类型的字典表示, 所对应的重构误差最小, 因此能够判别出该信号是属于正常信号类别. 这表明MS-SSEDL能够较好的表示对应类信号, 对其他类信号表示能力较差, 因此MS-SSEDL具有较好的表示性能.

表 2 0 Hp实验结果


Table 2 Experimental results of 0 Hp

方法	有标签数据数量				
	5	10	20	40	50
DKSVD	36.87	39.37	45.62	48.12	53.7
LC-KSVD	37.5	41.9	54.4	58.1	59.3
FDDL	61.87	75.62	80.12	80.12	81.25
SVGDL	38.4	39.4	42.37	44.3	52.3
KKSVD	63.75	75.62	82.5	90.62	93.75
SSDL-GA	41.87	54.68	60.41	69.27	78.23
MS-SSEDL	73.12	91.25	93.12	96.25	98.12

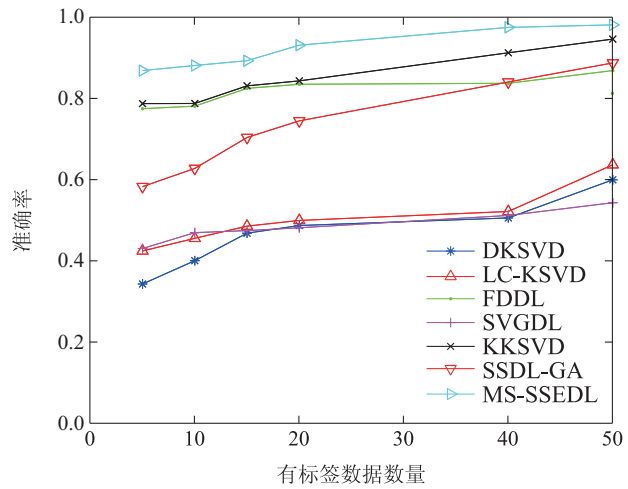
表 3 2 Hp实验结果

Table 3 Experimental results of 2 Hp

方法	有标签数据数量				
	5	10	20	40	50
DKSVD	34.37	40.1	48.75	50.62	60
LC-KSVD	42.5	45.6	50	52.2	63.7
FDDL	77.5	78.12	83.5	83.75	86.87
SVGDL	43.1	47	48.2	51.23	54.36
KKSVD	78.75	78.78	84.34	91.25	94.62
SSDL-GA	58.33	62.8	74.5	84.06	88.75
MS-SSEDL	86.87	88.125	93.12	97.5	98.12



(a) 0 Hp实验结果



(b) 2 Hp实验结果

图 2 不同方法分类性能

Fig. 2 Classification performance of different methods

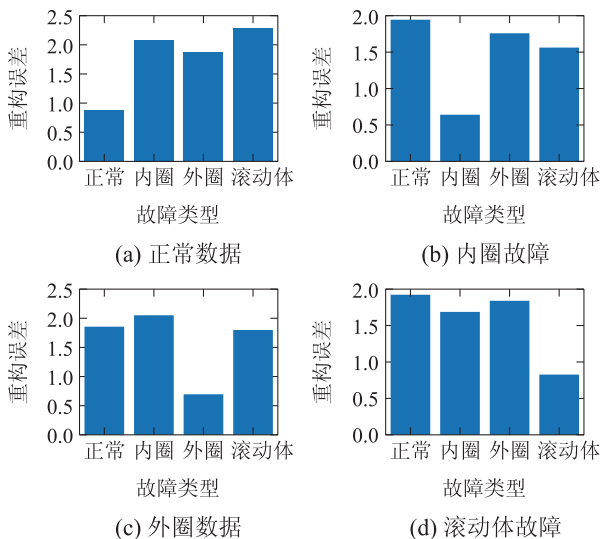


图 3 重构误差

Fig. 3 Reconstruction error

图4分别是负载为2 Hp的40个有标签训练数据MS-SSEDL和FDDL的测试数据混淆矩阵. 观察混淆矩阵, MS-SSEDL方法的错误类别发生在滚动体故障,

其他类别准确率达到100%, 滚动体故障准确率为90%, 每一类的识别效果相对较好. FDDL方法的错误类别比较分散, 内圈故障准确率为97.5%, 外圈故障准确率为80%, 滚动体故障准确率仅为57.5%, 其效果相对较差. 综合比较, MS-SSEDL可以更好的识别不同类别的故障, 能够较好的区分不同类型的故障, 具有更好的判别性能. 图5比较了使用流形学习与不使用流形学习时两种模型的诊断效果. MS-SSEDL与SSEDL的区别在于MS-SSEDL引入了流形学习. 从图中可以知道, 无论负载是0 Hp还是2 Hp, MS-SSEDL在识别精度方面比没用流形学习的SSEDL方法效果更好, 这表明所提方法考虑了数据的流形结构, 学习了数据的内部几何结构特征, 因而更具有判别性能.

3.3 齿轮数据实验

本文选取的齿轮数据来自康涅狄格大学的齿轮实验. 康涅狄格大学的齿轮数据每一类包含104个样本, 一共有9类, 每一个数据样本长3600. 输入轴上的小齿轮有9种不同的齿轮状况, 包括健康状况、缺齿、根部裂纹、剥落和具有不同严重程度的尖端崩刃.

为了进一步验证所提方法的诊断效果, 将方法应用于齿轮数据集, 表4描述了康涅狄格大学齿轮数据集的实验结果. 观察表4, 可以知道MS-SSEDL从整体上有更好的诊断精度, 特别是在有标签数据较少时, 更能体现所提方法的优越性. MS-SSEDL最好精度可以达到100%. 图6是几种不同方法的准确率随有标签数据的变化, 观察图6能够更直观的感受有标签数据的数量对模型性能的影响, 相比较于其他6种方法, 当有标签数据较少时MS-SSEDL能取得更好的效果.

本文在30个有标签齿轮数据的条件下将测试样本分类结果绘制成图7测试数据混淆矩阵. 观察图7, MS-SSEDL的综合准确率为100%, 每一类分类准确率同样都是100%; 而FDDL的综合准确率为98.3%, 并且第4类有一个样本被错误识别成第6类, 第4类准确率为95%, 第6类有两个样本被错误识别, 第6类准确率为90%. 因而表明MS-SSEDL对不同类别具有较强的判别性.

预测类别	1	40 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	40 25.0%	0 0.0%	2 1.3%	95.2% 4.8%
	3	0 0.0%	0 0.0%	40 25.0%	2 1.3%	95.2% 4.8%
	4	0 0.0%	0 0.0%	0 0.0%	36 22.5%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	90.0% 10.0%	97.5% 2.5%
	1	2	3	4	真实类别	

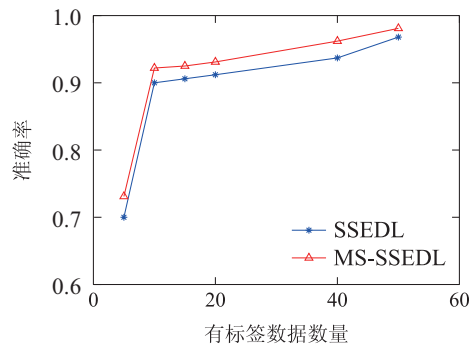
(a) MS-SSEDL

预测类别	1	40 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	39 24.4%	2 1.3%	8 5.0%	79.6% 20.4%
	3	0 0.0%	0 0.0%	32 20.0%	9 5.6%	78.0% 22.0%
	4	0 0.0%	1 0.6%	6 3.8%	23 14.4%	76.7% 23.3%
		100% 0.0%	97.5% 2.5%	80.0% 20.0%	57.5% 42.5%	83.8% 16.2%
	1	2	3	4	真实类别	

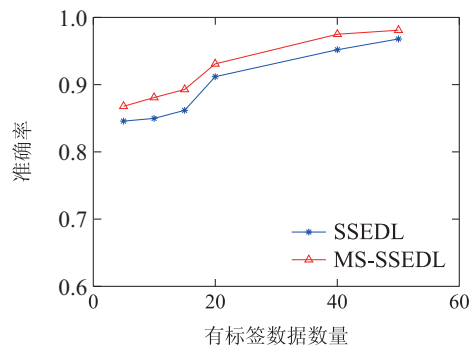
(b) FDDL

图 4 混淆矩阵

Fig. 4 Confusion matrix



(a) 负载为0 Hp



(b) 负载为2 Hp

图 5 有无流形学习性能比较

Fig. 5 Comparison of learning performance with and without manifold learning

表 4 齿轮数据实验结果

Table 4 Experimental results of gear data

方法	有标签数据数量				
	5	10	20	30	40
DKSVD	77.22	86.11	91.66	95.5	91.1
LC-KSVD	78.33	87.23	90	95	93.3
FDDL	84	94.5	97.5	98.4	99.4
SVGDL	76.1	85	89.4	95.6	92.8
KKSVD	75	89.44	92.78	95	95.55
SSDL-GA	79.45	88.34	92.22	96.11	95.64
MS-SSEDL	86.68	96.56	98.75	100	100




图 6 不同方法分类性能

Fig. 6 Classification performance of different methods

预测类别	1	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	100% 0.0%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	100% 0.0%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	100% 0.0%
			100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	4	5	6	7	8	9	
		真实类别									

(a) MS-SSEDL

预测类别	1	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	20 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	19 10.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.6%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%
	6	0 0.0%	0 0.0%	0 0.0%	1 0.6%	0 0.0%	19 10.6%	0 0.0%	0 0.0%	0 0.0%	95.0% 5.0%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	19 10.6%	0 0.0%	0 0.0%	100% 0.0%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 11.1%	0 0.0%	100% 0.0%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.6%	1 0.6%	0 0.0%	20 11.1%	95.2% 4.8%
		100% 0.0%	100% 0.0%	100% 0.0%	95.0% 5.0%	100% 0.0%	95.0% 5.0%	95.0% 5.0%	100% 0.0%	100% 0.0%	98.3% 1.7%
	1	2	3	4	5	6	7	8	9		
		真实类别									

(b) FDDL


图7 混淆矩阵

Fig. 7 Confusion matrix


3.4 鲁棒性测试

在实际应用中, 旋转设备经常在复杂的环境中工作, 采集的振动信号较易受到背景噪声污染. 因此, 有必要检查所提方法MS-SSEDL对噪声的鲁棒性. 本实验采取在原始振动信号中加入高斯白噪声^[6], 构造具有不同信噪比的信号. 在实验中, 本文使用从-2 dB到12 dB的不同信噪比信号来评估MS-SSEDL方法的鲁棒性. 本文分别选取了2 Hp的轴承数据和齿轮数据做实验, 实验结果如图8所示. 与其他6种方法相比, MS-SSEDL方法能取得较高的准确率, 在不同信噪比的条件下, 两组实验的准确率都保持在90%以上的准确率, 具有明显优势. 在不同信噪比的条件下, MS-SSEDL方法波动较为平缓, 整体趋势也较为稳定. 因

此, MS-SSEDL方法在没有任何去噪预处理的情况下, 对噪声具有较好的鲁棒性, 这表明MS-SSEDL在噪声环境下具有优越的鲁棒性.



(a) 2 Hp实验结果




(b) 齿轮实验结果

图8 不同信噪比信号的诊断性能


Fig. 8 Diagnostic performance of signals with different signal-to-noise ratios

3.5 参数影响


本文所提方法主要影响参数是扩展字典原子数 n 与计算置信度矩阵参数 o . 其中, 扩展字典原子数 n 决定每一次迭代能学习的扩展字典原子数量; 参数 o 与计算置信度矩阵有关, 参数 o 的大小将决定样本置信度的整体大小. 图9描述了MS-SSEDL的分类性能随参数 n 的变化, 当分类性能未达到最优值时, 随着扩展字典原子数增加, 分类性能逐渐提升, 从无标签数据学习的扩展字典可以有效完善整体字典, 因此可以取得较好效果; 当分类性能达到最优值, 扩展字典原子数继续增加, 分类性能整体趋势逐渐降低, 新学习的扩展字典原子则会混淆整体字典, 新学习的字典原子可靠度则会降低.




(a) 0 Hp轴承数据



(b) 齿轮数据

图9 分类性能随参数 n 变化Fig. 9 Classification performance varies with parameter n 

(a) 0 Hp轴承数据



(b) 齿轮数据

图10 分类性能随参数 o 变化Fig. 10 Classification performance varies with parameter o

从图10可知,随着参数 o 增加,分类性能整体趋势逐渐提升,当达到最优值时,参数 o 继续增加,分类性能整体趋势逐渐降低.本文为每一个无标签样本计算不同类别的置信度,一个无标签样本的不同类别置信度和为1.参数 o 决定计算出的置信度整体大小,参数 o 越小则会使得数值大的置信度越大,数值小的置信度越小,而随着参数 o 增大,数值大的置信度逐渐变小,数值小的置信度逐渐变大.为了保证模型有效学习无标签数据特征以及对标签分配错误具有鲁棒性,需要选取合适的参数 o .本文在实验中运用 K 折交叉验证选取上述两个参数,从而保证模型的效果,实现可靠的诊断效果.

4 结论

本文提出了一种流形结构化半监督扩展字典学习故障诊断方法来识别旋转设备的故障类型.为可靠学习无标签数据特征,在MS-SSEDL模型中提出了一项无标签数据重构误差项,利用无标签数据学习置信度矩阵,从而学习到扩展字典,以此增强字典学习的表示性.此外,本文通过将流形学习引入字典学习,考虑了数据的流形结构,增强了模型的判别性.本文将所提方法应用于数字图像、轴承故障及齿轮故障公共数据集的实验表明了方法的有效性.在很多实际工业环境的数据会存在非线性的特点,因此考虑如何有效解决数据的非线性问题将会是未来的研究工作.

参考文献:

- [1] SU Naiquan, XIONG Jianbin, ZHANG Qinghua, et al. Research methods of the rotating machinery fault diagnosis. *Machine Tool & Hydraulics*, 2018, 46(7): 133 – 139. (苏乃权, 熊建斌, 张清华, 等. 旋转机械故障诊断研究方法综述. *机床与液压*, 2018, 46(7): 133 – 139.)
- [2] SONG L, WANG H, CHEN P. Vibration-based intelligent fault diagnosis for roller bearings in low-speed rotating machinery. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67(8): 1887 – 1899.
- [3] ZHANG D, ENTEZAMI M, STEWART E, et al. Adaptive fault feature extraction from wayside acoustic signals from train bearings. *Journal of Sound and Vibration*, 2018, 425: 221 – 238.
- [4] ZENG Z H, GUI W H, CHEN X F, et al. A cell condition-sensitive frequency segmentation method based on the sub-band instantaneous energy spectrum of aluminum electrolysis cell voltage. *Engineering*, 2021, 7(9): 1282 – 1292.
- [5] XU Y, TIAN W, ZHANG K, et al. Application of an enhanced fast kurtogram based on empirical wavelet transform for bearing fault diagnosis. *Measurement Science and Technology*, 2019, 30(3): 035001.
- [6] JIANG G, HE H, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox. *IEEE Transactions on Industrial Electronics*, 2018, 66(4): 3196 – 3207.
- [7] SUN W, ZHAO R, YAN R, et al. Convolutional discriminative feature learning for induction motor fault diagnosis. *IEEE Transactions on Industrial Informatics*, 2017, 13(3): 1350 – 1359.
- [8] SADOUGHI M, HU C. Physics-based convolutional neural network for fault diagnosis of rolling element bearings. *IEEE Sensors Journal*, 2019, 19(11): 4181 – 4192.
- [9] MARCUS G. Deep learning: A critical appraisal. *ArXiv Preprint*, arXiv: 1801.00631, 2018.

- [10] ZHANG Q, LI B. Discriminative K-SVD for dictionary learning in face recognition. *IEEE computer society conference on computer vision and pattern recognition*. San Francisco: IEEE, 2010: 2691 – 2698.
- [11] JIANG Z, LIN Z, DAVIS L S. Label consistent K-SVD: Learning a discriminative dictionary for recognition. *IEEE transactions on pattern analysis and machine intelligence*, 2013, 35(11): 2651 – 2664.
- [12] YANG M, ZHANG L, FENG X, et al. Fisher discrimination dictionary learning for sparse representation. *International Conference on Computer Vision*. Barcelona: IEEE, 2011: 543 – 550.
- [13] WANG H, REN B, SONG L, et al. A novel weighted sparse representation classification strategy based on dictionary learning for rotating machinery. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(3): 712 – 720.
- [14] ZHOU L, WANG S, ZHAO Z, et al. Low-dimensional multi-scale fisher discriminant dictionary learning for intelligent gear-fault diagnosis. *Measurement Science and Technology*, 2021, 32(8): 084001.
- [15] LIU H, LIU C, HUANG Y. Adaptive feature extraction using sparse coding for machinery fault diagnosis. *Mechanical Systems & Signal Processing*, 2011, 25(2): 558 – 574.
- [16] WANG D, ZHANG X, FAN M, et al. Semi-supervised dictionary learning via structural sparse preserving. *The 30th AAAI Conference on Artificial Intelligence*. Phoenix, AZ: AAAI, 2016: 2137 – 2144.
- [17] CHEN L, YANG M. Semi-supervised dictionary learning with label propagation for image classification. *Computational Visual Media*, 2017, 3(1): 83 – 94.
- [18] SHRIVASTAVA A, PILLAI J K, PATEL V M, et al. Learning discriminative dictionaries with partially labeled data. *IEEE International Conference on Image Processing*. Orlando: IEEE, 2012: 3113 – 3116.
- [19] ROWEIS, S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, 290(5500): 2323 – 2326.
- [20] TENENBAUM J B, SILVA V D, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, 290(5500): 2319 – 2323.
- [21] 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. *IEEE Signal Processing Magazine*, 2014, 31(1): 55 – 66.
- [22] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311 – 4322.
- [23] MAIRAL J, PONCE J, SAPIRO G, et al. Supervised dictionary learning. *Advances in Neural Information Processing Systems*, Kuching, Malaysia: Springer, 2008: 1033 – 1040.
- [24] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655 – 4666.
- [25] JIANG W, ZHANG Z, LI F, et al. Joint label consistent dictionary learning and adaptive label prediction for semisupervised machine fault classification. *IEEE Transactions on Industrial Informatics*, 2015, 12(1): 248 – 256.
- [26] DENG Z Q, CHEN X F, XIE S W, et al. Semi-supervised discriminative projective dictionary pair learning and its application for industrial process monitoring. *IEEE Transactions on Industrial Informatics*, 2022, DOI: 10.1109/TII.2022.3168300.
- [27] WANG H, NIE F, CAI W, et al. Semi-supervised robust dictionary learning via efficient l-norms minimization. *IEEE International Conference on Computer Vision*. Sydney: IEEE, 2013: 1145 – 1152.
- [28] BECH A. A fast iterative shrinkage-thresholding algorithms for linear inverse problems. *SIAM Journal on Imaging Sciences*, 2009, 2(1): 182 – 202.
- [29] YANG M, ZHANG L, YANG J, et al. Metaface learning for sparse representation based face recognition. *IEEE International Conference on Image Processing*. Hong Kong: IEEE, 2010: 1601 – 1604.
- [30] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, 86(11): 2278 – 2324.
- [31] HHLL J J. A database for handwritten text recognition research. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1994, 16(5): 550 – 554.
- [32] ZHANG G, JIANG Z, DAVIS L S. Online semi-supervised discriminative dictionary learning for sparse representation. *Asian Conference on Computer Vision*. Macau: Springer, 2012: 259 – 273.
- [33] TRAN K H, NGOLE-MBOULA F M, STARCK J L, et al. Semi-supervised dictionary learning with graph regularized and active points. *SIAM Journal on Imaging Sciences*, 2020, 13(2): 724 – 745.
- [34] CAI S, ZUO W, ZHANG L, et al. Support vector guided dictionary learning. *European Conference on Computer Vision*. Zurich: Springer, 2014: 624 – 639.
- [35] VAN NGUYEN H, PATEL V M, NASRABADI N M, et al. Kernel dictionary learning. *IEEE International Conference on Acoustics, Speech and Signal Processing*. Kyoto: IEEE, 2012: 2021 – 2024.

作者简介:

周杰 硕士研究生, 主要研究方向为字典学习、工业故障诊断, E-mail: zhoujie20@csu.edu.cn;

陈晓方 教授, 主要研究方向为流程工业智能优化制造、知识自动化, E-mail: xiaofangchen@csu.edu.cn;

谢永芳 教授, 主要研究方向为知识自动化、有色冶金过程控制、工控信息安全, E-mail: yfxie@csu.edu.cn;

邓紫晴 博士研究生, 主要研究方向为知识自动化、复杂工业过程监测, E-mail: ziqingdeng@csu.edu.cn;

谢世文 副教授, 主要研究方向为复杂工业智能优化制造、知识自动化, E-mail: swxie@csu.edu.cn.