

# 基于迁移学习的零样本故障诊断

吴天舒, 尹宏鹏, 赵丹丹, 蔡力

(重庆大学, 重庆 404100)

**摘要:** 针对工业故障诊断中设备故障数据采集困难, 目标故障样本少的问题, 现有的零样本故障诊断方法仍依赖于故障数据集, 本文提出了一种基于迁移学习的零样本故障诊断方法. 通过经典的主成分分析算法, 构建了一个适用于源域和目标域的判别属性提取器, 用于提取源域数据样本潜在的细粒度特征表示, 将其作为知识迁移的桥梁. 利用源域故障数据获得所有已知故障类的共享细粒度基因组, 并将其作为知识迁移到目标域故障表示中. 从共享细粒度基因组学习源域和目标域的判别矩阵, 构建各自的判别性特征, 最终利用判别性属性实现零样本的故障诊断. 基于田纳西-伊斯曼过程(Tennessee Eastman Process, TEP)数据集, 实验对本文方法和其他零样本故障诊断方法进行对比, 实验结果验证了本文方法对零样本故障检测的有效性.

**关键词:** 故障诊断; 零样本; 迁移学习; 细粒度知识; 判别表示

**基金项目:** 重庆英才计划青年拔尖人才项目(No.cstc2021ycjh-bgzxm0028); 重庆英才计划项目(No.cstc2021ycjh-bgzxm0028); 国家自然科学基金面上项目(No.1010200720170220)

**中图分类号:** TP183

**文献标识码:** A

**文章编号:** 0372-2112(2023)09-2572-06

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20211681

## Zero Sample Fault Diagnosis Based on Transfer Learning

WU Tian-shu, YIN Hong-peng, ZHAO Dan-dan, CAI Li

(Chongqing University, Chongqing 404100, China)

**Abstract:** For the problem of difficulty in collecting equipment fault data and the shortage of target fault samples in industrial fault diagnosis, existing zero sample fault diagnosis method still depends on the fault datasets, a zero sample fault diagnosis method based on transfer learning is proposed. Through the classic PCA (Principal Components Analysis) algorithm, a discriminant attribute extractor applied to source domain and target domain is constructed, to extract the potential fine-grained feature representation of source domain data samples as a bridge for knowledge transfer. The shared fine-grained base group of all known fault classes is obtained from the source domain fault data and transferred as knowledge to the target domain fault representation. The discriminant matrices of source domain and target domain are learned from the shared fine-grained basis group, thus the discriminant characteristics of each domain are constructed. Finally, the discriminant attributes are used to realize zero sample fault diagnosis. Based on the tennessee-eastman process (TEP) datasets, the proposed method is compared with other zero sample fault diagnosis methods, and the experimental results illustrates the effectiveness of our method for zero sample fault diagnosis.

**Key words:** fault diagnosis; zero sample; transfer learning; fine-grained knowledge; discriminant feature representation

**Foundation Item(s):** Chongqing Talent Plan Youth Top Talent Project (No.cstc2021ycjh-bgzxm0028); Chongqing Talent Plan Project (No.cstc2021ycjh-bgzxm0028); National Natural Science Foundation of China (No.1010200720170220)

### 1 引言

故障诊断是利用已检测到的系统设备数据来判断系统设备运行状态的技术, 在保证工业设备安全、稳定、可靠运行中起到重要作用<sup>[1]</sup>. 随着数字化、信息化

时代的到来, 数据驱动技术被广泛应用于过程工业中的过程监控和诊断, 基于数据驱动的故障诊断已经成为当前故障诊断的主流方法. 数据驱动的故障诊断方法是直接从系统运行过程中的历史故障数据中学习故障特征, 以此在无精准系统数学模型情况下进行诊断.

然而,由于许多大型工业设备极少被允许运行至故障状态以获取故障诊断的训练样本,且从健康到故障需要经历一个渐变的退化过程,故障数据采集需要付出昂贵的人力物力成本,实际的目标故障样本少或没有可用的目标故障样本,很大程度上限制了传统数据驱动方法在实际故障诊断中的应用<sup>[2-4]</sup>.近年来,为了解决目标故障样本少的问题,大量基于迁移学习的故障诊断方法被提出<sup>[5,6]</sup>.基于迁移学习的故障诊断方法,其主要思想是利用相关的、有大量标记样本的一个或多个领域数据作为辅助知识来提升模型在目标领域的性能,帮助解决目标领域的目标任务<sup>[7,8]</sup>.由于基于迁移学习的故障诊断方法具有强大的表示学习和端到端的训练能力,得到了广泛研究.例如,Lu等人<sup>[3]</sup>提出一种具有域自适应的深度神经网络模型用于故障诊断.Yang等人<sup>[6]</sup>提出一种用于深度迁移故障诊断的多项式核诱导距离度量方法.这些深度迁移故障诊断模型实质上处理的是源域和目标域之间的域转移问题,仅针对小样本情况下的故障诊断而言.此外,还有研究者致力于解决未知类故障诊断<sup>[9]</sup>和未标记故障诊断<sup>[10]</sup>问题.Gupta等人<sup>[9]</sup>提出一种基于语义信息的多元时间序列(Multivariate Time Series, MTS)早期分类方法.通过属性学习模型来获得已知故障类的语义信息,再用可见类的语义信息来预测未知类故障.上述方法虽然与零样本问题相似,但本质上并不是零样本故障诊断问题.针对零样本故障诊断问题,Feng等人<sup>[11]</sup>提出基于故障描述的属性迁移方法.通过人为定义的故障描述,并将这些故障描述迁移到目标域,即可利用源域训练模型而在目标域进行故障诊断.但该方法需要人工手动设置故障属性描述,过度依赖故障数据库,需要对故障数据有较深入的了解.

为解决上述问题,本文提出了一种基于迁移学习的零样本故障诊断方法.该方法旨在提取源域数据样本潜在的细粒度特征表示,将其作为知识迁移的桥梁,并构建一个适用于源域和目标域的判别属性提取器.具体地,本文首先采用经典的主成分分析算法<sup>[12]</sup>提取故障的主属性.其次,利用源域故障数据获得所有已知故障类的共享细粒度基组,并将其作为知识迁移到目标域故障表示中.然后,用共享细粒度基组学习到源域和目标域的判别矩阵构建各自的判别性特征,最后用该判别性属性进行零样本故障诊断.

## 2 基于迁移学习的零样本故障诊断方法

### 2.1 零样本故障诊断问题描述

假设有故障样本  $X \in \mathbf{R}^{n \times m}$ , 其标签为  $Y \in \mathbf{R}^{n \times m}$ . 其中,  $n$  表示样本总数,  $m$  表示样本维度. 零样本故障诊断即待诊断的故障数据(目标域)没有可用的数据样本来

进行模型训练,需要利用其他/相关的、有可用样本的故障数据(源域)作为辅助知识进行模型训练.因此,将源域数据记为  $D_s = \{X_s \in \mathbf{R}^{n_s \times m}, Y_s \in \mathbf{R}^{n_s \times 1}\}$ ,  $n_s$  表示源域样本总数,  $x_{si}$  表示源域的第  $i$  个样本,  $y_{si}$  表示源域第  $i$  个样本的标签,  $y_{si} = 1, 2, \dots, p_s, p_s$  表示源域故障类别数量.

同理,  $D_t = \{X_t \in \mathbf{R}^{n_t \times m}, Y_t \in \mathbf{R}^{n_t \times 1}\}$  表示目标域故障数据,  $n_t$  表示源域样本总数,  $x_{tj}$  表示源域的第  $j$  个样本,  $y_{tj}$  表示源域的第  $j$  个样本的对应标签,  $y_{tj} = 1, 2, \dots, p_t, p_t$  表示目标域故障类别数量. 零样本故障诊断模型可表示为如下式子:

$$\hat{Y}_t = f(X_t, D_s(X_s, Y_s)), \text{ s.t. } \hat{Y}_t = Y_t \quad (1)$$

其中,  $f(\cdot)$  表示从源域到目标域的映射函数.

### 2.2 细粒度知识和判别性特征获取

本文提出的基于迁移学习的零样本故障诊断方法如图1所示,分为训练阶段和测试阶段两部分.蓝色部分为模型训练阶段,该阶段主要目标是利用源域数据来学习故障的共同细粒度表示,并将其迁移到目标域.在共同细粒度基表示下学习具有判别性的故障特征来用于故障分类.红色部分为测试阶段,该阶段主要是根据训练阶段的细粒度基表示提取故障判别性特征进行分类.由于源域标签和目标域标签是不同的,所以还需要对标签进行映射,将源域标签映射成细粒度基表示下判别性特征所对应的故障标签.

对于给定大量源域故障数据  $X_s$ , 经过主成分分析提取主属性特征为  $P(X_s) = X_s^P = [f_{s1}^P, f_{s2}^P, \dots, f_{sn}^P]$ . 根据图1思想,首先利用  $X_s^P$  学习共享的细粒度属性和判别性特征.因此,可以将  $X_s^P$  分解成一个共享细粒度基和一个判别矩阵,表示如下:

$$\min_{G, M_s^G} \|X_s^P - GM_s^G\|_F^2 \quad (2)$$

其中,  $G \in \mathbf{R}^{n_s \times k}$  表示共享细粒度基矩阵,  $k$  为细粒度基的原子数,含义是希望用  $k$  个能表示更多故障种类的属性(细粒度属性)来表示  $X_s^P$ .  $M_s^G \in \mathbf{R}^{k \times m}$  表示细粒度基矩阵  $G$  下的判别矩阵.为了使判别矩阵判别性更强,本文使用  $\text{tr}((M_s^G)^T Y^S M_s^G)$  作为约束.但是源域和目标域标签不一致,虽然经过映射但并不是真实标签,所以约束项改为  $\text{tr}((M_s^G)^T M_s^G)$ . 所以式(2)可以写成下式:

$$\min_{G, M_s^G} \|X_s^P - GM_s^G\|_F^2 + \|M_s^G\|_2 \quad (3)$$

当得到判别矩阵后,通过式子(4)来获得故障的判别特征  $X_s^G$ :

$$X_s^G = X_s^P M_s^G \quad (4)$$

上述过程为源域共享细粒度基矩阵和判别特征获取过程.同理,将共享细粒度基矩阵迁移到目标域可以

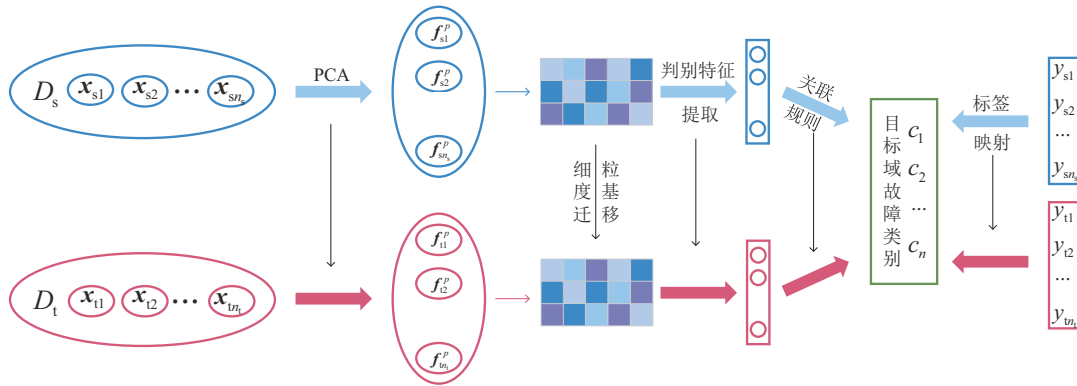


图1 基于迁移学习的零样本故障诊断方法图

获得目标域判别性矩阵,过程如下:

$$\min_{M_t^G} \|X_t^p - GM_t^G\|_F^2 + \|M_t^G\|_2 \quad (5)$$

则目标域判别特征  $X_t^G = X_t^p M_t^G$ .

优化求解:由于目标函数与字典学习目标函数类似.因此,可以采用字典学习求解过程来求解本文提出的方法一样.为了获得较好的共享细粒度基矩阵,本文使用和KSVD算法<sup>[13]</sup>相同的优化过程进行模型求解.固定  $M_s^G$  和  $G$  其中一个优化变量,优化另一个变量,这样交替优化更新.

首先初始化  $G$ ,然后利用正交匹配追踪算法获得  $M_s^G$ .下面采用逐列交替更新的方法更新每一列共享细粒度基矩阵  $G$  和判别矩阵  $M_s^G$ .  $g_k$  表示共享细粒度基矩阵的第  $k$  列向量,  $m_k^T$  为判别映射矩阵的第  $k$  行向量.式(2)可以写成如下形式:

$$\begin{aligned} \|X_s^p - GM_s^G\|_F^2 &= \left\| X_s^p - \sum_{i=1}^k g_i m_i^T \right\|_F^2 \\ &= \left\| \left( X_s^p - \sum_{i \neq k} g_i m_i^T \right) - g_k m_k^T \right\|_F^2 \\ &= \|E_k - g_k m_k^T\|_F^2 \end{aligned} \quad (6)$$

其中,  $E_k = X_s^p - \sum_{i \neq k} g_i m_i^T$ . 共享细粒度基矩阵  $G$  优化问题可描述为:

$$\min_{g_k, m_k^T} \|E_k - g_k m_k^T\|_F^2 \quad (7)$$

式(7)最小化的最优  $g_k$  和  $m_k^T$  是  $E_k$  秩为1的近似,可以利用奇异值分解可求解得到.但是直接将  $E_k$  进行奇异值分解可求解得到的  $m_k^T$  不稀疏.因此,取出  $E_k$  中对应的  $m_k^T$  不为0的位置提取出来,得到新的  $E_k'$ .对  $E_k'$  进行奇异值分解.即,  $E_k' = U \sum V^T$ .取左奇异矩阵  $U$  的第1个列向量作为  $g_k$ ;取右奇异矩阵的第1个行向量与第1个奇异值的乘积作为  $m_k^T$ .根据源域数据获得共享细粒度基矩阵  $G$  后,使用正交匹配追踪算法获得  $M_t^G$ .

完整的优化求解过程如算法1所示.

#### 算法1 模型优化求解

输入:源域数据  $X_s^p$

输出:  $X_s^G, X_t^G$

1. 初始化共享细粒度基矩阵  $G$

2. 对于式(2)使用正交匹配追踪算法获得源域判别矩阵  $M_s^G$

3. 交替逐列更新  $g_k$  和  $m_k$

根据公式  $E_k = X_s^p - \sum_{i \neq k} g_i m_i^T$  计算误差矩阵

取出  $E_k$  中对应的  $m_k^T$  不为0的位置提取出来,得到新的  $E_k'$   
应用SVD分解  $E_k' = U \sum V^T$ ,更新  $g_k = u_1$  和表示  $m_k^T = \sum [1, 1] \cdot v_1$

当  $\|X_s^p - GM_s^G\|_F^2$  的改变足够小时停止迭代;否则,继续迭代

4. 根据式(4)获得  $X_s^G$

5. 对于式(5)使用正交匹配追踪算法获得源域判别矩阵  $M_t^G$

6. 根据公式  $X_t^G = X_t^p M_t^G$  获得目标域判别特征  $X_t^G$

## 3 实验结果与分析

### 3.1 实验数据

为了更好地验证本文提出的基于迁移学习的零样本故障诊断方法,我们在田纳西-伊斯曼过程(Tennessee Eastman process, TE)数据集上进行了大量的实验.

TE过程数据是基于一个真实工业过程进行仿真创建的.它包含21类故障,其中每种故障都是由41个测量控制变量和11个过程控制变量组成. TE数据分成训练集和测试集两部分.训练集中的每类故障含有480个样本,共21×480个训练样本.测试集中每类故障含有960个样本,共21×960个测试样本.

### 3.2 实验设置

本文提出的方法(图1)第一步是用监督主成分分析方法提取故障相关特征,获得源域故障主相关特征  $X_s^p$  和目标域故障主相关特征  $X_t^p$ .对于故障的每个属性,从原始的52个变量中提取20个主相关特征.第二

步是利用源域数据  $X_s^p$  学习共享细粒度基, 粒度大小设置为 35 (共享细粒度基的取值在下文中讨论), 并学习源域数据判别矩阵. 第三步是利用共享细粒度基获得目标域判别矩阵, 然后获取源域和目标域的判别性特征  $X_s^G$  和  $X_t^G$ . 对于源域和目标域标签信息不同, 本文采用线性映射函数将源域标签  $y_s$  和目标域标签  $y_t$  映射为具有相同信息的标签  $z_{sm}, z_{tm} = \{c_1, c_2, \dots, c_n\}$ . 零样本故障诊断定义了待诊断的故障类别无可用训练样本, 本文实验设置与文献[9]相同, 仅使用到了 TE 过程数据集的训练集部分. 由于 TE 数据的 21 个故障类中后 6 种故障在数据集中描述较少, 本文利用所有故障类的前 15 类的 80% 的故障类做训练, 20% 的故障类作测试. 实验一共分为 5 组, 每组有 12 个故障类用于训练, 3 个故障类用于测试. 具体类别见表 1.

表 1 实验分组设置

分组	训练故障类	测试故障类
A	2-3-4-5-7-8-9-10-11-12-13-15	1-6-14
B	1-2-3-5-6-8-9-11-12-13-14-15	4-7-10
C	1-2-3-4-5-6-7-9-10-13-14-15	8-11-12
D	1-4-6-7-8-9-10-11-12-13-14-15	2-3-5
E	1-2-3-4-5-6-7-8-10-11-12-14	9-13-15

此外, 本文采用了三种不同的机器学习算法进行故障分类, 分别是支持向量机 (Support Vector Machines, SVM)<sup>[14]</sup>、随机森林 (Random Forest, RF)<sup>[15]</sup> 和朴素贝叶斯 (Naive Bayes, NB)<sup>[16]</sup>. LSVM 的参数设置为 ('-s 0 -t 0 -c 1'), RF 的决策树个数设为 50. 我们测试了五组实验的准确性. 故障分类准确度计算公式如下:

$$\text{Accuracy} = \frac{\hat{Z}_t}{Z_t} \quad (8)$$

其中,  $\hat{Z}_t$  为正确分类的样本数,  $Z_t$  为测试阶段目标故障的样本总数.

### 3.3 实验结果

五组实验在三种机器算法下的诊断结果如表 2 所示, LSVM 分类器结果在 60.28%~91.32% 之间, RF 分类

器的结果在 57.29%~87.22% 之间, NB 分类器的结果在 44.24%~88.96% 之间. 可以看出 LSVM 分类器分类精度最高. 虽然三种分类器最高的故障诊断准确率在 57.29%~91.31% 之间变化, 但平均准确率在 53.94%~89.17% 之间, 仍具有很大的提升空间.

表 2 五组实验在三种机器学习算法下的结果 单位: %

分组	LSVM	RF	NB	Heighest	Mean
A	91.32	87.22	88.96	91.31	89.17
B	83.61	66.60	87.08	87.08	79.10
C	60.69	66.04	50.14	66.04	58.96
D	60.63	65.00	78.54	78.54	68.06
E	60.28	57.29	44.24	57.29	53.94

文本还与 DAP<sup>[17]</sup>、IAP<sup>[18]</sup>、SJE<sup>[19]</sup>、ESZSL<sup>[20]</sup> 和 Feng<sup>[11]</sup> 等人的方法做了比较, 结果如表 3 所示, 本文提出的方法在五个故障分组上面均取得最好的诊断结果, 且五组实验的平均精度达到 69.85%. 从表 3 可知本文提出的共享细粒度基迁移可以有效解决零样本故障诊断问题.

表 3 本文剔除的方法与其他方法比较 单位: %

分组	DAP <sup>[17]</sup>	IAP <sup>[18]</sup>	SJE <sup>[19]</sup>	ESZSL <sup>[20]</sup>	Feng <sup>[11]</sup>	本文
A	54.16	55.48	74.58	57.22	75.78	89.17
B	62.63	60.69	33.12	33.33	55.54	79.10
C	40.13	45.00	33.95	39.51	53.46	58.96
D	55.48	36.25	63.88	39.65	62.50	68.06
E	36.94	48.88	33.81	33.33	51.03	53.94
Mean	49.86	49.26	47.86	40.60	59.66	69.85

### 3.4 实验参数分析

本文提出的方法旨在迁移源域共享细粒度基矩阵, 因此, 本文讨论了不同粒度下表示矩阵迁移的诊断结果. 本文设置粒度  $k = [20, 25, 30, 35, 40]$  五种不同粒度下的对比试验, 结果如图 2 所示. 可以看出总体趋势为粒度越大诊断结果越准确, 这也比较符合实际理论解释, 即在一定范围内, 用更多维度的描述来表示故障的特征可以使分类效果更好.




图 2 细粒度矩阵不同维度设置下的结果

## 4 结论

针对大型复杂设备实际应用中,系统运行过程的故障样本数量少且采集困难,收集故障样本通常耗费大量人力物力资源的问题,提出一种基于迁移学习的零样本故障诊断方法,该方法在目标域没有可用样本的情况下,将其他相关领域故障数据的细粒度表示迁移到目标域,从而对目标域的故障进行诊断.与已有的零样本故障诊断方法不同的是,本文构建了基于共享细粒度基表示下的判别特征提取方法.提出的方法中的细粒度基能够随意选择维度,并且故障细粒度基描述矩阵可以根据算法自动获取,不需要人工设置故障细粒度描述.通过在 TEP 数据集上的大量实验,通过对不同实验结果的分析,验证了文本提出的方法的有效性.

### 参考文献

- [1] LIU R N, YANG B Y, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: A review[J]. *Mechanical Systems and Signal Processing*, 2018, 108: 33-47.
- [2] WANG F, TAN S A, YANG Y W, et al. Hidden Markov model-based fault detection approach for a multimode process[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(16): 4613-4621.
- [3] 张彩霞, 王子涵, 文成林, 等. 样本空间基于多级高维特征表示的微小故障诊断[J]. *电子学报*, 2020, 48(8): 1647-1654.  
ZHANG C X, WANG Z H, WEN C L, et al. Sample space based on multi-level high dimensional feature representation micro-fault diagnosis[J]. *Acta Electronica Sinica*, 2020, 48(8): 1647-1654. (in Chinese)
- [4] 鲍中新, 文成林, 马雪. 一种基于数据变化率的预处理及主元分析故障诊断方法[J]. *电子学报*, 2021, 49(11): 2234-2240.  
BAO Z X, WEN C L, MA X. Data preprocessing and PCA fault diagnosis method based on rate of change transformation[J]. *Acta Electronica Sinica*, 2021, 49(11): 2234-2240. (in Chinese)
- [5] LU W N, LIANG B, CHENG Y, et al. Deep model based domain adaptation for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3): 2296-2305.
- [6] YANG B, LEI Y G, JIA F, et al. A polynomial kernel induced distance metric to improve deep transfer learning for fault diagnosis of machines[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(11): 9747-9757.
- [7] 于重重, 田蕊, 谭励, 等. 非平衡样本分类的集成迁移学习算法[J]. *电子学报*, 2012, 40(7): 1358-1363.  
YU C C, TIAN R, TAN L, et al. Integrated transfer learning algorithmic for unbalanced samples classification[J]. *Acta Electronica Sinica*, 2012, 40(7): 1358-1363. (in Chinese)
- [8] 季鼎承, 蒋亦樟, 王士同. 基于域与样例平衡的多源迁移学习方法[J]. *电子学报*, 2019, 47(3): 692-699.  
JI D C, JIANG Y Z, WANG S T. Multi-source transfer learning method by balancing both the domains and instances[J]. *Acta Electronica Sinica*, 2019, 47(3): 692-699. (in Chinese)
- [9] GUPTA A, GUPTA H P, BISWAS B, et al. An unseen fault classification approach for smart appliances using ongoing multivariate time series[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(6): 3731-3738.
- [10] GUO L, LEI Y G, XING S B, et al. Deep convolutional transfer learning network: A new method for intelligent fault diagnosis of machines with unlabeled data[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(9): 7316-7325.
- [11] FENG L J, ZHAO C H. Fault description based attribute transfer for zero-sample industrial fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 1852-1862.
- [12] BARSHAN E, GHODSI A, AZIMIFAR Z, et al. Supervised principal component analysis: Visualization, classification and regression on subspaces and submanifolds[J]. *Pattern Recognition*, 2011, 44(7): 1357-1371.
- [13] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [14] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. *ACM Transactions on Intelligent Systems and Technology*, 2(3): 27.
- [15] CUTLER A, CUTLER D R, STEVENS J R. Random forests[M]//*Ensemble Machine Learning*. New York: Springer New York, 2012: 157-175.
- [16] Murphy K P. Naive Bayes classifiers[J]. *University of British Columbia*, 2006, 18(60): 1-8.
- [17] LAMPERT C H, NICKISCH H, HARMELING S. Learning to detect unseen object classes by between-class attribute transfer[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 951-958.
- [18] LAMPERT C H, NICKISCH H, HARMELING S. Attribute-based classification for zero-shot visual object cate-

gorization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(3): 453-465.

- [19] AKATA Z, REED S, WALTER D, et al. Evaluation of output embeddings for fine-grained image classification [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2015: 2927-2936.
- [20] ROMERA-PAREDES B, TORR P H S. An embarrassingly simple approach to zero-shot learning[C]// Proceedings of the 32nd International Conference on Machine Learning. Lille: PMLR, 2015: 2152-2161.

#### 作者简介



**吴天舒** 男, 1989年6月出生于重庆市. 2020年毕业于重庆大学计算机专业, 获博士学位. 现在 Cloudwork 担任博士后研究员. 主要研究方向为数据挖掘、分布式计算、工业视觉等.

E-mail: tswu@cqu.edu.cn



**尹宏鹏 (通讯作者)** 男, 1981年8月出生于江西省莲花市. 2009年毕业于重庆大学控制科学与控制工程. 现为重庆大学自动化学院教授, 从事模式处理、工业视觉等研究.

E-mail: yinhongpeng@cqu.edu.cn



**赵丹丹** 女, 1997年10月出生于云南省曲靖市. 现为重庆大学自动化学院控制科学与工程博士. 主要研究方向为图像智能处理与分析、故障诊断、迁移学习等.

E-mail: whsmhgy@gmail.com



**蔡力** 男, 1996年出生于四川省. 现为重庆大学自动化学院在读博士生, 主要研究方向为寿命预测、故障诊断等.

E-mail: c201506060101@163.com