



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



一种用于旋转机械故障特征提取的簇紧凑自编码器

张志强, 储昭碧, 陈立平, 杨清宇

引用本文:

张志强, 储昭碧, 陈立平, 杨清宇. 一种用于旋转机械故障特征提取的簇紧凑自编码器[J]. 控制与决策, 2024, 39(7): 2251–2258.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1519>

您可能感兴趣的其他文章

Articles you may be interested in

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

基于批次图像化的卷积自编码故障监测方法

Fault detection of batch image-based convolutional autoencoder

控制与决策. 2021, 36(6): 1361–1367 <https://doi.org/10.13195/j.kzyjc.2019.1342>

基于分类特征约束变分伪样本生成器的类增量学习

Class incremental learning based on variational pseudo-sample generator with classification feature constraints

控制与决策. 2021, 36(10): 2475–2482 <https://doi.org/10.13195/j.kzyjc.2020.0228>

考虑退化轨迹差异性与相似性的轴承RUL预测

Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories

控制与决策. 2021, 36(11): 2832–2840 <https://doi.org/10.13195/j.kzyjc.2020.1028>

基于无标签、不均衡、初值不确定数据的设备健康评估方法

Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition

控制与决策. 2020, 35(11): 2687–2695 <https://doi.org/10.13195/j.kzyjc.2018.1493>

一种用于旋转机械故障特征提取的簇紧凑自编码器

张志强¹, 储昭碧^{1†}, 陈立平¹, 杨清宇²

(1. 合肥工业大学 电气与自动化工程学院, 合肥 230009;

2. 西安交通大学 自动化科学与工程学院, 西安 710049)

摘要: 针对传统自编码器以无监督方式学习特征、缺乏监督信息的指导造成特征判别性弱的问题, 提出一种簇紧凑自编码器 (cluster compact auto-encoder, CCAE). 首先, 利用模糊 C 均值算法对样本进行聚类得到伪标签, 并通过 PBMF 指标确定最佳聚类数; 然后, 利用伪标签构建簇紧凑正则项, 嵌入样本所属类别的判别性信息; 最后, 将簇紧凑正则项与标准自编码器的损失函数相结合作为 CCAE 的损失函数, 所提出的 CCAE 通过伪标签的方式嵌入区分类别的判别性信息, 可增强特征的判别性, 从而显著提升诊断性能; 最后, 在旋转机械齿轮和轴承数据集上验证所提出方法的有效性, 结果表明, CCAE 可广泛用于旋转机械故障诊断的特征提取阶段, 为工程人员实现判别性特征的自动提取提供一种解决方案.

关键词: 旋转机械; 故障诊断; 特征提取; 自编码器; 模糊 C 均值; 伪标签

中图分类号: TP206

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1519

引用格式: 张志强, 储昭碧, 陈立平, 等. 一种用于旋转机械故障特征提取的簇紧凑自编码器[J]. 控制与决策, 2024, 39(7): 2251-2258.

A cluster compact auto-encoder for rotating machinery fault feature extraction

ZHANG Zhi-qiang¹, CHU Zhao-bi^{1†}, CHEN Li-ping¹, YANG Qing-yu²

(1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China; 2. School of Automation Science and Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To deal with the problem that features learned by a traditional auto-encoder (AE) are less discriminative due to unsupervised manner, we propose a cluster compact auto-encoder (CCAIE). First of all, a fuzzy C -means algorithm is used to cluster samples to get pseudo labels, where the optimal number of clusters is determined by the PBMF index. Then, a cluster compact regularization (CCR) is established based on the pseudo labels, which embeds discriminant information indicating categories of samples. Finally, the CCR is combined with the AE to constitute the CCAIE's loss function. Discriminant ability of the proposed method can be enhanced via the pseudo labels that incorporate discriminant information indicating categories, so as to improve the diagnostic performance greatly. The effectiveness of the proposed method is verified on rotating machinery gear and bearing datasets. The proposed CCAIE can be widely applicable to the feature extraction stage of rotating machinery fault diagnosis, which provides a solution for engineers to realize automatic extraction of discriminative features.

Keywords: rotating machinery; fault diagnosis; feature extraction; auto-encoder; fuzzy C -means; pseudo labels

0 引言

旋转机械是现代工业中的重要设备, 长时间运行在高速、重载和强冲击等恶劣环境下, 其关键零部件如齿轮或轴承容易出现故障^[1]. 这些故障轻则造成机器停机影响生产, 重则导致严重的财产损失和人员伤亡. 因此, 旋转机械故障诊断研究意义重大.

由于振动信号易获取且携带丰富的故障信息, 基于振动分析的旋转机械故障诊断广为研究^[2], 该框架包括两个主要步骤^[3]: 特征提取和故障识别. 前者从振动信号中提取有代表性的特征, 后者利用提取的特征训练分类器以识别设备的健康状态. 研究表明, 特征提取是故障诊断的关键一步, 因为提取的特征质量

收稿日期: 2022-08-24; 录用日期: 2023-06-04.

基金项目: 中央高校基本科研业务费专项资金项目 (JZ2023HGQA0108, JZ2023HGTA0200); 国家自然科学基金面上项目 (62073114, 11971032); 安徽省科技重大专项项目 (202103a05020001).

责任编委: 方华京.

[†]通讯作者. E-mail: zbchu@hfut.edu.cn.

很大程度上决定了诊断结果的好坏^[4]. 传统特征提取方法采用先进的信号处理技术人工设计特征, 虽能取得不错的诊断性能, 但诊断结果依赖于丰富的先验知识和诊断经验^[5].

无监督特征学习借助神经网络强大的非线性映射能力, 从无标注数据中自动学习特征, 有效克服了传统特征提取方法的不足^[5-6]. 自编码器(auto-encoder, AE)^[7]是一种重要的无监督特征学习方法, 在旋转机械故障诊断领域备受关注. 标准AE通常表现较差, 原因在于它只能执行简单的数据复制任务, 难以从数据中学到有意义的信息. 为了提升AE的特征学习能力, 各种变体相继提出并应用到旋转机械故障诊断中. 稀疏自编码(sparse auto-encoder, SAE)^[8]通过对AE的隐层神经元施加KL (Kullback-Leibler) 散度项惩罚, 提升了特征的稀疏性. Sun等^[9]堆叠2个SAE构建了深度神经网络, 该方法在7种电机轴承故障诊断中取得了97.47%的识别率; 为了增强特征的多样性, Jia等^[10]提出了规范化稀疏自编码器(normalized sparse auto-encoder, NSAE), 该方法使用Relu函数代替SAE隐层的Sigmoid函数作为激活函数, 同时使用 ℓ_1 范数项代替KL散度项. 在齿轮箱诊断案例中, NSAE的诊断精度达到了99.43%, 比SAE高5.02%. 此外, Yu等^[11]从多误差重构角度提出了联合多重重构自编码器(joint multiple reconstructions auto-encoder, JMRAE), 该方法分别使用Relu和Sigmoid激活函数构建重构误差, 然后以最小化复合重构误差为目标训练网络. 在两个轴承数据集上的结果表明, JMRAE明显好于单重构方法.

尽管以上AE变体取得了相当不错的诊断结果, 但这些方法以无监督方式学习特征, 未能利用样本间的类别信息, 导致学到的特征仍然存在判别性不足的问题. 另一方面, 类别信息通常由样本标签体现, 标签相同的样本属于同一类, 反之则属于不同类^[12]. 如果采用真实标签, 则构建的模型将违背无监督属性, 同时需要花费大量精力标注样本. 因此, 有必要研究一种新的AE变体用于旋转机械故障诊断, 该变体同时满足3个条件: 1) 无监督方式学习特征; 2) 利用样本间的类别信息; 3) 无需人工标注样本.

基于以上分析, 本文提出一种簇紧凑自编码器(cluster compact auto-encoder, CCAE). 该方法首先利用模糊C均值(fuzzy C-means, FCM)算法^[13]对样本进行聚类得到伪标签, 并用PBMF指标^[14]确定最佳聚类数; 然后利用伪标签构建簇紧凑正则项, 并添加到AE的损失函数中; 最后以最小化联合损失函数为目标训练网络参数. 将CCAIE提取的特征输入

Softmax分类器^[5], 实现旋转机械故障的智能识别与诊断. 在齿轮和轴承数据集上对CCAIE进行测试, 并通过大量对比实验验证所提方法的有效性.

1 自编码器基本理论

如图1所示, AE的网络结构由输入层、隐层和输出层组成, 包括编码器和解码器. 给定含有 N 个样本的无标签数据集 $\{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^N\}$, $\mathbf{x}^n \in \mathbf{R}^I$ 是第 n 个样本, 经编码器处理得到 \mathbf{x}^n 的特征向量 $\mathbf{h}^n \in \mathbf{R}^J$, 即

$$\mathbf{h}^n = \sigma(\mathbf{W}_e \mathbf{x}^n + \mathbf{b}_e). \quad (1)$$

其中: I 和 J 分别为AE的输入尺寸和隐层尺寸; $\mathbf{W}_e \in \mathbf{R}^{J \times I}$ 和 $\mathbf{b}_e \in \mathbf{R}^J$ 分别为编码器的权重和偏置; $\sigma(\cdot)$ 为激活函数, 通常选用Sigmoid型函数, 即 $\sigma(t) = 1/[1 + \exp(-t)]$.

紧接着, \mathbf{h}^n 经解码器处理得到 \mathbf{x}^n 的重构 $\hat{\mathbf{x}}^n$, 即

$$\hat{\mathbf{x}}^n = \sigma(\mathbf{W}_d \mathbf{h}^n + \mathbf{b}_d), \quad (2)$$

其中 $\mathbf{W}_d \in \mathbf{R}^{I \times J}$ 和 $\mathbf{b}_d \in \mathbf{R}^I$ 分别为解码器的网络权重和偏置. 标准AE的损失函数如下:

$$\min_{\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d} \psi_{\text{AE}} = \frac{1}{2N} \sum_{n=1}^N \|\hat{\mathbf{x}}^n - \mathbf{x}^n\|_2^2. \quad (3)$$

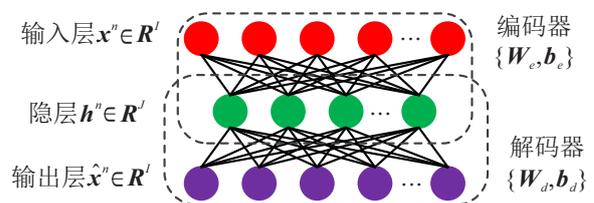


图1 AE的网络结构

2 簇紧凑自编码器 (CCAIE)

由于未利用样本间的类别信息, 标准AE及SAE、NSAE和JMRAE等变体难以从振动信号中学到判别性特征, 致使诊断能力不足. 为此, 本文提出CCAIE, 该方法利用样本间的伪类别信息建立簇紧凑正则项, 将同类样本在重构空间中聚合成紧凑的簇, 从而提升隐层特征的判别性.

假设第1节中的 N 个样本来自 C 个簇, 令第 c ($c = 1, 2, \dots, C$)个簇的样本集为 $\{\mathbf{x}_c^i\}_{i=1}^{N_c}$. 其中: \mathbf{x}_c^i 为第 c 个簇中第 i 个样本; N_c 为第 c 个簇中所有样本的个数且 $\sum_{c=1}^C N_c = N$. 根据式(1)和(2)可以计算样本 \mathbf{x}_c^i 的重构 $\hat{\mathbf{x}}_c^i$, 即

$$\hat{\mathbf{x}}_c^i = \sigma(\mathbf{W}_d \sigma(\mathbf{W}_e \mathbf{x}_c^i + \mathbf{b}_e) + \mathbf{b}_d). \quad (4)$$

令 $\bar{\mathbf{x}}_c$ 为第 c 个簇的样本中心, 且 $\bar{\mathbf{x}}_c = \sum_{i=1}^{N_c} \mathbf{x}_c^i / N_c$. 在CCAIE中, 重构空间中的每个样本 $\hat{\mathbf{x}}_c^i$ 不仅像标准

AE那样逼近原始空间中的对应样本 \mathbf{x}_c^i , 还要逼近对应的簇中心 $\bar{\mathbf{x}}_c$. 因此, CCAE的损失函数如下:

$$\min_{\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d} \psi_{\text{CCAe}} = \psi_{\text{AE}} + \lambda \psi_{\text{CCR}}. \quad (5)$$

其中: $\lambda > 0$ 为正则项参数; ψ_{CCR} 为簇紧凑正则项, 其基本形式为

$$\psi_{\text{CCR}} = \frac{1}{C} \sum_{c=1}^C \frac{1}{2N_c} \sum_{i=1}^{N_c} \|\hat{\mathbf{x}}_c^i - \bar{\mathbf{x}}_c\|_2^2. \quad (6)$$

CCAe的基本思想如图2所示. 图2中相同符号的样本组成一个簇, 双箭头连接的两个样本之间作差, 左右两部分分别对应CCAe的损失项 ψ_{AE} 和 ψ_{CCR} .

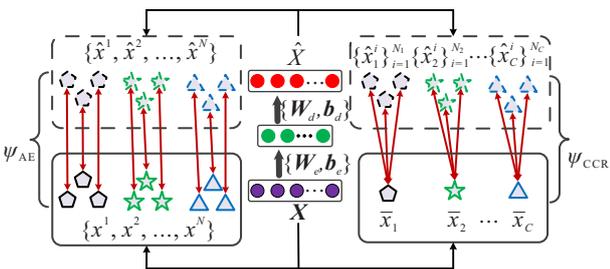


图2 CCAE的基本结构

式(5)是一个无约束非线性优化问题, ψ_{CCAe} 光滑且处处可导, 因此采用梯度法进行优化. 本文使用有限拟牛顿法(L-BFGS), 该算法在每步迭代时自适应选择学习率, 计算效率高. 为了便于梯度计算, 一些矩阵定义如下: $\mathbf{X} = \{\mathbf{x}^n\}_{n=1}^N \in \mathbf{R}^{I \times N}$, $\hat{\mathbf{X}} = \{\hat{\mathbf{x}}^n\}_{n=1}^N \in \mathbf{R}^{I \times N}$, $\mathbf{X}_c = \{\mathbf{x}_c^i\}_{i=1}^{N_c} \in \mathbf{R}^{I \times N_c}$, $\hat{\mathbf{X}}_c = \{\hat{\mathbf{x}}_c^i\}_{i=1}^{N_c} \in \mathbf{R}^{I \times N_c}$, $\bar{\mathbf{X}}_c = \text{repmat}(\bar{\mathbf{x}}_c, 1, N_c) \in \mathbf{R}^{I \times N_c}$, 其中运算符repmat表示将 $\bar{\mathbf{x}}_c$ 按列复制 N_c 次.

ψ_{CCAe} 对 $\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d$ 的梯度计算如下:

$$\begin{cases} \frac{\partial \psi_{\text{CCAe}}}{\partial \mathbf{W}_e} = \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{W}_e} + \lambda \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{W}_e}, \\ \frac{\partial \psi_{\text{CCAe}}}{\partial \mathbf{b}_e} = \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{b}_e} + \lambda \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{b}_e}, \\ \frac{\partial \psi_{\text{CCAe}}}{\partial \mathbf{W}_d} = \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{W}_d} + \lambda \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{W}_d}, \\ \frac{\partial \psi_{\text{CCAe}}}{\partial \mathbf{b}_d} = \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{b}_d} + \lambda \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{b}_d}. \end{cases} \quad (7)$$

其中: ψ_{AE} 对 $\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d$ 的梯度计算如下:

$$\begin{cases} \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{W}_e} = \frac{1}{N} (((\mathbf{W}_d^T \Theta) \odot \sigma'(\mathbf{W}_e \mathbf{X} + \mathbf{B}_e)) \mathbf{X}^T), \\ \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{b}_e} = \frac{1}{N} \text{sum}((\mathbf{W}_d^T \Theta) \odot \sigma'(\mathbf{W}_e \mathbf{X} + \mathbf{B}_e), 2), \\ \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{W}_d} = \frac{1}{N} (\Theta \sigma(\mathbf{W}_e \mathbf{X} + \mathbf{B}_e)^T), \\ \frac{\partial \psi_{\text{AE}}}{\partial \mathbf{b}_d} = \frac{1}{N} \text{sum}(\Theta, 2). \end{cases} \quad (8)$$

这里: $\Theta = (\hat{\mathbf{X}} - \mathbf{X}) \odot \sigma'(\mathbf{W}_d \sigma(\mathbf{W}_e \mathbf{X} + \mathbf{B}_e) + \mathbf{B}_d)$,

$\mathbf{B}_e = \text{repmat}(\mathbf{b}_e, 1, N)$, $\mathbf{B}_d = \text{repmat}(\mathbf{b}_d, 1, N)$; $\sigma'(t) = \sigma(t)(1 - \sigma(t))$ 表示 $\sigma(t)$ 的导函数; 运算符 \odot 表示两矩阵对应元素相乘; 运算符 $\text{sum}(\Theta, 2)$ 表示对矩阵 Θ 的每行所有元素相加.

ψ_{CCR} 对 $\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d$ 的梯度计算如下:

$$\begin{cases} \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{W}_e} = \frac{1}{C} \sum_{c=1}^C \frac{((\mathbf{W}_d^T \mathbf{A}_c) \odot \sigma'(\mathbf{W}_e \mathbf{X}_c + \mathbf{B}_e^c)) \mathbf{X}_c^T}{N_c}, \\ \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{b}_e} = \frac{1}{C} \sum_{c=1}^C \frac{\text{sum}((\mathbf{W}_d^T \mathbf{A}_c) \odot \sigma'(\mathbf{W}_e \mathbf{X}_c + \mathbf{B}_e^c), 2)}{N_c}, \\ \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{W}_d} = \frac{1}{C} \sum_{c=1}^C \frac{\mathbf{A}_c \sigma(\mathbf{W}_e \mathbf{X}_c + \mathbf{B}_e^c)^T}{N_c}, \\ \frac{\partial \psi_{\text{CCR}}}{\partial \mathbf{b}_d} = \frac{1}{C} \sum_{c=1}^C \frac{\text{sum}(\mathbf{A}_c, 2)}{N_c}. \end{cases} \quad (9)$$

其中: $\mathbf{A}_c = (\hat{\mathbf{X}}_c - \bar{\mathbf{X}}_c) \odot \sigma'(\mathbf{W}_d \sigma(\mathbf{W}_e \mathbf{X}_c + \mathbf{B}_e^c) + \mathbf{B}_d^c)$, $\mathbf{B}_e^c = \text{repmat}(\mathbf{b}_e, 1, N_c)$, $\mathbf{B}_d^c = \text{repmat}(\mathbf{b}_d, 1, N_c)$.

在构造簇紧凑正则项 ψ_{CCR} 前, 需要知道每个样本的簇标签, 以此判定哪些样本属于同一个簇. 如果采用真实标签, 则CCAe不属于无监督特征学习方法, 而且真实标签通常需要人工标注, 耗时耗力. 为了保证CCAe能够以无监督方式从信号中自动学习特征, 合理的办法是采用聚类算法获取每个样本的伪标签作为簇标签. 常见的聚类算法有K均值、FCM和谱聚类等. 由于FCM算法简单易实施且计算效率高^[13], 本文采用FCM算法.

使用FCM算法的目的是给样本集 $\{\mathbf{x}^n\}_{n=1}^N$ 中的每个样本 \mathbf{x}^n 赋予一个伪标签, 记为 $l^n \in \{1, 2, \dots, C\}$. 需要注意, 本文中的 \mathbf{x}^n 是一段振动信号(即时序数据), 而FCM算法无法直接处理时序数据. 为了保证FCM的有效运行, 计算 \mathbf{x}^n 的12个常见的时域指标组成时域向量(记为 $\mathbf{t}^n \in \mathbf{R}^{12}$)代表 \mathbf{x}^n , 这些参数^[15] 分别为: 峰值、峰峰值、均值、标准差、方根幅值、均方幅值、偏斜度指标、峭度指标、峰值指标、裕度指标、脉冲指标和波形指标. 这些时域指标常用于旋转机械故障诊断中, 能够从不同方面反映信号的特性^[16]. 此外, 文献[17]在研究数据清洗算法时通过这些指标构建每个信号段的特征向量, 实现了正常和劣质数据的区分, 验证了这些指标的有效性.

当 $\{\mathbf{t}^n\}_{n=1}^N$ 作为输入时, FCM的损失函数为

$$\min_{\mathbf{U}, \mathbf{V}} \psi_{\text{FCM}} = \sum_{c=1}^C \sum_{n=1}^N u_{cn}^\varepsilon \|\mathbf{t}^n - \mathbf{v}_c\|_2^2. \quad (10)$$

其中: $\mathbf{U} = (u_{cn})_{C \times N}$ 为隶属度矩阵, $u_{cn} \in (0, 1)$ 为 \mathbf{t}^n 属于第 c 个簇的概率, 最大概率对应的簇索引为

$t^n(x^n)$ 的伪标签, $\sum_{c=1}^C u_{cn} = 1; V = [v_1, v_2, \dots, v_C]$ 为簇中心矩阵, v_c 为第 c 个簇的中心; ε 为隶属度因子, 最佳取值范围^[14] 为 $[1.5, 2.5]$, 本文中 ε 取 1.5. U 和 V 的迭代公式如下:

$$\begin{cases} v_c = \sum_{n=1}^N u_{cn}^{\varepsilon} t^n / \sum_{n=1}^N u_{cn}^{\varepsilon}, \\ u_{cn} = 1 / \sum_{k=1}^C (\|t^n - v_c\|_2 / \|t^n - v_k\|_2)^{\frac{2}{\varepsilon-1}}. \end{cases} \quad (11)$$

在 FCM 算法中, C 为 N 个样本聚类以后得到的簇的个数. 当 $C = 1$ 时, 所有样本聚成一个簇, 样本的标签相同; 当 $C = N$ 时, 每个样本单独成一个簇, 样本的标签互异. 为了确定最佳的 C 值, 许多聚类指标^[14] 相继提出, 如 Davies-Bouldin、Dunn、Xie-Beni 和 PBMF 等. 根据文献 [14] 中的对比结果, PBMF 指标评价 FCM 算法的聚类结果更准确. 因此, 本文采用 PBMF 确定最优的 C , 该指标定义如下:

$$\text{PBMF}(C) = \left(\frac{1}{C} \times \frac{E_1}{J_C^{\varepsilon}} \times D_C \right)^2. \quad (12)$$

其中: E_1 为 $C = 1$ 时 J_C^{ε} 的值; J_C^{ε} 和 D_C 计算如下:

$$\begin{cases} J_C^{\varepsilon} = \sum_{c=1}^C \sum_{n=1}^N u_{cn}^{\varepsilon} \|t^n - v_c\|_2, \\ D_C = \max_{i,j=1,2,\dots,C} \|v_i - v_j\|_2. \end{cases} \quad (13)$$

这里 C 的值通常在 $2 \sim \sqrt{N}$ 之间^[14].

本文提出的 CCAE 可以自动地从原始振动信号中提取特征, 在此之前需要对 CCAE 的网络参数进行训练, 具体训练步骤如算法 1 所述.

算法 1 CCAE 网络参数的训练步骤.

输入: N 个振动信号样本 $\{x^n\}_{n=1}^N$, 正则化参数 λ , 最大聚类数 C_{\max} .

输出: 最优网络参数 W_e^*, b_e^*, W_d^* 和 b_d^* .

1) 计算每个 x^n 的 12 个时域统计参数组成时域向量 $t^n, n = 1, 2, \dots, N$;

- 2) $C = 2$;
- 3) 初始化隶属度矩阵 U ;
- 4) 将 $\{t^n\}_{n=1}^N$ 作为 FCM 的输入, 式 (10) 为损失函数, 通过 (11) 更新隶属度矩阵 U 和簇中心矩阵 V ;
- 5) 根据式 (12) 和 (13) 计算当前的 PBMF(C);
- 6) 如果 $C \leq C_{\max}$, 则 $C = C + 1$, 并转向 3), 否则继续;
- 7) 找出 $\{\text{PBMF}(C), C = 2, 3, \dots, C_{\max}\}$ 中的最大值, 对应的 C 为最佳聚类数, 相应的隶属度矩阵 U 为最佳聚类结果;
- 8) 根据 U 确定每个样本的簇标签 l^n , 根据簇标签将 $\{x^n\}_{n=1}^N$ 分成 C 个簇 $\{x_c^i\}_{i=1}^{N_c}, c = 1, 2, \dots, C$;
- 9) 利用 $\{x^n\}_{n=1}^N$ 和 $\{x_c^i\}_{i=1}^{N_c}$ 建立 CCAE 的损失函数, 如式 (5) 所示;
- 10) 对 CCAE 中的权重矩阵 W_e 和 W_d 随机初始化, 偏置向量 b_e 和 b_d 均初始化为 0;
- 11) 利用 L-BFGS 算法优化 W_e, b_e, W_d 和 b_d ;
- 12) 优化后的最优参数记为 W_e^*, b_e^*, W_d^* 和 b_d^* .

3 基于 CCAE 的特征提取

CCAe 用于特征提取前, 需要对其网络参数进行训练, 具体如下. 采集设备正常和各种故障状态下共 P 个振动信号样本组成训练集 $\{s_1, s_2, \dots, s_P\}$, 其中 $s_p \in \mathbf{R}^D$ 含有 D 个数据点. 为了克服振动信号固有的移位不变属性, 用长为 $I(I \ll D)$ 的滑动窗对每个样本 s_p 分片, 相邻片段之间的重叠率为 $\eta \in (0, 1)$, 得到的片段记为 $\{s_p^m\}_{m=1}^M$. 其中: $s_p^m \in \mathbf{R}^I; M = \text{ceil}((D - I + 1) / (I - \text{floor}(I\eta)))$, ceil 和 floor 分别为向上取整和向下取整运算. 使用样本集 $\{s_p^m, p = 1, 2, \dots, P; m = 1, 2, \dots, M\}$ 训练 CCAE 的网络参数, 具体训练步骤如算法 1 所示. 训练完毕后得到最优的编码器权重 W_e^* 和偏置 b_e^* .

对于一个新采集的振动信号样本 $s \in \mathbf{R}^D$, 其特征向量的计算流程如图 3 所示.

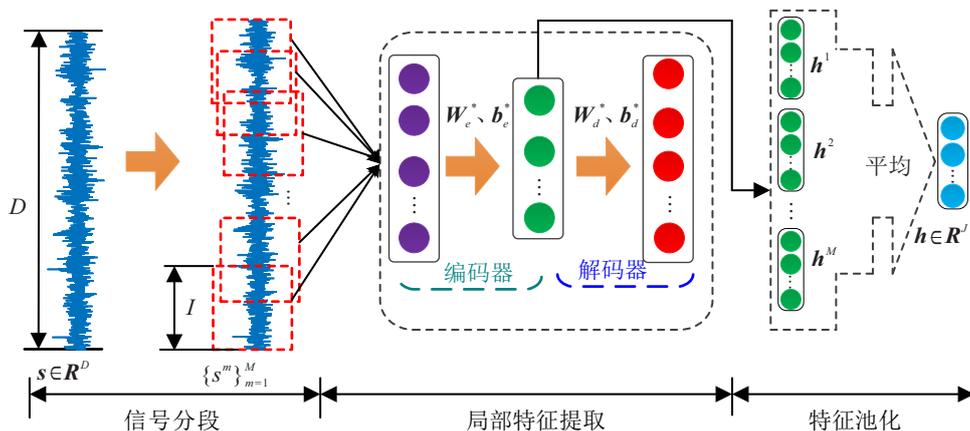


图 3 基于 CCAE 的特征提取流程

图3包括信号分段、局部特征提取和特征池化3个环节。在信号分段环节,将 s 以重叠率 η 分割成 M 个长度为 I 的片段 $\{s^m\}_{m=1}^M$,其中 $s^m \in R^I$ 。在局部特征提取环节,利用CCA的编码器对每个片段 s^m 进行编码得到相应的特征向量 $h^m \in R^J$,即局部特征向量,其中 $h^m = \sigma(W_e^* s^m + b_e^*)$ 。在特征池化环节,对 $\{h^m\}_{m=1}^M$ 做平均池化处理得到 s 的特征向量 $h \in R^J$,即全局特征向量,其中 $h = \sum_{m=1}^M h^m / M$ 。经CCA提取的特征向量 h 可以直接用来训练分类器,从而实现旋转机械故障诊断。

4 实验验证

齿轮和轴承是旋转机械的关键零部件,也是容易发生故障的部件。本文使用一个齿轮数据集和一个轴承数据集验证CCA的故障特征提取效果。

4.1 数据集描述

齿轮数据集从图4中的动力传动系统模拟试验平台^[18]上采集,试验台由驱动电机、两级行星齿轮箱、两级平行齿轮箱以及磁粉制动器传动构成,分别模拟了两种工况下(转速1200 r/min-负载0 N·m和转速1800 r/min-负载7.2 N·m)的5种齿轮健康状态,如表1所示。故障齿轮为行星齿轮箱中的一级太阳轮(齿数为20个),4种故障齿轮如图5所示。PCB608A11型传感器采集振动数据,采样频率为5120 Hz。每种工况下每种健康状态采集300个振动信号样本,每个样本有2400个采样点,整个齿轮数据集有3000个样本。

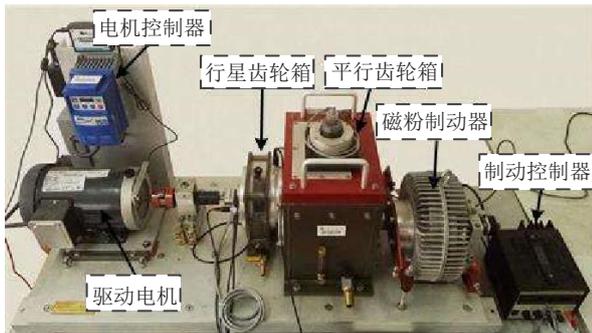


图4 动力传动系统模拟试验平台

表1 齿轮和轴承数据集描述

数据集	健康状态	描述	样本数
齿轮	正常状态	无故障状态	600 (300×2)
	缺齿	齿轮缺齿一个	600 (300×2)
	齿根裂纹	齿根部有裂纹	600 (300×2)
	齿面磨损	齿轮表面磨损	600 (300×2)
	齿剥落	齿上有部分剥落	600 (300×2)
轴承	正常状态	无故障	840
	内圈故障	内圈出现裂纹	840 (120×7)
	外圈故障	外圈出现裂纹	840 (120×7)

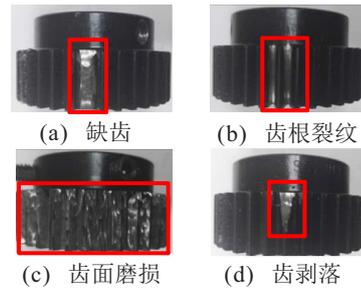


图5 4种故障齿轮图例

轴承数据集由美国机械故障预防技术协会^[19]提供,包含3种轴承健康状态,如表1所示。其中:840个正常状态样本在270磅负载下以97656 Hz的频率采集;840个内圈故障样本在7种负载(0,50磅,100磅,150磅,200磅,250磅,300磅)下以48828 Hz的频率采集,每种负载下120个样本;840个外圈故障样本在7种负载(25磅,50磅,100磅,150磅,200磅,250磅,300磅)下以48828 Hz的频率采集,每种负载下120个样本。每个样本均有1200个采样点,整个轴承数据集共有2520个样本。

4.2 诊断结果与分析

从每类样本中任选10%作为训练样本,余下90%作为测试样本。将训练样本分割成一系列有重叠的小片段,重叠率 η 取0.9。所有片段组成数据矩阵用以训练CCA,其网络结构选为75~100(即输入尺寸 $I = 75$,隐层尺寸 $J = 100$),正则项参数 λ 取100,最大聚类数 C_{max} 取20。训练完CCA后,按照图3的流程计算训练和测试样本的特征向量。然后,使用训练样本的特征向量训练Softmax分类器,选用该分类器的原因是其计算速度快,泛化性好^[5]。将测试样本的特征向量输入训练后的分类器中得到测试结果。为了减小样本随机划分和CCA网络参数随机初始化的影响,独立重复进行20次实验。

CCA采用PBMF指标确定最佳聚类数,为了验证该策略的有效性,图6作出了第1次实验中聚类数在[2,20]范围内PBMF指标的变化曲线。可以看出,在齿轮和轴承数据集上,最大PBMF指标值对应的聚类数分别为5和3,与真实类别数完全吻合。需要说明:齿轮数据集上聚类数为4或5时,PBMF值几乎相同,但本文仍选5为最佳聚类数,原因是4与5两者相

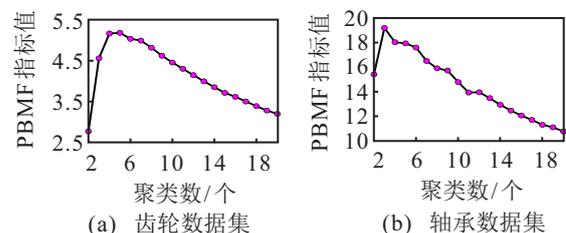


图6 不同聚类数下的PBMF指标值

差太小时仍以PBMF值最大为参考,但当两个差距较大的聚类数对应的PBMF值几乎相同时,从防止过拟合角度应该选取最小的聚类数。

本文方法的诊断结果如表2最后一列所示。为了验证该方法的优越性,使用9种典型的特征提取方法作为对比,包括:3种信号处理方法,分别为奇异谱分析(singular spectrum analysis, SSA)^[20]、小波包分解(wavelet packet decomposition, WPD)^[21]和SSA+WPD;两种深度学习方法,分别为深度神经网络(deep neural networks, DNNs)^[22]和一维卷积神经网络(1-D convolutional neural network, 1D-CNNs)^[23];4种无监督特征学习方法,分别为标准AE及其3种无监督变体,即SAE^[8]、NSAE^[10]和JMRAE^[11]。这些方法的说明如下:1)SSA中滑动窗长度设置为40;WPD采用‘db4’作为小波基函数做5层分解得到32个频带分量,计算每个分量的能量值组成特征向量;SSA+WPD将SSA和WPD提取的特征首尾相连,每个特征做z-score标准化以消除量纲影响。2)DNNs由多个AE堆叠而成,将信号的频谱作为输入,在齿轮和轴承数据集上的网络结构分别设置为1200-600-300-100-5和600-300-150-3;1D-CNNs采用两层卷积结构,卷积核数量分别为16和32,卷积核大小均为100,采用最大化池化方式和Relu激活函数。3)4种无监督特征学习方法的网络结构均设置为75-100。

表2 不同特征提取方法取得的诊断结果对比 /%

方法	齿轮数据集		轴承数据集	
	平均测试精度	标准差	平均测试精度	标准差
SSA	87.79	0.992	90.98	1.696
WPD	90.51	1.086	92.55	1.213
SSA+WPD	92.99	0.741	93.60	1.261
DNNs	99.27	0.746	99.85	0.092
1D-CNNs	99.09	0.742	98.34	0.586
AE	66.61	2.745	59.75	6.447
SAE	96.84	1.296	96.36	1.048
NSAE	98.21	0.778	97.91	0.889
JMRAE	95.61	0.765	98.68	0.554
本文方法	99.44	0.646	99.84	0.163

从表2的结果可以看出:1)3种信号处理法的诊断效果明显不如特征自学习法(AE除外),原因在于前者提取的特征有限,难以充分表征设备健康状态,而后者从信号中自动学习的特征能够全面捕捉信号中的故障信息。2)两种深度学习法与本文方法的诊断结果几乎相当,而前者的性能取决于设计良好的网络结构和有监督的反向微调。相比之下,本文方法的优势在于网络结构简单,特征学习过程无监督,而且可以直接将原始振动信号作为输入,无需使用信号的频谱。3)标准AE的性能较差,主要原因是它只能简单地将数据进行复制,难以从数据中挖掘到有价值的信

息。SAE、NSAE和JMRAE的性能相比于AE有了显著提升,但仍不如本文提出的CCAIE,原因在于CCAIE通过聚类算法生成伪标签,将判别信息引入网络训练中,增强了特征的判别性。

为了直观地说明CCAIE的特征判别性,使用t-分布邻域嵌入算法^[24]将5种无监督特征学习方法提取的100个特征可视化,在二维空间中作出测试样本的散点图,如图7所示(在齿轮数据集上进行)。可以看出,AE的特征判别性较差,SAE和JMRAE的样本簇之间也有少许重叠,NSAE的样本簇之间几乎没有重叠,但其齿根裂纹与齿剥落样本之间很接近,容易造成误分类。相比之下,CCAIE的每类样本能形成紧凑无重叠的簇,表明CCAIE的特征判别性更强。

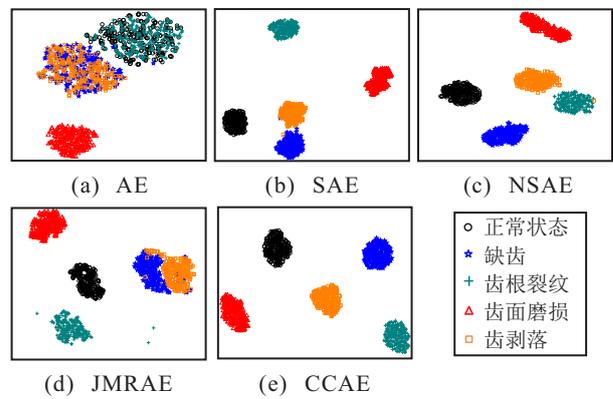


图7 齿轮数据集上5种AE方法的特征可视化

除了测试精度和标准差,训练时间也是反映诊断效果的一个重要指标。图8对比了5种无监督特征学习方法的训练时间,这些方法采用相同的网络结构和迭代步数。对比实验在PC端、处理器为AMD Ryzen 5 4600H CPU及16GB RAM、Matlab 2019(a)环境下进行。可以看出,本文方法的训练过程由于包括伪标签获取和CCAIE网络参数训练两个环节,花费的时间略高于其他4种方法,但仍在一个数量级上。随着训练算法和计算机硬件的提升,未来CCAIE的训练时间有望进一步降低。

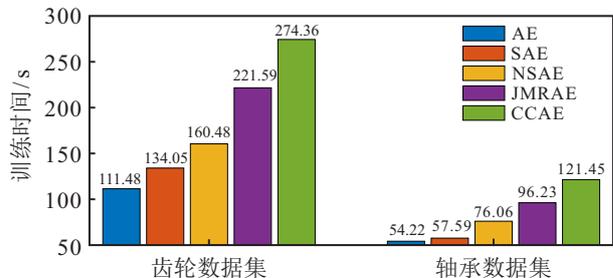


图8 5种AE方法的训练时间

4.3 研究参数λ对诊断结果的影响

λ是CCAIE中的重要参数,其作用是平衡 ψ_{AE} 与 ψ_{CCR} 之间的重要性。本小节在一个较大范围内研究λ

对诊断性能的影响,结果如图9中的箱形图所示.图9中的中间红线、上黑线和下黑线分别表示20次重复实验测试精度值的中位数、最大值和最小值.

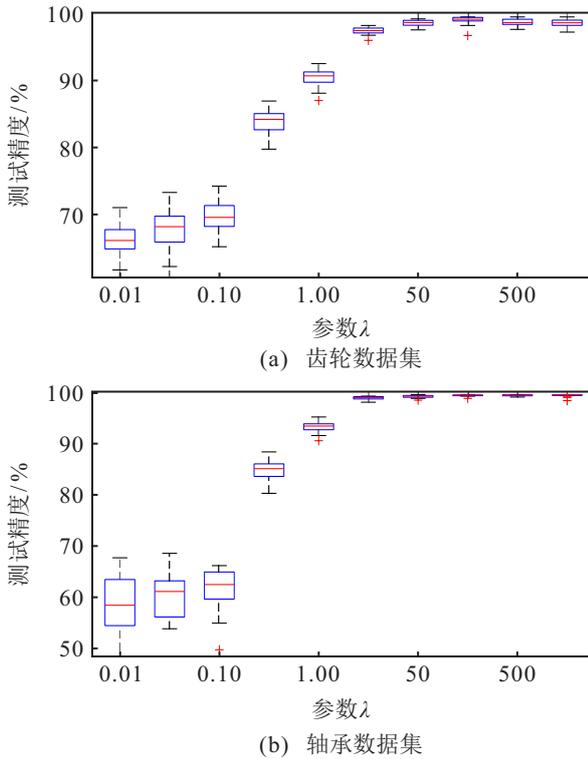


图9 参数λ取不同值时CCAe的诊断结果

从图9中可以看出:当λ从0.01增加到100时,所提方法在两个数据集上均表现为测试精度逐渐提升,波动范围逐渐减小,诊断结果越来越好;当λ从100继续增加时,诊断性能略有下降.上述现象的原因分析如下:当λ较小时,ψ_{CCR}的作用较小导致CCAe的特征学习能力弱,极端情况下λ = 0时的CCAe退化为标准AE;当λ逐渐增加时,ψ_{CCR}逐渐发挥作用,判别性特征被提取,使得诊断性能越来越好;当λ更大时,CCAe过于侧重ψ_{CCR}而忽略ψ_{AE},结果样本间的重构作用变弱,造成输入数据中部分信息丢失,从而影响了诊断性能.

4.4 伪标签可行性验证

为了保证CCAe的无监督属性,本文采用FCM算法并结合PBMF指标获得样本的伪标签.为了验证该策略的可行性,CCAe使用其他4类标签作为对比:1)真实标签:在信号采集和分段时人工标注;2)随机标签:为每个样本随机赋予标签值 $c \in \{1, 2, \dots, C\}$,其中齿轮和轴承数据集上的C分别为5和3;3)相同标签:所有样本的标签相同,此时等价于 $C = 1$;4)互异标签:每个样本单独成一个簇,此时等价于 $C = N$.所有对比实验在8种网络结构(50-50,50-75,75-75,75-100,100-100,100-150,150-150,150-200)下进行,结果如图10所示.

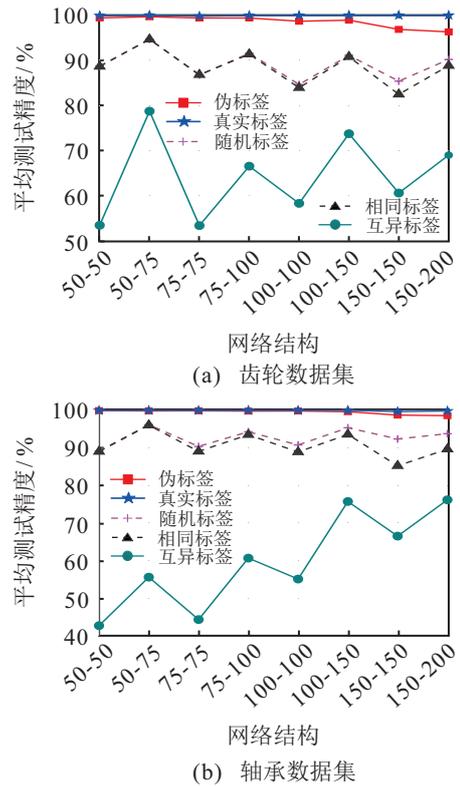


图10 不同网络结构下5种标签对应的平均测试精度

从图10的每个数据集中可以看出,伪标签与真实标签的测试精度几乎相当,大尺度网络结构下前者略逊于后者,但两者明显优于另外3类标签.随机标签与相同标签的测试精度几乎相当,大尺度网络结构下前者略优于后者,这说明随机标签一定程度上也能增强特征的判别性.互异标签的诊断结果最差,原因在于此时的CCAe完全等价于标准AE,其特征学习能力严重不足.综上可知,图10的实验结果验证了伪标签策略的可行性,该策略不仅能取得优异的诊断结果,还能保证CCAe的无监督属性.

5 结论

为了解决传统AE难以以无监督方式提取判别性特征的问题,本文提出了CCAe.在该方法中,FCM算法与PBMF指标相结合获得样本的伪标签,用以构建簇紧凑正则项,然后将簇紧凑正则项与标准AE的损失函数进行联合最小化.在齿轮和轴承故障数据集上测试CCAe的性能,得出了如下主要结论:

- 1) 由PBMF指标获得的最佳聚类数与真实类别数完全吻合,结果表明使用该指标是合理有效的.
- 2) 所提方法在两个数据集上均取得超过99%的诊断精度,性能与深度学习方法几乎相当,但显著优于传统的信号处理方法和目前主流的无监督特征学习方法.同时5种无监督特征学习方法的特征可视化结果表明本文方法的特征判别性最强.
- 3) 在8种网络结构下对比伪标签和4种其他类

型标签的平均测试精度,结果表明伪标签取得的精度与真实标签的精度几乎相当,且两者均远远优于其他3类标签,结果表明使用伪标签是可行的。

参考文献(References)

- [1] Yang C Y, Zhou K B, Liu J. SuperGraph: Spatial-temporal graph-based feature extraction for rotating machinery diagnosis[J]. IEEE Transactions on Industrial Electronics, 2022, 69(4): 4167-4176.
- [2] 邵海东, 肖一鸣, 颜深. 仿真数据驱动的改进无监督域适应轴承故障诊断[J]. 机械工程学报, 2023, 59(3): 76-85.
(Shao H D, Xiao Y M, Yan S. Simulation data-driven enhanced unsupervised domain adaptation for bearing fault diagnosis[J]. Journal of Mechanical Engineering, 2023, 59(3): 76-85.)
- [3] 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络[J]. 控制与决策, 2023, 38(7): 1918-1926.
(Yao J Q, Jing H, Zhao C H. A multimode coupled input neural network for rotating machinery fault diagnosis in the noisy environment[J]. Control and Decision, 2023, 38(7): 1918-1926.)
- [4] Peng D D, Wang H, Liu Z L, et al. Multibranch and multiscale CNN for fault diagnosis of wheelset bearings under strong noise and variable load condition[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4949-4960.
- [5] Lei Y G, Jia F, Lin J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data[J]. IEEE Transactions on Industrial Electronics, 2016, 63(5): 3137-3147.
- [6] 张志强, 杨清宇. 一种用于机械故障特征提取的多尺度稀疏滤波网络[J]. 控制与决策, 2022, 37(5): 1267-1278.
(Zhang Z Q, Yang Q Y. A multi-scale sparse filtering network for fault feature extraction of machinery[J]. Control and Decision, 2022, 37(5): 1267-1278.)
- [7] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [8] Ng A. Sparse autoencoder[J]. CS294A Lecture Notes, 2011, 72: 1-19.
- [9] Sun J D, Yan C H, Wen J T. Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(1): 185-195.
- [10] Jia F, Lei Y G, Guo L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines[J]. Neurocomputing, 2018, 272: 619-628.
- [11] Yu H, Wang K, Li Y. Multiscale representations fusion with joint multiple reconstructions autoencoder for intelligent fault diagnosis[J]. IEEE Signal Processing Letters, 2018, 25(12): 1880-1884.
- [12] 冀俊忠, 龙腾, 杨翠翠. 基于邻域决策粗糙集的脑功能连接生物标记物识别[J]. 控制与决策, 2023, 38(4): 1092-1100.
(Ji J Z, Long T, Yang C C. Recognition of biomarkers of brain functional connection based on neighborhood decision rough set[J]. Control and Decision, 2023, 38(4): 1092-1100.)
- [13] Pal N R, Bezdek J C. On cluster validity for the fuzzy c-means model[J]. IEEE Transactions on Fuzzy Systems, 1995, 3(3): 370-379.
- [14] Pakhira M K, Bandyopadhyay S, Maulik U. Validity index for crisp and fuzzy clusters[J]. Pattern Recognition, 2004, 37(3): 487-501.
- [15] Zhang X L, Zhang Q, Chen M, et al. A two-stage feature selection and intelligent fault diagnosis method for rotating machinery using hybrid filter and wrapper method[J]. Neurocomputing, 2018, 275: 2426-2439.
- [16] Lei Y G, He Z J, Zi Y Y, et al. Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs[J]. Mechanical Systems and Signal Processing, 2007, 21(5): 2280-2294.
- [17] Xu X F, Lei Y G, Li Z D. An incorrect data detection method for big data cleaning of machinery condition monitoring[J]. IEEE Transactions on Industrial Electronics, 2020, 67(3): 2326-2336.
- [18] Zhao R, Wang D Z, Yan R Q, et al. Machine health monitoring using local feature-based gated recurrent unit networks[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1539-1548.
- [19] Bechhoefer E. A quick introduction to bearing envelope analysis[EB/OL]. (2022-07-04)[2022-08-24]. <https://mfpt.org/fault-data-sets/>.
- [20] Muruganatham B, Sanjith M A, Krishnakumar B, et al. Roller element bearing fault diagnosis using singular spectrum analysis[J]. Mechanical Systems and Signal Processing, 2013, 35(1/2): 150-166.
- [21] Lei Y G, He Z J, Zi Y Y. Application of an intelligent classification method to mechanical fault diagnosis[J]. Expert Systems With Applications, 2009, 36(6): 9941-9948.
- [22] Jia F, Lei Y G, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems and Signal Processing, 2016, 72/73: 303-315.
- [23] Ince T, Kiranyaz S, Eren L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [24] Der Maaten L V, Hinton G E. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.

作者简介

张志强(1993—), 男, 讲师, 博士, 从事智能故障诊断的研究, E-mail: zhiqiangzhang@hfut.edu.cn;

储昭碧(1970—), 男, 教授, 博士生导师, 从事工业控制系统与智能装备、机器人与智能系统集成、自适应控制等研究, E-mail: zbchu@hfut.edu.cn;

陈立平(1984—), 男, 教授, 博士生导师, 从事复杂系统建模分析与控制、储能系统能量管理、数字孪生与机器学习等研究, E-mail: lip_chen@hfut.edu.cn;

杨清宇(1974—), 男, 教授, 博士生导师, 从事信息物理融合能源系统优化与安全、智能电网优化调度与隐私安全、故障诊断与智能运维等研究, E-mail: yangqingyu@mail.xjtu.edu.cn.