

控制与决策

Control and Decision

轴承在线早期故障检测的无监督张量深度迁移学习方法

毛文涛, 施华东, 张艳娜, 仲志丹

引用本文:

毛文涛, 施华东, 张艳娜, 仲志丹. 轴承在线早期故障检测的无监督张量深度迁移学习方法[J]. *控制与决策*, 2024, 39(3): 867–876.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1101>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer
控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于2D-OTSU图像边缘检测的回转窑工况识别方法

Condition recognition method of rotary kiln based on 2D-OTSU image edge detection
控制与决策. 2021, 36(10): 2427–2434 <https://doi.org/10.13195/j.kzyjc.2020.0348>

面向复杂网络的异常检测研究进展

Research progress of anomaly detection for complex networks
控制与决策. 2021, 36(6): 1293–1310 <https://doi.org/10.13195/j.kzyjc.2020.0055>

融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning
控制与决策. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

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>

轴承在线早期故障检测的无监督张量深度迁移学习方法

毛文涛^{1,3†}, 施华东¹, 张艳娜¹, 仲志丹²

(1. 河南师范大学 计算机与信息工程学院, 河南 新乡 453007; 2. 河南科技大学 机电工程学院, 河南 洛阳 471000; 3. 智慧商务与物联网技术河南省工程实验室, 河南新乡 453007)

摘要: 基于张量分解可有效挖掘信号高维本质信息的优点, 提出一种无监督张量深度迁移学习方法. 首先, 构建基于张量表示的深度多任务异常检测模型, 利用核心张量构建单分类异常检测规则表示, 并建立超球规则适配机制, 交替优化张量分解和域无关特征提取, 以实现异常检测规则在离线轴承和在线目标轴承间的有效传递, 完成在线无标记数据的异常检测; 其次, 提出一个基于异常概率贯序累积的非参数报警阈值设定方法, 可在仅设定误报率置信度的条件下自适应选择在线阈值, 并给出该阈值合理性的理论分析. 在 IEEE PHM Challenge 2012 轴承数据集上进行实验, 结果表明, 所提出方法可获得更好的检测实时性和更低的误报警数, 为早期故障检测提供一种具有易部署性和鲁棒性的解决方案.

关键词: 早期故障检测; 深度学习; 迁移学习; 异常检测; 滚动轴承

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1101

引用格式: 毛文涛, 施华东, 张艳娜, 等. 轴承在线早期故障检测的无监督张量深度迁移学习方法[J]. 控制与决策, 2024, 39(3): 867-876.

Unsupervised tensor-based deep transfer learning for online early fault detection of bearing

MAO Wen-tao^{1,3†}, SHI Hua-dong¹, ZHANG Yan-na¹, ZHONG Zhi-dan²

(1. School of Computer and Information Engineering, Henan Normal University, Xinxiang 453007, China; 2. School of Mechatronics Engineering, Henan University of Science and Technology, Luoyang 471000, China; 3. Engineering Lab of Intelligence Business & Internet of Things, Henan Province, Xinxiang 453007, China)

Abstract: With the merit that tensor decomposition can represent high-dimensional essential information of signal effectively, this paper proposes an unsupervised tensor-based deep transfer learning approach. First, a tensor representation-based deep multi-task anomaly detection model is built. This model utilizes core tensor to construct the representation of one-class anomaly detection rule and establishes hypersphere rule adaptation mechanism. By running with an alternative optimization of tensor decomposition and common feature extraction, this model can conduct effective transition of anomaly detection rule from offline bearings to online target bearing and realize anomaly detection of online unlabeled data. Second, a nonparametric alarm threshold setting method is designed based on sequential accumulation of anomalous probability. This method can adaptively determine online threshold only requiring the confidence level of false alarm. Moreover, a theoretical analysis about the threshold's rationality is provided. Experimental results on the IEEE PHM Challenge 2012 dataset show that the proposed approach can obtain real-time detection performance and lower number of false alarm. The proposed approach is believed to supply a solution with better deployment and robustness.

Keywords: early fault detection; deep learning; transfer learning; anomaly detection; rolling bearing

0 引言

作为各类工程机械中的关键支承元件, 滚动轴承的健康状态直接关系到整体设备的运行状态. 受

大负荷、高速旋转等复杂工况环境的影响, 滚动轴承不可避免地产生磨损, 直至彻底失效. 准确、及时地检测滚动轴承的早期故障, 有助于在故障发生之初发

收稿日期: 2022-06-23; 录用日期: 2022-11-10.

基金项目: 国家重点研发计划重点专项基金项目(2018YFB1701400); 河南省重大科技专项项目(221100220100); 河南省科技研发计划联合基金项目(222103810030).

†通讯作者. E-mail: maowt@htu.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

现设备安全隐患,开展预防性维修,避免重大事故的发生,目前已成为故障预测与健康管理(prognostics and health management, PHM)的关键技术环节^[1]. 早期故障检测技术主要从系统监测数据中识别运行状态的变化^[2]. 近年来,随着传感技术的发展,各类机器学习算法开始被用于解决轴承早期故障检测问题,包括支持向量机(support vector machine, SVM)^[3]、高斯过程^[4]等浅层模型和卷积神经网络(convolutional neural network, CNN)^[1]、长短期记忆(long short-term memory, LSTM)^[5]等深度模型. 如何根据具体应用特点,构建合适的检测模型,仍是目前轴承早期故障检测研究的核心问题.

与现有大多数早期故障检测研究不同,本文关注的是在线场景下的早期故障检测问题. 该问题强调在不停机场景下检测目标轴承的运行状态变化,并于故障发展到严重程度之前及时报警. 这一做法有助于实时评估轴承工作状态,避免因等待停机检查而产生延误,更契合于实际应用需求,因此越来越受到工业界的重视^[5]. 受在线场景制约,在线早期故障检测通常存在如下挑战: 1) 目标轴承的状态信号以流数据形态贯序采集,其状态信息既无人工标注,也无法提前设定,即不应该默认初始阶段为正常状态; 2) 因磨合、润滑、装配工艺等因素制约,目标轴承的正常运行过程易受不规则噪声干扰,产生误报警,相比于漏报警(现有故障诊断方法已较成熟),在线检测更应避免误报警; 3) 现有报警阈值的设置多依赖于人工经验,不具有良好的自适应性,并不适用于在线检测. 需要强调的是,虽然现在已有部分针对在线早期故障检测的研究^[5-6],但这些工作均假设目标轴承运行初期的数据为正常状态,而在实际应用中这一要求过于严格,一定程度上降低了检测方法的易部署性和实用性.

根据调研,直接使用在线场景采集的无标记数据建立检测模型并无法有效地解决上述挑战. 由于同型号轴承在不同工况下的退化趋势具有内在的相似性^[7],一个基本思路是借助离线工况(例如实验室或工厂环境)下采集的轴承数据(本文称为离线轴承),提升在线工况下目标轴承无标记状态数据的故障检测效果. 轴承运行过程通常可分正常状态、早期故障状态和快速退化状态,若能离线轴承对早期故障的判别信息传递到目标轴承,则可有效解决无标记数据缺乏故障先验信息的问题. 这种情况下,如何有效提取和迁移轴承的早期故障演化知识,成为提升在线早期故障检测效果的关键.

基于上述思路,本文引入深度迁移学习技术解决上述问题. 基于深度神经网络,深度迁移学习技术强调利用一个领域数据(称为源域)中的领域知识,提升另一个相关但不同的领域(称为目标域)中的模型性能,目前已在轴承故障诊断、剩余寿命预测等问题得到成功应用^[8-9]. 若把离线轴承数据视为源域,把在线目标轴承数据视为目标域,同时将早期故障检测视为正常状态数据的异常检测问题,则轴承在线早期故障检测可表示为无监督异常检测迁移学习问题. 具体而言,本文提出一种无监督张量迁移学习方法. 该方法构建了基于核心张量的单分类异常检测规则表示,进而在多任务学习框架基础上完成检测规则的传递,提高了目标轴承无标记数据的异常检测效果,并基于所提取的公共特征表示,给出了一个非参数阈值设定方法,实现自适应的在线早期故障报警. 引入张量的目的在于合理提取信号高维本质信息,而相比于传统迁移学习模型的单向信息传递模式,多任务学习框架可一定程度避免目标域的过学习现象^[10],更适用于对在线无标记数据的异常检测. 最终在 IEEE PHM Challenge 2012 轴承数据集上进行实验,结果验证了本文方法的可行性与有效性.

本文工作主要集中在以下几个方面:

1) 提出一种面向无标记流数据的轴承在线早期故障检测方法,与现有轴承早期故障检测方法相比,该方法直接对无标记流数据进行学习,无需假设轴承运行初期一定为正常状态,同时误报警率显著降低,极大扩展了该方法的部署方式,更符合实际应用特点. 根据作者文献调研,目前利用无监督异常检测迁移学习方法研究轴承在线早期故障检测仍处于起步阶段.

2) 提出一种基于张量表示的深度多任务异常检测模型,通过建立超球规则适配机制,交替优化张量分解和公共特征提取,实现了异常检测规则在源域和目标域间的有效传递. 与现有迁移学习方法相比,该模型可有效抑制公共特征对不规则噪声干扰的敏感度,同时提高对异常数据的判别能力,从而提升无监督异常检测效果. 根据文献调研,目前尚未发现张量表示优化在无监督深度迁移学习中的应用.

3) 提出一种基于异常概率贯序累积的非参数报警阈值设定方法,从故障演化的时序特性出发,仅需设定误报警率置信度即可自适应确定最优在线报警阈值,并给出了该阈值合理性的理论分析. 与现有多依赖于人工经验的报警策略相比,该方法不需要过多人工干预,具有良好的自适应性,可有效提高检测准

确率和鲁棒性,因此非常适合于不停机场景下的早期故障检测问题。

1 无监督张量深度迁移学习方法

将无监督张量深度迁移学习方法用于不停机场

景下的轴承在线早期故障检测. 如图1所示,整体流程主要包括两个环节:基于张量表示的深度多任务异常检测模型和异常概率贯序累积的非参数报警阈值设定。

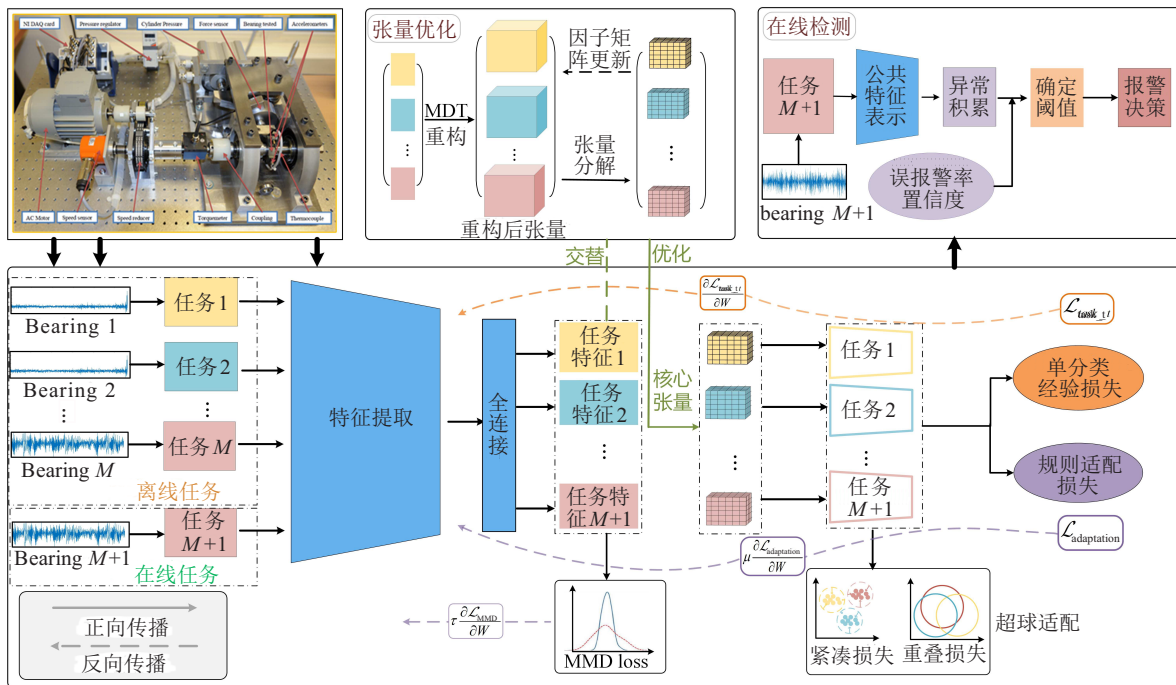


图1 本文方法的整体流程

1.1 基于张量表示的深度多任务异常检测模型

基于多任务学习框架,引入张量提取和表示异常检测规则,完成规则在多个轴承(检测任务)之间的合理传递.之所以采用多任务学习作为基础迁移框架,主要基于如下考虑:1)目标轴承早期故障检测规则同样有助于提升离线轴承的检测效果,同时提升所有轴承的故障检测效果更为合理;2)目前已有研究^[11-12]表明,常规迁移学习模型在使用领域对抗等策略时存在目标域过度学习的风险,尤其对于目标域的无标记数据,较难以控制信息迁移程度。

1.1.1 模型建立

设离线工况下轴承正常状态数据为 $\{X^1, X^2, \dots, X^M\}^S$. 其中: M 表示离线轴承的数量,上标 S 表示源域. 此处正常状态数据可通过状态划分方法^[2]从全寿命数据中获取. 在线工况下目标轴承的状态监测数据为 $\{X^{M+1}\}^T$, 其中上标 T 表示目标域. 将 M 个离线轴承作为离线任务,第 $M + 1$ 个轴承为在线任务,该多任务学习模型可分为3个部分:

1) 特征提取模块.

该模块可以是任一种深度神经网络,其结构取决于应用问题特点或训练样本的复杂程度. 在本文中由3个卷积层和3个池化层组成,可描述为:给定输入

空间 $\chi \subseteq \mathbf{R}^d$, 输出空间 $F \subseteq \mathbf{R}^p$. 其中: $\phi(\cdot; W) : \chi \rightarrow F$ 为网络映射函数; $W = \{W^1, \dots, W^L\}$ 为隐层的权重矩阵, W^ℓ 代表第 $\ell \in \{1, 2, \dots, L\}$ 层参数. 该模块目标是通过最小化目标函数学习到特征映射关系 $\phi(\cdot; W)$ 的神经网络参数 W . 假设任务 t 的输入数据为 $X^t = \{x_1^t, \dots, x_n^t\}$, 经网络 ϕ 映射之后的特征为 $\hat{X}^t = \{\hat{x}_1^t, \dots, \hat{x}_n^t\}$.

2) 基于张量的单分类异常检测规则表示.

为了使特征 \hat{X}^t 能充分利用样本间的时序信息,抑制不规则噪声干扰,此处使用多路延迟变换技术 (multi-way delay embedding transform, MDT)^[13], 将 \hat{X}^t 沿着时间方向转换为高阶张量 $\mathbf{X}^t = \{\mathcal{X}_1^t, \dots, \mathcal{X}_{n-\tau+1}^t\} \subseteq \mathbf{R}^{p \times \tau}$, 其中

$$\mathcal{X}_i^t = \mathcal{H}(\hat{X}^t) = \text{Fold}_{(n,1)}(\hat{X}^t \times_1 S_1), \quad (1)$$

τ 和 n 分别是嵌入维和样本长度, S_1 是时间方向的映射矩阵.

在 MDT 构建的张量基础上,进一步使用 Tucker 分解^[14] 获得能够代表数据本质信息的核心张量 ($G_{n-\tau+1}^t = \{g_1^t, \dots, g_{n-\tau+1}^t\}$)

$$G_{n-\tau+1}^t = \mathbf{X}^t \times_1 U^{(1)} \times_2 U^{(2)} \times \dots \times_H U^{(H)}; \quad \text{s.t. } U^{(h)\top} U^{(h)} = I, h = 1, 2, \dots, H. \quad (2)$$

其中 $\{U^{(h)}\}_{h=1}^H$ 为正交因子矩阵. 通过优化 $\{U^{(h)}\}_{h=1}^H$, 可最大限度使 $G_{n_t-\tau+1}^t$ 保留原始张量的核心信息, 同时规避不规则噪声对模型的干扰.

基于 $G_{n_t-\tau+1}^t$, 参考 SVDD^[15] 中的超球概念, 建立一个基于张量的单分类异常检测规则表示, 通过最小化包含 $G_{n_t-\tau+1}^t$ 的超球, 获得具有判别性能的异常检测决策面. 此时任务 t 的单分类经验损失为

$$\mathcal{L}_{\text{task}_t} = R_t^2 + \frac{1}{\nu n_t'} \sum_{i=1}^{n_t'} \max\{0, \|g_i^t - c_t\|^2 - R_t^2\}. \quad (3)$$

其中: R_t 和 c_t 为超球的半径和球心, $c_t = \frac{1}{n_t} \sum_{j=1}^{n_t} g_j$, $n_t' = n_t - \tau + 1$. 需要注意的是, 为实现张量数据的范数运算, 式(3)中需对 g_i^t 选择某一方向进行展开.

3) 异常检测规则适配.

在上述异常检测规则表示的基础上, 进一步考虑适合于异常检测的迁移策略. 本节采用一种直观而有效的策略: 将各个任务在特征空间中的超球尽可能重叠, 以实现检测规则的适配. 现有针对异常检测的迁移学习研究^[11] 多侧重于直接寻找域不变特征, 其本质是一种无序的公共特征提取方式, 而本节这一策略可更有指向性地提取公共特征, 实现各任务异常检测规则的有效传递. 基于上述分析, 可得规则适配损失

$$\mathcal{L}_{\text{adaptation}} = \mathcal{L}_c + \mathcal{L}_{\text{compactness}}. \quad (4)$$

其中:

① \mathcal{L}_c 表示各个任务的超球重叠损失, 通过计算不同任务超球球心的距离, 以衡量任务之间的规则适配程度, 其构造函数如下:

$$\mathcal{L}_c = \frac{1}{M} \sum_{t=1}^M \sum_{t'=t+1}^{M+1} \|c_t - c_{t'}\|^2. \quad (5)$$

② $\mathcal{L}_{\text{compactness}}$ 代表各个任务的紧凑损失, 同一任务的样本应在特征空间中尽可能向球心收缩, 以便于更好地传递检测规则, 其具体构造函数如下:

$$\mathcal{L}_{\text{compactness}} = \frac{1}{n_t'} \sum_{i=1}^{n_t'} \|g_i - m_i\|^2. \quad (6)$$

这里: $g_i \in \mathbf{R}^{p \times \tau}$ 表示第 i -th 个核心张量, $m_i = \frac{1}{n_t' - 1} \sum_{j=1, j \neq i}^{n_t'} g_j$, $1 \leq i \leq n_t'$. 需注意, 式(4)中并没有限制超球半径应尽可能一致, 这是为了避免迁移过程中出现超球坍塌现象, 即网络参数 W 全部为0、所有样本点映射到同一个偏置量. 引入 $\mathcal{L}_{\text{compactness}}$ 可代替超球半径一致的作用.

至此, 可得该模型的总体损失函数

$$\mathcal{L}_{\text{loss}} = \sum_{t=1}^{M+1} \mathcal{L}_{\text{task}_t} + \eta \mathcal{L}_{\text{adaptation}} + \beta \mathcal{L}_{\text{MMD}} + \frac{1}{2} \|\mathbf{X}^t - \hat{\mathbf{X}}^t\|_F^2 + \frac{\lambda}{2} \sum_{l=1}^{\mathcal{L}} \|W^l\|_F^2. \quad (7)$$

其中: $\mathcal{L}_{\text{task}_t}$ 和 $\mathcal{L}_{\text{adaptation}}$ 如式(3)和(4)所示; $\|\mathbf{X}^t - \hat{\mathbf{X}}^t\|_F^2$ 为张量分解过程的重构损失, 其中 \mathbf{X}^t 为原始张量, $\hat{\mathbf{X}}^t$ 为使用因子矩阵 $\{U^{(h)}\}_{h=1}^H$ 重构后的张量, 具体优化见下节; $\sum_{l=1}^{\mathcal{L}} \|W^l\|_F^2$ 是 Frobenius 范数, 最小化该项有助于避免网络过拟合; \mathcal{L}_{MMD} 代表最大均值差异 (maximum mean discrepancy, MMD)^[16] 损失, 可提高数据分布差异较大时的算法收敛性, 即

$$\mathcal{L}_{\text{MMD}}(W) = \left\| \sum_{t=1}^M \sum_{t'=t+1}^{M+1} \left(\frac{1}{n_t} \sum_{i=1}^{n_t} \phi(x_i^t) - \frac{1}{n_{t'}} \sum_{j=1}^{n_{t'}} \phi(x_j^{t'}) \right) \right\|_F. \quad (8)$$

最小化式(7)可促使整个多任务学习模型在异常检测规则适配的指引下完成正常状态数据的公共特征提取. 这一过程的核心是单分类异常检测规则在多个任务之间的传递, 而核心张量的使用可提升不规则噪声干扰下的单分类检测规则表示效果, 从而更为有效地实现检测规则适配. 本文将这一过程称为超球规则适配机制.

1.1.2 优化算法

式(7)既包括网络模型参数的优化, 也包括张量重构损失的优化. 考虑到两者优化方式不同, 采用随机梯度下降法无法直接求解, 本文采用对网络模型参数和张量因子矩阵进行交替优化的策略, 可概括为: 确定张量因子矩阵 $\{U^{(h)}\}_{h=1}^H$, 更新所有任务共享的模型参数 W 和每个任务超球半径 R_t ; 确定 W 和 R_t , 更新 $\{U^{(h)}\}_{h=1}^H$; 这两个步骤交替进行, 直至最终收敛. 具体优化过程如下:

1) 更新 W 和 R_t .

考虑到 W 和 R_t 维度不同且具有耦合性, 本文仍然采用交替优化的方式: 固定 R_t , 最小化式(7)得到最优 W ; 固定 W , 计算 R_t , 直至收敛. 对 W 的优化采用传统随机梯度下降法, 具体细节可参见文献[17]. 此处主要给出涉及到 R_t 的优化步骤. 第 k 次迭代时 R_t 的优化问题如下:

$$R_t^k = \arg \min_{R_t} \mathcal{L}_{\text{loss}}(R_1^k, R_2^k, \dots, R_t, \dots, R_{M+1}^{(k-1)}, W^{(k-1)}). \quad (9)$$

对 R_t 的具体更新过程可写为

$$R_t^k = R_t^{k-1} - \xi \left(\frac{\partial \mathcal{L}_{\text{loss}}}{\partial R_t} \right) = R_t^{k-1} - \xi \frac{\partial \mathcal{L}_{\text{task}_t}}{\partial R_t}. \quad (10)$$

其中 ξ 为学习率, 且由式(3)可知

$$\frac{\partial \mathcal{L}_{\text{task}_t}}{\partial R_t} = \frac{\partial}{\partial R_t} \left((R_t)^2 + \frac{1}{\nu n_t'} \sum_{i=1}^{n_t'} \max\{0, \|g_i^t - c_t\|^2 - R_t^2\} + \frac{\lambda}{2} \sum_{\ell=1}^L \|W^\ell\|_F^2 \right). \quad (11)$$

$\frac{1}{\nu n_t'} \sum_{i=1}^{n_t'} \max\{0, \|g_i^t - c_t\|^2 - R_t^2\}$ 为离散值, 无法直接求导, 因此使用 $m_t \leq n_t'$ 代表第 t 个任务中满足 $\|g_i^t - c_t\|^2 - R_t^2 > 0$ 的样本总数, 可得

$$\frac{\partial \mathcal{L}_{\text{task}_t}}{\partial R_t} = 2R_t \left(1 - \frac{m_t}{n_t'} \right). \quad (12)$$

综上, 第 k 次迭代时 R_t^k 可由下式更新:

$$R_t^k = R_t^{k-1} - \xi \left(2R_t^{k-1} \left(1 - \frac{m_t}{n_t'} \right) \right). \quad (13)$$

2) 更新 $\{U^{(h)}\}_{h=1}^H$.

该优化问题可表示为

$$\min \| \mathbf{X}^t - \hat{\mathbf{X}}^t \|_F^2. \quad (14)$$

其中: $\|\cdot\|_F$ 为 Frobenius 范数, $\hat{\mathbf{X}}^t = G_{n_t-\tau+1}^t \times_1 U^{(1)} \times_2 U^{(2)} \dots \times_H U^{(H)}$. 因为 $\{U^{(h)}\}_{h=1}^H$ 为正交矩阵, 所以式(14)可重写为

$$\begin{aligned} & \| \mathbf{X}^t - \hat{\mathbf{X}}^t \| = \\ & \| \text{vec}(\mathbf{X}^t) - (U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(1)}) \cdot \\ & \text{vec}(G_{n_t-\tau+1}^t) \|_F^2 = \\ & \| \text{vec}(\mathbf{X}^t) - (U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(1)}) \cdot \\ & (U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(1)})^T \cdot \text{vec}(\mathbf{X}^t) \|_F^2 = \\ & \| \text{vec}(\mathbf{X}^t) \|_F^2 - \| U^T \cdot \text{vec}(\mathbf{X}^t) \|_F^2, \end{aligned} \quad (15)$$

其中 $U^T = U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(1)}$. 若使式(15)最小, 则应求下式的最大值:

$$\| U^T \cdot \text{vec}(\mathbf{X}^t) \|_F^2 = \begin{cases} \| U^{(1)T} \cdot A^{(1)} \cdot (U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(2)}) \|_F^2, \\ \| U^{(2)T} \cdot A^{(2)} \cdot (U^{(H)} \otimes U^{(H-1)} \otimes \dots \otimes U^{(1)}) \|_F^2, \\ \vdots \\ \| U^{(H)T} \cdot A^{(1)} \cdot (U^{(H-1)} \otimes U^{(H-2)} \otimes \dots \otimes U^{(1)}) \|_F^2. \end{cases} \quad (16)$$

其中: $A^{(i)}$ 表示张量 \mathbf{X}^t 在第 i 维度的展开矩阵, 可采用交替最小二乘法求解^[18], 依次固定各个方向上的因子矩阵, 寻找最小二乘解, 即

$$\begin{aligned} U_{k+1}^{(h)} = & \arg \min_{\{U^{(h)}\}_{h=1}^H} \| \hat{\mathbf{X}}^t - G_{n_t-\tau+1}^t \times_M U_k^{(H)} \times \\ & M_{-1} U_k^{(H-1)} \dots \times_1 U_k^{(1)} \|_F^2. \end{aligned} \quad (17)$$

1.2 基于异常概率贯序累积的非参数报警阈值设定

尽管 1.1 节模型可以较好地实现目标轴承无标记数据的异常检测, 但其检测方式主要针对单个样本点进行, 并未考虑故障发生时的时序性. 这可能导致检测出的异常点并不是真正的早期故障, 即误报警. 因此, 对于在线场景下的早期故障检测, 有必要进一步设立合理的报警阈值, 提高报警结果的合理性. 然而, 在线场景下无法提前储备充足的故障数据, 因此无法从数据中学习得到故障先验信息.

对于正常状态下相邻时间内的数据, 可以认为它们遵循某一概率分布. 本节首先利用 1.1 节所获得的正常状态数据的公共特征表示 (即参数矩阵 W), 建立在线数据的非参数描述, 进而构建一个人工干预少、具有良好的自适应和鲁棒性的报警阈值. 具体而言, 基于上述基于超球的单分类异常检测规则, 可以计算在线轴承每个样本的异常分数

$$\text{score}_i = \|\phi(x_i^t; W) - c^t\|_2 - R_t. \quad (18)$$

在此基础上, 为利用故障发生的时序性来规避误报警, 本节参考 CUSUM 控制图^[19] 原理, 提出一个异常程度累积指标

$$\delta_i = \max\{\text{score}_i + \delta_{i-1}, 0\}, \text{score}_0 = 0. \quad (19)$$

CUSUM 主要通过计算检测过程中样本信息的偏差累积和提高对小偏移的灵敏度. 式(19)中, 若训练数据为正常状态数据, δ_i 在零附近波动, 则当故障发生后, δ_i 连续增加, 超过阈值 h 时进行报警. 但阈值 h 的选择大多依赖人工经验, 并未对阈值的合理性进行分析. 此处给出如下适合上述异常程度累积指标的阈值设定方法及合理性分析.

定理 1 给定所期望的误报警率 FAR, 式(19)所示异常程度累积指标的报警阈值的最大值为

$$h = \frac{-\log(\text{FAR})}{\omega_0}. \quad (20)$$

其中: $\omega_0 = \nu_p - W((e^\phi + e^{R_M})/a_0)$, $a_0 = e^{\nu_p R_M} / \nu_p$.

证明 对于具有独立增量的 CUSUM 算法, 其平均误报警周期的下界^[19] 为

$$E_\infty[T] \geq e^{\omega_0 h}. \quad (21)$$

其中: h 为检测阈值, $\omega_0 \geq 0$ 为 $E[e^{\omega_0 s_i}] = 1$ 的解^[19].

给定所期望的误报警率, 式(20)的计算可转换为求解 ω_0 . 对于正常状态数据, 式(20)的结果并不受影

响,因此可假设 score_i 随着时间变化是独立分布的,其累积分布函数为

$$P(\text{score}_i \leq y) = P(d_i \leq y + R_M). \quad (22)$$

因此,只需要估计出 d_i 的概率分布. 考虑到退化过程是一个时间连续状态离散的随机过程,可以认为 d_i 符合强度 $\lambda = 1$ 的齐次泊松过程

$$P(d_i \leq r) = 1 - \exp(\Lambda(b(\hat{x}_i^t, r))). \quad (23)$$

其中: \hat{x}_i^t 为 x_i^t 经参数矩阵 W 得到的 p 维特征向量, $\Lambda(b(\hat{x}_i^t, r))$ 是超球 $b(\hat{x}_i^t, r)$ 的到达强度, $b(\hat{x}_i^t, r)$ 以 \hat{x}_i^t 为球心, r 为测度范围^[20]. 对于齐次泊松过程,其到达强度可写为 $\Lambda(b(\hat{x}_i^t, r)) = \lambda|b(\hat{x}_i^t, r)|$. 其中: $|b(\hat{x}_i^t, r)| = \frac{\pi^{p/2}}{\Gamma(p/2 + 1)} r^p = \nu_p r^p$ 是超球 $b(\hat{x}_i^t, r)$ 经过 Lebesgue 测度转换之后的结果^[20], $\nu_p = \frac{\pi^{p/2}}{\Gamma(p/2 + 1)}$ 是 p 维 Lebesgue 测度常数. 因此,式(23)可表示为

$$P(d_i \leq r) = 1 - \exp(-\nu_p r^p), \quad (24)$$

进而可得 d_i 和 score_i 的概率密度

$$f_{d_i}(y) = \frac{\partial}{\partial d} [1 - \exp(-\nu_p y)] = \nu_p \exp(-\nu_p y), \quad (25)$$

$$f_{s_i}(y) = \nu_p \exp(-\nu_p R_M) \exp(-\nu_p y). \quad (26)$$

将式(26)代入 $E[e^{\omega_0 s_i}] = 1$, 可得

$$1 = \int_{-R_M}^{\phi} e^{\omega_0 y} \nu_p e^{-\nu_p R_M} e^{-\nu_p y} dy, \quad (27)$$

约简可得

$$\frac{e^{\nu_p R_M}}{\nu_p} = \int_{-R_M}^{\phi} e^{(\omega_0 - \nu_p)y} dy = \frac{e^{(\omega_0 - \nu_p)y}}{\omega_0 - \nu_p} \Big|_{-R_M}^{\phi} = \frac{e^{(\omega_0 - \nu_p)\phi} - e^{(\omega_0 - \nu_p)(-R_M)}}{\omega_0 - \nu_p}, \quad (28)$$

其中 $-R_M$ 和 ϕ 是 score_i 的上下界. 因在线目标轴承的训练数据已知,上下界可以认为是确定值,式(28)可重写为

$$(e^{\phi} + e^{R_M})e^{\omega_0 - \nu_p} = (\omega_0 - \nu_p) \frac{e^{\nu_p R_M}}{\nu_p}. \quad (29)$$

为了求解 ω_0 , 令 $x = \omega_0 - \nu_p$, $a_0 = \frac{e^{\nu_p R_M}}{\nu_p}$, $\theta = e^{\phi} + e^{R_M}$, 因此式(29)可重写为

$$e^{x\phi} - e^{x(-R_M)} = xa_0. \quad (30)$$

本文的目的是求解 ω_0 的最大值,在 $x = \omega_0 - \nu_p$ 中 ν_p 为定值,因此使得 x 值最大即可. 式(30)中 a_0 为定值, $0 \leq R_M \leq \phi$, 根据每一项函数的单调性,在 $R_M = 0$ 时, x 取极大值. 令 $b_0 = \frac{\nu_p}{e^{\nu_p R_M}}$, 式(30)重写为

$$e^{x\phi} = (x + b_0)a_0. \quad (31)$$

该式的解可以由 Lambert-W 函数^[21] 在 $x = -b_0$

$-W(-\phi e^{-\phi b_0}/a_0)$ 时得到,因此有

$$\omega_0 = \nu_p - b_0 - \frac{1}{\phi} W(-\phi b_0 e^{-\phi b_0}), \quad (32)$$

其中 $W(\cdot)$ 为 Lambert-W 函数. 由文献[19]可知,误报警率的上限为 $\text{FAR} \leq e^{\omega_0 h}$. 由于误报警率为误报警周期的倒数,可得

$$h = \frac{-\log(\text{FAR})}{\omega_0}. \quad (33)$$

由此定理得证. \square

由定理1可知,在给定期望的误报警率前提下,式(19)所示异常程度累积指标的报警阈值可由式(20)得出. 该报警阈值只依赖于目标轴承的在线数据特点,可充分利用故障演化的时序性,同时不需要过多的先验信息,因此非常适合于在线早期故障检测问题.

2 实验结果

2.1 数据介绍

IEEE PHM Challenge 2012^[22] 轴承数据集提供了3种不同工况下采集的17个轴承从正常到故障的全寿命数据. 3种工况信息分别为转速1800 rpm、1650 rpm、1500 rpm 和载荷4000 N、4200 N、5000 N. 采样频率为25.6 kHz, 每10 s采集一个样本,其中包含2560个采样点.

2.2 实验设置

为了模拟在线检测,本文将工况1作为离线数据,工况2下的轴承 Bearing_2_1 作为在线轴承. 具体而言,本文从工况1的3个轴承数据中选择正常状态的前500个样本作为离线训练数据. 根据文献[2]的验证,工况1下轴承的前500个样本均处于正常状态. 本文另选择 Bearing_2_1 的前100个样本作为在线训练数据,为模拟流数据形态,这100个样本的状态标签未知,且存在较明显的波动. 此外,本文所使用的正则化参数 η 、 β 、 λ 和学习率 ξ 由交叉验证和网格搜索确定最优值,最终实验参数为 η , $\beta = 5$, $\lambda = 0.01$, $\xi = 0.001$.

2.3 实验结果分析

首先,为验证本文方法的迁移学习性能,图2给出了各个轴承在迁移前后的特征分布. 考虑到在线训练数据无标签,此处使用 SDAE^[6] 提取未迁移的特征分布. 可以看出,本文方法明显提升了不同工况下单分类检测任务数据分布的一致性,为异常检测规则从离线轴承向在线轴承的迁移提供了有效支撑.

其次,图3给出了本文方法提取的在线轴承的特征走势. 为对比效果,图3同时给出了 RMS 走势和 Deep SVDD 特征走势. Deep SVDD^[23] 是目前最具代

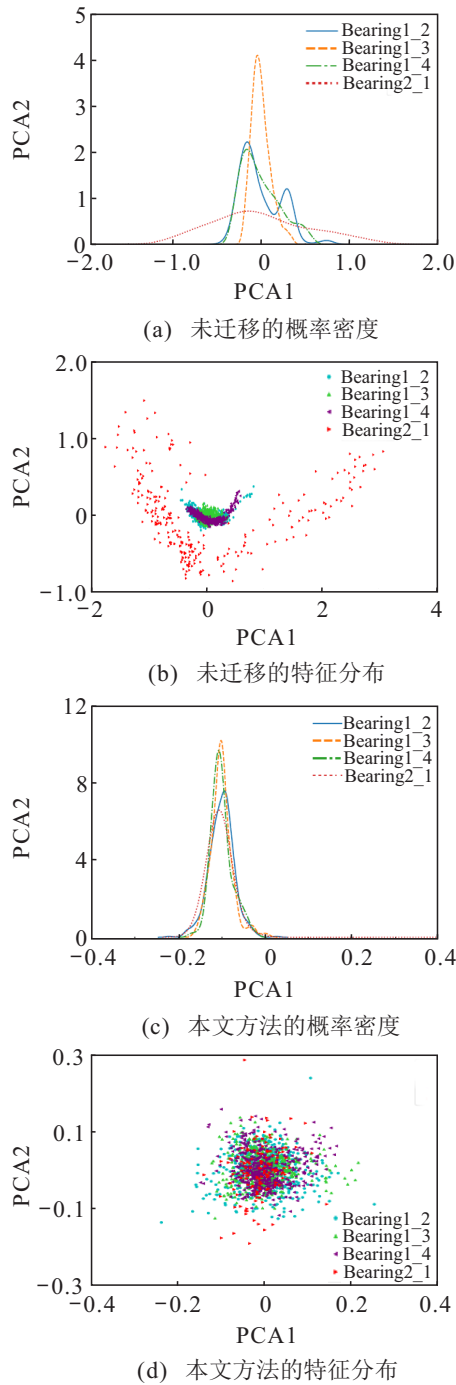


图2 迁移前后训练数据的特征分布对比

代表性的深度单分类异常检测方法. 可以看出, 在线轴承 Bearing 2_1 正常阶段的初始部分存在较明显的不规则波动, Deep SVDD 的特征受这些波动影响较大, 造成特征区分度不够明显, 对噪声干扰也不够鲁棒. 相反, 本文方法的特征序列在正常状态下的波动幅度明显降低, 而在早期故障发生位置又有清晰的跃升, 这非常有利于构建单分类异常检测决策面, 同时也表明所提取的正常状态公共特征具有良好的判别性和鲁棒性.

基于图3所提特征, 给定所期望的最大误报警率 FAR 为 0.05, 图4给出了本文方法最终的检测结果以

及 Deep SVDD 的检测结果. 从图4(a)可以看出, 本文所构造的阈值可有效规避正常状态的异常波动, 只在异常累积程度出现明确增长时进行报警, 从而有效降低了误报警现象. 同时, 由图3(c)可知, 本文特征对状态变化具有较高的敏感性, 因此基于这些特征构建在线报警阈值, 报警位置更为靠前. 而 Deep SVDD 的报警位置明显落后于本文方法, 同时受初始阶段噪声干扰, 存在明显的误报警现象.

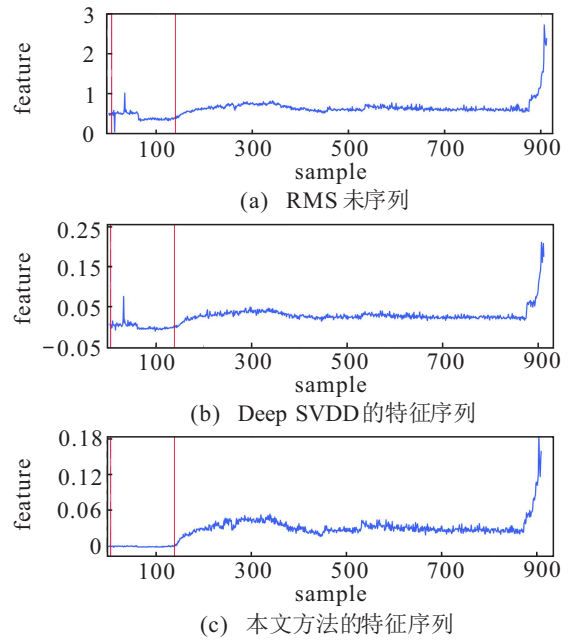


图3 在线轴承 Bearing 2_1 的特征走势对比




图4 检测结果对比

基于图4的检测结果, 图5给出了在线轴承 Bearing 2_1 正常状态和故障状态的特征分布. 可以看出: 本文方法具有清晰的决策边界, 对于两种状态

的样本区分度良好;而Deep SVDD受限于初始阶段波动的影响,所构建的决策面无法清晰、准确地区分两种状态,导致报警位置延后,同时有部分正常状态样本被划分到故障类别中,形成误报警。

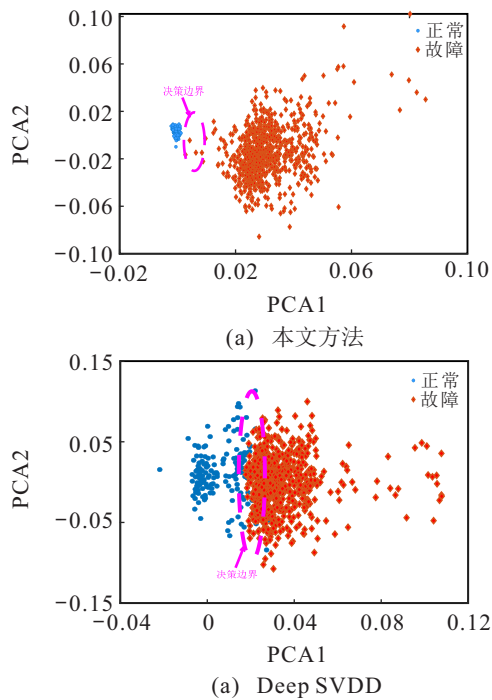


图5 在线轴承 Bearing 2_1 的特征分布

本文方法的核心是检测规则的张量表示和超球规则适配。本文设计了一组消融实验,分别对式(7)去除规则适配损失和张量重构损失,检测结果如图6所示。为了便于可视化对比,将3条特征序列进行尺度归一化。可以看到,去除这两项损失后的特征序列在正常状态均出现了明显波动,去除规则适配损失后,会出现比较明显的误报警,但相比较而言,去除张量重构损失的波动幅度更大一些。这表明对于无监督异常检测的迁移学习问题,单分类检测规则的代表和传递方法同样关键。




图6 去除不同损失项后的在线轴承特征序列

所提出方法的计算复杂性包括两部分:训练复杂性和测试复杂性。训练复杂度主要涉及本文所提出方法网络模型的训练成本,包括参数存储和每秒浮点运算(FLOPs)^[24]。对于本文方法,训练过程中一个批次(128个样本)的FLOPs是7.29 G,而整个网络

的参数存储是26.91 MB,表明本文方法对硬件要求较低,具有良好的部署能力。测试复杂性采用计算一个在线数据块的特征提取和异常检测时间来衡量,其主要成本来自于报警阈值和异常指标的计算,即 h 和 δ_i 。本文方法对一个有10个样本的在线数据块的平均检测时间是0.0021 s,远远小于连续两个数据块之间的时间间隔,表明所提出方法能够很好地满足在线早期故障检测问题的计算效率要求。

2.4 对比实验

本节引入18种早期故障检测方法和异常检测方法进行对比实验,具体方法名称见表1。其中:方法1^[25]是目前具有代表性的信号分析方法;方法2~方法7是将3种经典的异常值检测方法(LOF, SVDD和iFOREST)与两种早期故障特征(峭度和SDAE特征)进行两两组合的方法;方法8^[23]为最具有代表性的深度单分类异常检测方法;方法9^[26]为基于CNN的自监督异常检测方法;方法10和方法11为目前最新的基于深度学习的轴承在线早期故障检测方法;方法12~方法14为3种最新的深度异常检测迁移学习方法,分别使用变分自编码器(DCAE)^[27]、知识蒸馏(KD)^[28]和SSL进行预训练,然后微调Deep SVDD模型进行检测;方法15~方法18是目前最新的基于深度迁移学习的早期故障检测方法,其中方法15^[29]采用稀疏字典编码和 K 近邻算法实现跨工况故障检测,方法16^[2]采用参数微调策略实现早期故障检测,方法17^[12]将MMD距离加入SDAE网络,构建无监督深度迁移故障诊断模型,方法18^[6]采用深度自编码网络和排列熵进行在线早期故障检测。本实验采用两个评价指标^[2]:1)报警位置,即报警时的样本编号;2)误报警数,即在报警之前检测到的异常样本数。检测结果见表1。

由表1可以看出,本文方法的报警位置最早,且误报警数为零。虽然部分方法(方法16~方法18)也取得较好的检测结果,但均存在着一定数量的误报警。这是由于目标轴承的初始部分数据存在大量的不规则噪声干扰,而传统方法过度依赖于训练数据的分布特性,所提取特征对于噪声的抑制作用并不明显,因此并不适合此类在线检测问题。方法1因早期故障发生时故障信号微弱,基于故障频率的检测方法并不能有效地识别早期故障发生,需要工况信息来计算信号的故障频率,因此也不适合于未知工况的在线场景。相反,本文方法采用基于张量表示的异常检测规则迁移,能够更有效地提高在线数据的检测效果,同时规避正常状态下的噪声干扰。

表1 本文方法与17种方法的对比结果

方法类型	方法名称	报警位置	误报警数	
信号分析	1. BEMD+AMMA ^[25]	185	—	
	2. Kurtosis+ LOF	250	12	
	3. SDAE+ LOF	205	3	
	4. Kurtosis+SVDD	250	18	
	异常检测方法	5. SDAE+SVDD	180	9
		6. Kurtosis+ iFOREST	753	25
		7. SDAE+ iFOREST	367	30
		8. Deep SVDD ^[23]	253	2
		9. SSL ^[26]	885	7
同工况非迁移的	10. SDFM ^[16]	176	7	
早期故障检测方法	11. FDDA ^[5]	879	4	
	异常检测的 深度迁移学习方法	12. DCAE pre-train ^[27]	212	9
13. KD pre-train ^[28]		896	0	
14. SSL pre-train		243	5	
跨工况迁移的 早期故障检测方法	15. SRD ^[29]	873	11	
	16. OD-DTL ^[2]	162	5	
	17. DAFD ^[12]	160	18	
	18. AE-PER ^[6]	147	1	
	本文方法	146	0	

3 结论

本文针对轴承在线早期故障检测问题,提出一种无监督张量深度迁移学习方法. 该方法构建于多任务学习框架,其核心是基于张量表示的超球规则适配机制,在有效传递异常检测规则的同时提取具有良好判别性和鲁棒性的正常状态公共特征表示,进一步给出了满足期望误报警率的非参数报警阈值. 本文方法不仅有效降低了不规则噪声干扰下的误报警率,同时模型简单、可靠,人工干预少,具有较好的自适应性和易部署性,非常适合在线场景下的轴承在线早期故障检测问题.

在下一步工作中,拟研究适用于概念漂移问题的在线早期故障检测方法,重点分析网络模型对核心信息的自适应提取机制及优化策略;此外,对无标记流数据的迁移学习可能会出现负迁移现象,如何评估模型的性能上界、确定影响迁移效果的关键因素是值得探索的理论问题.

参考文献(References)

[1] Lei Y, Li N, Guo L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing,

2018, 104: 799-834.

[2] Mao W T, Ding L, Tian S Y, et al. Online detection for bearing incipient fault based on deep transfer learning[J]. Measurement, 2020, 152: 107278.

[3] Liu R N, Yang B Y, Zhang X L, et al. Time-frequency atoms-driven support vector machine method for bearings incipient fault diagnosis[J]. Mechanical Systems and Signal Processing, 2016, 75: 345-370.

[4] Kumar P S, Kumaraswamidhas L A, Laha S K. Selection of efficient degradation features for rolling element bearing prognosis using Gaussian process regression method[J]. ISA Transactions, 2021, 112: 386-401.

[5] Lu W N, Li Y P, Cheng Y, et al. Early fault detection approach with deep architectures[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(7): 1679-1689.

[6] 毛文涛, 田思雨, 窦智, 等. 一种基于深度迁移学习的滚动轴承早期故障在线检测方法[J]. 自动化学报, 2022, 48(1): 302-314.
(Mao W T, Tian S Y, Dou Z, et al. A new deep transfer learning-based online detection method of rolling bearing early fault[J]. Acta Automatica Sinica, 2022, 48(1): 302-314.)

[7] Zhu J, Chen N, Shen C. A new data-driven transferable remaining useful life prediction approach for bearing under different working conditions[J]. Mechanical Systems and Signal Processing, 2020, 139: 106602.

[8] Sun M D, Wang H, Liu P, et al. Stack autoencoder transfer learning algorithm for bearing fault diagnosis based on class separation and domain fusion[J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 3047-3058.

[9] Miao M Q, Yu J B, Zhao Z H. A sparse domain adaption network for remaining useful life prediction of rolling bearings under different working conditions[J]. Reliability Engineering & System Safety, 2022, 219: 108259.

[10] Caruana R. Multitask learning[J]. Machine Learning, 1997, 28(1): 41-75.

[11] Yang Z Y, Bozchalooi I S, Darve E. Anomaly detection with domain adaptation[J/OL]. 2020, arXiv: 2006.03689.

[12] 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.

[13] Yokota T, Erem B, Guler S, et al. Missing slice recovery for tensors using a low-rank model in embedded space[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 8251-8259.

[14] Zhou Y, Cheung Y M. Bayesian low-tubal-rank robust tensor factorization with multi-rank determination[J].

- IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(1): 62-76.
- [15] Zhao Y, Wang S, Xiao F. Pattern recognition-based chillers fault detection method using support vector data description (SVDD)[J]. Applied Energy, 2013, 112: 1041-1048.
- [16] Mao W T, Chen J X, Liang X H, et al. A new online detection approach for rolling bearing incipient fault via self-adaptive deep feature matching[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(2): 443-456.
- [17] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [18] Comon P, Luciani X, de Almeida A L F. Tensor decompositions, alternating least squares and other tales[J]. Journal of Chemometrics, 2009, 23(7/8): 393-405.
- [19] Basseville M, Nikiforov I V. Detection of abrupt changes: Theory and application[M]. Englewood Cliffs: Prentice Hall, 1993.
- [20] Chiu S N, Stoyan D, Kendall W S, et al. Stochastic geometry and its applications[M]. DOI: 10.1002/9781118658222.
- [21] Scott T C, Fee G, Grotendorst J. Asymptotic series of generalized Lambert W function[J]. ACM Communications in Computer Algebra, 2014, 47(3/4): 75-83.
- [22] Nectoux P, Gouriveau R, Medjaher K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests[C]. IEEE International Conference on Prognostics and Health Management. Denver, 2012: 1-8.
- [23] Ruff L, Vandermeulen R, Goernitz N, et al. Deep one-class classification[C]. International Conference on Machine Learning. Stockholm, 2018: 4393-4402.
- [24] Wang X D, Zheng Z D, He Y, et al. Soft person reidentification network pruning via blockwise adjacent filter decaying[J]. IEEE Transactions on Cybernetics, 2022, 52(12): 13293-13307.
- [25] Li Y B, Xu M Q, Liang X H, et al. Application of bandwidth EMD and adaptive multiscale morphology analysis for incipient fault diagnosis of rolling bearings[J]. IEEE Transactions on Industrial Electronics, 2017, 64(8): 6506-6517.
- [26] Sohn K, Li C L, Yoon J, et al. Learning and evaluating representations for deep one-class classification[J/OL]. 2020, arXiv: 2011.02578.
- [27] Zhou Y, Liang X M, Zhang W, et al. VAE-based deep SVDD for anomaly detection[J]. Neurocomputing, 2021, 453: 131-140.
- [28] Bergmann P, Fauser M, Sattlegger D, et al. Uninformed students: Student-teacher anomaly detection with discriminative latent embeddings[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 4182-4191.
- [29] 郭小萍, 刘诗洋, 李元. 基于稀疏残差距离的多工况过程故障检测方法研究[J]. 自动化学报, 2019, 45(3): 617-625.
(Guo X P, Liu S Y, Li Y. Fault detection of multi-mode processes employing sparse residual distance[J]. Acta Automatica Sinica, 2019, 45(3): 617-625.)

作者简介

毛文涛(1980—),男,教授,博士,从事机器学习、智能故障诊断等研究, E-mail: maowt@htu.edu.cn;

施华东(1997—),男,硕士生,从事机器学习、早期故障检测等研究, E-mail: shdyds@126.com;

张艳娜(1990—),女,博士,从事机器学习、信号处理等研究, E-mail: zhangyanna@htu.edu.cn;

仲志丹(1975—),男,副教授,博士,从事机器学习、智能轴承等研究, E-mail: zzd@haust.edu.cn.