

DOI: 10.19650/j.cnki.cjsi.J2412835

零故障样本下小波知识驱动的工业机器人故障检测*

黎国强¹, 魏美容², 吴德烽¹, 吴军³, 段超群⁴

(1. 集美大学轮机工程学院 厦门 361021; 2. 集美大学航海学院 厦门 361021; 3. 华中科技大学船舶与海洋工程学院 武汉 430074; 4. 上海大学机电工程与自动化学院 上海 200444)

摘要:针对零故障样本问题,现有方法大多从迁移学习、样本生成等开展研究,然而该类方法依赖相近故障样本,难以保证训练样本与真实故障信号在数据分布上保持对齐,导致模型泛化性不足。针对上述问题,提出了基于连续小波变换知识库和ViT网络的故障检测方法。采用了多种母小波函数构建连续小波变换知识库,从不同时间-频角度对机械装备监测数据进行分析;设计了一种基于多模态时-频特征的对比损失函数,实现了ViT的有效训练;开发了基于余弦相似性分析的故障检测算法,检测机械装备各类异常状态。使用工业机器人实验平台对方法进行验证。结果表明,所提方法能够在零故障样本下构建高性能的特征提取网络,并能对各类故障状态进行准确检测。

关键词: 零故障样本;连续小波变换知识库;对比损失函数;故障检测

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.40

Wavelet knowledge-driven mechanical equipment fault detection with zero-fault samples

Li Guoqiang¹, Wei Meirong², Wu Defeng¹, Wu Jun³, Duan Chaoqun⁴

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China; 2. Navigation Institute, Jimei University, Xiamen 361021, China; 3. School of Naval Architecture and Ocean Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 4. School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200444, China)

Abstract: For the zero-fault sample problem of mechanical equipment, transfer learning-based and data generation-based methods have attracted much attention. However, the methods usually require the support of similar fault samples, which makes it difficult to ensure training data is aligned with the real-world fault sample of mechanical equipment in data distribution. The generalization is insufficient in applications. To address the aforementioned problems, a novel fault detection (FD) method is proposed based on a designed new loss function and vision transformer (ViT). First, the continuous wavelet transform knowledgebase is established by combining three different mother wavelet functions, which are used to analyze the monitored signals of mechanical equipment from different time-frequency perspectives. Secondly, a new contrastive loss function is designed based on different time-frequency features and the cosine similarity analysis to effectively optimize the parameters of a constructed ViT. Finally, a fault detection algorithm is proposed to parse the real-time monitored signals of mechanical equipment to achieve the FD. The proposed FD method is evaluated by the industrial robot test rig. The results show that a deep network-based feature encoder with high-performance feature extraction can be established with zero-fault samples, and accurate fault detection for different fault conditions can also be realized.

Keywords: zero-fault sample; continuous wavelet transform knowledgebase; contrastive loss functions; fault detection

0 引言

故障检测是机械装备智能运维中的关键一环,可及时感知机械装备的运行状态,避免机械装备发生严重故障。现有故障检测方法分为两类,模型驱动与数据驱动。随着机械装备结构复杂性的增加,模型驱动的故障检测方法常面临建模困难、检测精度低等挑战。近年来,数据驱动的故障检测方法得到了广泛研究,取得了不错应用表现^[1-3]。

对于数据驱动的故障检测方法,其性能高低取决于可获得的数据规模与质量。在充足样本条件下,基于人工神经网络、支持向量机(support vector machine, SVM)、自动编码器和卷积神经网络等的故障检测方法明显优于传统方法^[4-8]。然而,工程实际中多且全的故障样本集很难构建,常面临的情形是故障数据样本极少、甚至没有,数据驱动的故障检测模型在工程实际中难以广泛应用。针对机械装备因故障样本稀少问题,已开展不少研究,He等^[9]提出了一种名为深度传递多小波自动编码器模型,通过利用迁移学习技术,在故障样本较少的情况下得到了具有高诊断精度的变速箱故障诊断模型。Wang等^[10]提出了一种基于迁移域对抗方法,在目标域故障样本数目较少,且源域故障类别少于目标域类别的条件下,构建了高性能的轴承故障诊断模型。上述方法的核心是引入了迁移学习思想,建立了一种新的数据学习范式,不仅具有深度学习在特征表示方面的优势,同时还兼具知识迁移优势^[11]。然而,迁移学习要求迁移对象与目标对象之间的监测数据具有相似性,同时又要求迁移学习后的深度网络模型对源域和目标域数据兼具良好的深度表征能力,这使得实际中深度迁移网络模型训练困难。

随着数据生成对抗技术的发展,已涌现出大量通过生成故障样本来解决深度网络模型训练数据不平衡的问题。Dai等^[12]提出了分类特征生成对抗网络模型,通过从真实故障样本中学习潜在的分类特征,接着通过结合轻微噪声来生成故障样本,弥补了机械装备故障样本稀缺的问题。Guo等^[13]提出了基于局部权重共享多新型生成对抗网络(generative adversarial network, GAN),该网络包含多组生成器,每组生成器在前几层网络采用了权重共享,用来保证生成的故障样本不发生漂移,使得生成的故障样本具有多样性。基于GAN的故障样本生成方法的关键在于能够生成与真实故障样本相近的样本,能有效缓解深度网络模型训练样本不平衡的问题。然而,工程实际中的机械装备故障发生频率很低,且无法覆盖所有的故障类型,因此常面临无真实故障样本用于生成对抗学习的情形。

零样本学习是一项公认具有重大应用价值,但亟需

突破的关键技术。零样本学习范式最早应用于计算机视觉任务和自然语言处理等领域^[14]。受到图像识别领域零样本学习启发,Chen等^[15]利用正常状态数据和实验室其他设备的故障样本,通过拼接两者之间的高维特征,实现了深度关系网络零故障样本下的有效训练,突破了对机械装备故障样本的依赖。然而,机械装备的运行状态数据具有强时序性,若历史采集的状态数据具有较强代表性,则离线训练得到的模型有较好表现,反之将存在泛化性弱,检测精度低甚至完全失效等挑战。此外,考虑到机械装备运行工况复杂多变,不同工况下的监测数据存在数据分布差异,利用离线训练过程无法提前考虑这一未知因素,导致故障检测模型在线应用时将遭受挑战。因此,符合工程应用要求的数据驱动故障检测方法不仅需要具备在零故障样本下建模的能力,还需要具备快速学习不同工况监测数据的特点,最终实现机械装备全服役周期内的高精度故障检测。

针对机械装备的故障诊断任务,现已积累了大量信号分析知识,例如振动信号的高频段多为干扰信息、低频段蕴含丰富的故障信息、时-频特征与故障状态具有高度相关性等等^[16-17]。基于此,为突破零故障样本对数据驱动方法的限制,本文结合小波变换知识,建立一种故障样本要求低的深度网络模型自主训练方式,提出机械装备零样本故障检测方法。首先,引入多种母小波函数构建连续小波变换知识库,实现对机械装备正常状态数据的多角度时-频分析;接着,设计一种基于多种时频数据高维相似度对比的损失函数,在零故障样本下实现深度网络模型的有效训练;最后,利用优化后的深度网络模型对实时监测数据进行状态表征,将其与正常状态表征进行对比分析,构建相似性检测矩阵,最终依据检测阈值,实现机械装备故障状态的及时精准检测。

本文引入多种母小波函数构建连续小波变换知识库,从不同角度解析机械装备的状态监测数据,充分揭示监测数据蕴含的时-频特征。基于机械装备连续正常状态监测数据样本,建立小波变换特征间的相似度对比矩阵。基于此,设计了一种全新的损失函数,实现了深度网络模型零故障样本下的有效训练,突破工程实际中故障样本不平衡对数据驱动方法的限制。本文提出的方法实现了连续小波变换知识与传感数据的深度融合,为如何联合先验知识与工业大数据的机械装备故障检测方法提供了一种新思路。

1 本文方法原理

1.1 连续小波变换

小波变换是一种利用可变大小窗口对信号进行时频分析的技术^[18]。相比于窗宽窄、且不能缩放的短时傅里

叶变换方法,小波基可以实现伸缩,能有效解决时域与频域分辨率不可兼得的问题。

设 $f(t)$ 为输入信号,对应的连续小波变换操作为将 $f(t)$ 与母小波函数 $\psi(t)$ 进行积分计算:

$$CWT(f(t)) = \int_{-\infty}^{+\infty} f(t) \cdot \psi(t) dt \quad (1)$$

连续小波变换是将母小波函数 ψ 卷积输入信号:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \cdot \psi(a, b, t) dt \quad (2)$$

式中: $\psi_{a,b}(t)$ 为母小波是通过缩放和移位 $\psi(t)$ 衍生获得; a 为缩放因子; b 为移位因子; $CWT(a, b)$ 表示输入信号的小波系数,是时-频矩阵中比例与位置的关系。目前,已存在多种母小波函数,它们能够从不同角度对输入信号 $f(t)$ 进行时频分析,且各自具有优势。例如,墨西哥草帽^[19](Mexican hat, mexh)函数能对输入信号的时域和频域同时进行比较好的局部化分析, mexh 函数为:

$$\psi(a, b) = -\frac{1}{\pi\sigma^4} \left(1 - \frac{a^2 + b^2}{2\sigma^2}\right) e^{-(a^2+b^2)/2\sigma^2} \quad (3)$$

复数 B 样条小波^[20](complex frequency b-spline, fbps)函数具有很好时频光滑分段特性,fbps 函数为:

$$B_{i,1}(u) = \begin{cases} 1, & u_i < u < u_{i+1} \\ 0, & \text{其他} \end{cases} \quad (4)$$

$$B_{i,k}(u) = \frac{u - u_i}{u_{i+k-1} - u_i} B_{i,k-1}(u) + \frac{u_{i+k} - u}{u_{i+k-1} - u_i} B_{i+1,k-1}(u) \quad (5)$$

高斯函数^[21](Gaussian, gaus)函数能平衡小波变换时的时间分辨率和频率分辨率, gaus 函数为:

$$\psi(t) = c \frac{d^k}{dt^k} e^{-\frac{t^2}{2}} \quad k = 1, 2, \dots, 8 \quad (6)$$

Morlet 函数^[22]在时间和频率上均具有良好的分辨率, Morlet 函数为:

$$\psi_\sigma(t) = C_\sigma \pi^{-\frac{1}{4}} e^{-\frac{1}{2}t^2} (e^{i\sigma t} - \kappa_\sigma) \quad (7)$$

1.2 Vision transformer (ViT)

Vision transformer^[23](ViT)从 transformer^[24]发展而来,能像处理自然语言序列一样对图像数据进行深度学习。ViT 包括两个关键:1)将 2-D 图像变成 1-D 序列。考虑到直接图像像素点作为元素,整个序列长度将异常的大,因此 ViT 采用对 2-D 图像进行分割的方式得到大小一致的小图像块,并将每个小图形块作为序列元素。设输入图像大小为 224×224,如将一个像素点比作一个元素,那么整个序列长度将高达 50 176,而若将一个 16×16 图像块作为一个元素,那么序列长度仅为 196,显然 ViT 可以应对这种短的序列;2) ViT 的特殊结构, ViT 是由 N 个相同的层结构组成,每层有两个子层,

第 1 层是多头自注意力机制层 (multi-head attention),用于学习特征内部的关系,第 2 层是前馈层 (feed-forward networks, FFN),用于对每个输入的向量进行相同的线性变换。两个子层采用残差进行连接,并都进行层归一化操作^[25]。多头自注意力机制为将查询对 Q 和一组键-值 K-V 对映射至输出,得到一组值的加权和,接着进行键-值的查询计算给每个值分配权重。多头注意力机制包含多组有缩放的点乘操作,用以将输入映射到不同的子表示空间,使模型可以在不同子表示空间中关注到不同的位置信息,过程如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (8)$$

式中: d_k 为 Q 与 K 矩阵的维度。矩阵 Q 与 K 的内积除以 d_k 的平方根为矩阵内积的缩放,该操作避免了由内积过大而导致的 softmax 输出落在梯度较小区域。

多头自注意力机制为:

$$\text{Multihead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{con}(h_1, \dots, h_2) \mathbf{W}^O \quad (9)$$

$$h_i = \text{Attention}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (10)$$

式中: \mathbf{W}^O 为多头注意力机制的权重矩阵。权重矩阵分别满足 $\mathbf{W}_i^Q \in \mathbf{R}^{d_{\text{model}} \times d_Q}$, $\mathbf{W}_i^K \in \mathbf{R}^{d_{\text{model}} \times d_K}$, $\mathbf{W}_i^V \in \mathbf{R}^{d_{\text{model}} \times d_V}$ 。 d_{bmodel} 为模型输出, d_Q, d_K, d_V 分别输入 Q, K, V 矩阵的维度。concat 注意力头的输出进行拼接得到最终输出。

前馈层由两个全连接层组成,各层均使用 ReLU 激活函数进行数据映射

$$\text{FFN}(x) = \max(0, x\mathbf{W}_1 + b_1) \mathbf{W}_2 + b_2 \quad (11)$$

式中: \mathbf{W}_1 与 \mathbf{W}_2 为网络权重; b_1 与 b_2 为网络权重的偏置;前馈层输入和输出维度都为 d_{bmodel} 。

考虑到机械装备绝大多数时间都运行在正常状态,很难获得足够规模的真实故障样本,构建完备的深度网络模型的训练集。为摆脱对故障样本的依赖,本文提出连续小波变换知识库和深度网络编码器联合驱动故障检测方法。优势是不依赖故障样本,只需机械装备的正常状态数据就可实现深度网络模型训练。所提方法的整体架构如图 1 所示,包含两个阶段。训练阶段如下:首先,通过滑动窗口从正常状态数据中截取样本,建立训练样本集($s_1, s_2, \dots, s_{m-1}, s_m$);接着,构建连续小波变换知识库,利用库中的不同连续小波变换操作对训练样本进行多角度的时-频解析,获得多种时-频图谱;随后,利用深度网络编码器对时-频图谱进行状态表征,基于相关性计算构建对比损失函数;最后,结合前后向传播算法,利用训练样本集($s_1, s_2, \dots, s_{m-1}, s_m$)对深度网络模型进行优化。测试阶段如下:首先,利用连续小波变换知识库对待检测在线状态数据 s_x 进行相同连续小波变换操作,输入至深度网络编码器中进行状态表征;接着,将待检测数据的表征与正常状态基准数据的表征进行相关性计

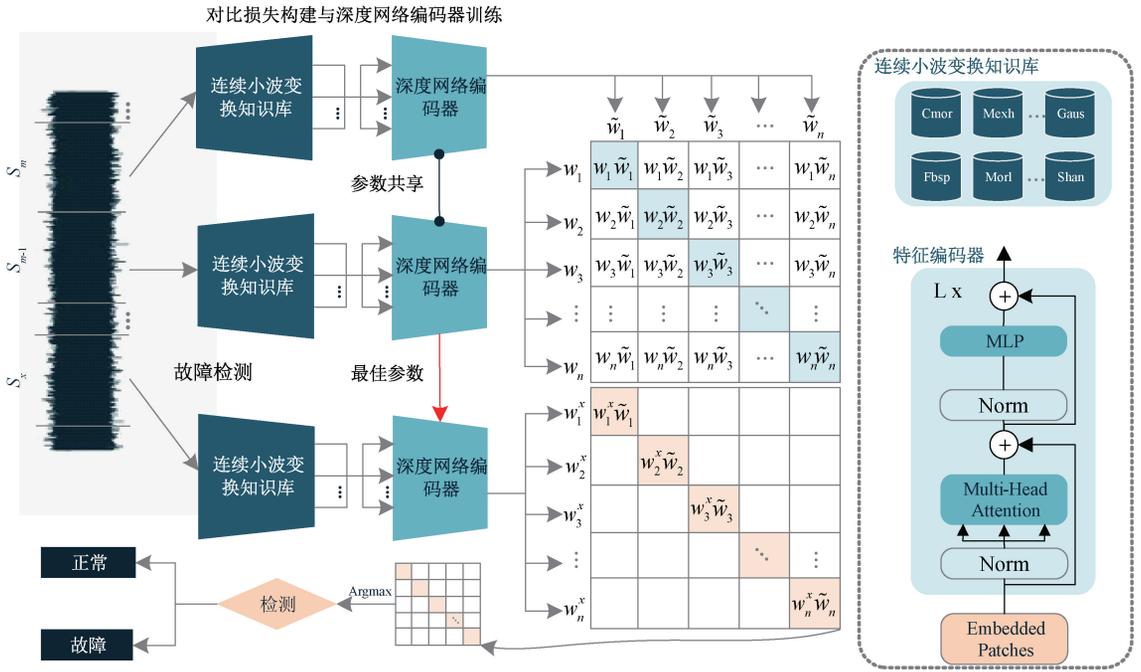


图 1 所提方法整体框架

Fig. 1 Overall framework of the proposed method

算;最后,根据预设的阈值来判别机械装备是否发生故障。

2 本文方法

2.1 对比损失函数

现有的数据驱动故障检测方法多依赖深度神经网络模型进行故障特征提取与模式识别,这类方法关键在于利用故障状态样本与正常状态样本构建二分类损失函数训练深度网络。然而,零故障样本下,只有正常状态样本,无法构建 0~1 损失函数,网络训练难以实现。目前,尚未见只利用一类样本,构建深度网络模型的方法。

考虑到机械装备实际监测数据具有强时序性的特点,相连时间窗下的监测数据具有相似性。此外,由两相连数据样本高度相似可知,两者连续小波变换后得到的时频特征也应具有相似性,而利用不同连续小波变换操作得到的时频特征具有不相关性。基于上述科学假设,本文设计了一种全新的对比损失函数。设两相连正常数据样本为 s_{m-1} 与 s_m , 同时利用连续小波变换知识库对两者分别进行连续小波变换,以获得多模态的时-频特征。

$$f_1^{m-1}, f_2^{m-1}, \dots, f_n^{m-1} = CWTK(s_{m-1}) \quad (12)$$

$$f_1^m, f_2^m, \dots, f_n^m = CWTK(s_m) \quad (13)$$

$$f_n^m = cwt_n(s_m) \quad (14)$$

$$CWTK = \{cwt_1, cwt_n, \dots, cwt_n\} \quad (15)$$

式中: $CWTK$ 为构建的连续小波变换知识库; cwt_n 为库中

连续小波变换操作; n 为连续小波变换操作数目; f 为获得的时频特征。

接着,利用深度网络编码器对模态时频特征进行状态表征,设特征编码器为 F , 进行不同时-频图谱的状态表征。

$$\tilde{w}_x = F(f_x^{m-1}) \quad x = 1, 2, \dots, n \quad (16)$$

$$w_x = F(f_x^m) \quad x = 1, 2, \dots, n \quad (17)$$

然后,利用 $(\tilde{w}_1, \tilde{w}_2, \dots, \tilde{w}_{n-1}, \tilde{w}_n)$ 与 $(w_1, w_2, \dots, w_{n-1}, w_n)$ 构建对比矩阵 M :

$$M = \begin{pmatrix} w_1 \tilde{w}_1 & \dots & w_1 \tilde{w}_n \\ \vdots & \ddots & \vdots \\ w_n \tilde{w}_1 & \dots & w_n \tilde{w}_n \end{pmatrix} \quad (18)$$

通过对 $w_x \tilde{w}_x$ 进行相关性计算,基于相似性对比结果,构建相关系数矩阵 M^{cc} :

$$M^{cc} = \begin{pmatrix} cc(w_1, \tilde{w}_1) & \dots & cc(w_1, \tilde{w}_n) \\ \vdots & \ddots & \vdots \\ cc(w_n, \tilde{w}_1) & \dots & cc(w_n, \tilde{w}_n) \end{pmatrix} \quad (19)$$

随后,基于最大相似性假设构建损失函数 $loss_1$:

$$loss_1 = \sum_{i=1}^n cc(w_i, \tilde{w}_i) \quad (20)$$

基于最小相似性假设构建损失函数 $loss_2$:

$$loss_2 = \sum_{i,j=1}^n cc(w_i, \tilde{w}_j), \quad i \neq j \quad (21)$$

由对称关系可知,当 $i = j$ 时,矩阵 M^{cc} 第 i 行中的

$cc(w_i, \tilde{w}_j)$ 在该行中应为最大, 可得:

$$T = \begin{pmatrix} 1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & 1 \end{pmatrix} \quad (22)$$

通过对 M^{cc} 各行进行 argmax 操作, 可得类似标签矩阵:

$$P = [p_1, p_2, \cdots, p_n] \quad (23)$$

$$p_x = [cc(w_x, \tilde{w}_1), \cdots, cc(w_x, \tilde{w}_n)]_{\text{argmax}}$$

因此, 通过对 P 与 T 进行交叉熵计算, 构建损失函数 $loss_3$:

$$loss_3 = \sum_m T_m \log P_m \quad (24)$$

最后, 通过结合 $loss_1, loss_2, loss_3$, 构造损失函数 $loss$:

$$loss = loss_2 - loss_1 + loss_3 \quad (25)$$

2.2 所提方法训练与测试

所提方法的训练与故障检测流程如图2所示。对于训练过程, 首先从正常状态数据样本集 $(s_1, s_2, \cdots, s_{m-1}, s_m)$ 中按序依次选择两两相连的样本对, 通过式(11)~(24) 构建损失函数 $loss$ 。接着, 利用反向梯度传播算法优化深度网络编码器, 目的是使 $loss$ 不断下降。深度网络编码器的训练算法伪代码总结如表1所示。

表1 ViT 训练算法

Table 1 ViT training algorithm

ViT 训练过程流程伪代码

设正常数据样本集为 $S = (s_1, s_2, \cdots, s_{m-1}, s_m)$, 训练样本为 (s_{i-1}, s_i) , 一共有 $\text{int}(m/2)$ 个样本;

设 $CWTK = \{cwt_1, cwt_n, \cdots, cwt_n\}$ 为连续小波变换知识库, n 为库中包含的连续小波变换操作数目;

设 θ 为深度网络编码器参数;

for epoch in range (Epoch):

for (s_{i-1}, s_i) in S :

$$f_1^{i-1}, f_2^{i-1}, \cdots, f_n^{i-1} = CWTK(s_{i-1});$$

$$f_1^i, f_2^i, \cdots, f_n^i = CWTK(s_i);$$

$$\tilde{w}_1, \tilde{w}_2, \cdots, \tilde{w}_n = \text{net}_\theta(f_1^{i-1}, f_2^{i-1}, \cdots, f_n^{i-1});$$

$$w_1, w_2, \cdots, w_n = \text{net}_\theta(f_1^i, f_2^i, \cdots, f_n^i)$$

利用式(20)、(21)、(24)、(25) 得到损失函数 $loss$;

利用反向传播算法更新 θ ;

当 $i = m$;

end for

当 epoch = Epoch 时;

end for

$$M_x^{cc} = \begin{pmatrix} cc(w_1^b, w_1^x) & \cdots & cc(w_1^b, w_n^x) \\ \vdots & \ddots & \vdots \\ cc(w_n^b, w_1^x) & \cdots & cc(w_n^b, w_n^x) \end{pmatrix} \quad (26)$$

随后, 对 M_x^{cc} 进行归一化处理, 将矩阵中的每一行元素分别映射至 $[-0.5, 0.5]$, 利用 argmax 操作获得 M_x^{cc} 每一行元素的 Hot 编码 P_x , 过程如下:

$$r_m^x = [cc(w_m^b, w_1^x), \cdots, cc(w_m^b, w_n^x)] \quad (27)$$

$$v_i = \frac{r_m^x[i] - \min(r_m^x)}{\max(r_m^x) - \min(r_m^x)} - 0.5 \quad (28)$$

$$p_m^x = [v_1^m, v_2^m, \cdots, v_n^m]_{\text{argmax}} \quad (29)$$

$$P_x = [p_1^x, \cdots, p_m^x, \cdots, p_n^x] \quad (30)$$

最后, 考虑到网络优化方向为使得 M^{cc} 在对角位置取到最大值, 而其他位置取到最小值, 因此 p_m^x 归一化后各元素之和趋近于 0。基于此, 本文设计阈值 $threshold$, 当 p_m^x 满足 $abs(\text{sum}(p_m^x)) \geq threshold$ 时, 检测结果为故障; 当 $abs(\text{sum}(p_m^x)) < threshold$, 且 $P_x = [0, 1, \cdots, n]$ 时, 则检测结果为正常状态, 否则为故障。故障检测算法总结如表2所示。

3 实验分析

3.1 试验平台

为验证本文提出方法的有效性, 采用工业机器人试验平台故障试验数据对提出方法进行验证。六关节工业机器人试验平台如图3所示, 主要由6个关节组成, 每个

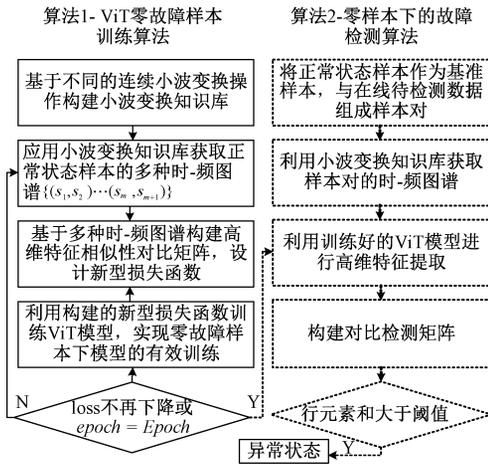


图2 所提方法训练与故障检测流程

Fig. 2 The proposed method training and fault detection process

由于 CWTK-ViT 的训练是基于两相连数据样本高度相似的假设来实施, 因此检测过程也依据这一假设来开展。将正常数据样本作为基准样本设为 S_b , 将待检测样本设为 S_x 。首先, 对 S_b 与 S_x 分别进行多种连续小波变换分别得到 $f_1^b, f_2^b, \cdots, f_n^b$ 与 $f_1^x, f_2^x, \cdots, f_n^x$ 。接着, 通过训练后的深度网络编码器分别得到 $w_1^b, w_2^b, \cdots, w_n^b$ 与 $w_1^x, w_2^x, \cdots, w_n^x$ 。随后, 基于相关性计算结果构建故障检测矩阵 M_x^{cc} 如下:

表 2 所提方法的故障检测算法

Table 2 Fault detection algorithm for the proposed method

故障检测算法伪代码

取 CWTk-ViT 训练时的最后一个样本作为基准样本 s_b , 设待检数据样本为 s_x , 设定阈值为 $threshold$;

$f^n = cwt_n(s)$; #连续小波变换

$w^n = net_g(s)$; #时频图像进行特征编码

构建异常检测矩阵 M_x ;

利用(27)得 r_m^x , 并进行归一化和计算 $abs(sum(r^x))$;

执行异常检测:

if $abs(sum(p_m^x)) \geq threshold$:

S_x 为故障样本;

else if $abs(sum(p_m^x)) < threshold$, $P_x = [0, 1, \dots, n]$;

S_x 为正常样本;

else:

S_x 为故障样本;

关节由连接轴实现关节转动。该试验平台主要用于加速模拟工业机器人退化过程。具体操作为 6 号关节处加装额定负载的 150% 重量(额定负载 20 kg), 以额定速度的 100% 进行门字形运动。一段时间后, 试验机器人出现连接轴 1 抱闸动作不正常、连接轴 2 和 3 有异响、连接轴 5 和 6 减速器油脂泄露。

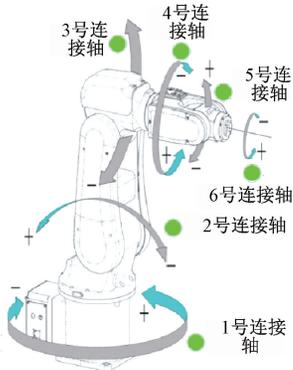
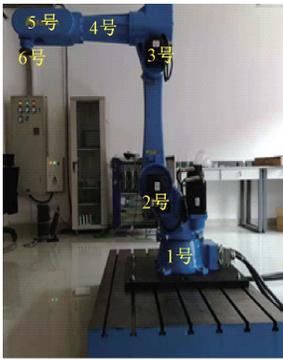


图 3 六关节工业机器人试验平台

Fig. 3 Six-joint industrial robot test bed

3.2 验证数据集

为获取单轴运行故障数据, 将退化的 1 轴、2 轴抱闸故障的伺服电机、3 轴故障减速器和 5 轴故障减速器分别进行更换, 并在单轴运行状态逐个进行故障试验。试验时采用采样频率为 10 kHz 的振动加速度传感器收集工业机器人运行状态数据。一共获得 1 组正常状态监测数据和 4 组故障状态监测数据。

工业机器人 4 种故障状态下的监测数据作为测试样本, 将正常状态下的监测数据作为训练样本。每个样本均包含 10 000 个振动数据点, 训练样本一共 1 000 个, 测试样本一共 5 000 个。验证数据集详情如表 3 所示。

表 3 验证所提方法的数据集详情

Table 3 Details of the dataset to validate the proposed method

运行状态	标签	训练/测试样本数
正常状态	正常	1 000/1 000
1 轴抱闸异响	故障 1	0/1 000
2 轴抱闸异响	故障 2	0/1 000
3 轴减速器故障	故障 3	0/1 000
5 轴减速器故障	故障 4	0/1 000

3.3 验证结果分析

考虑到输入经基于 mexh 母小波函数的连续小波变换后的时域与频域均有很好局部分辨率, 而经基于 fbsp 母小波函数的连续小波变换后不同频信息的分界上具有光滑样条。两者能分别从不同角度对训练样本的时频信息进行分析。因此, 本文选择 mexh 母小波函数与 fbsp 母小波函数组建连续小波变换知识库, 分别用于从数据样本得到时-频图谱, 输出的时-频图谱大小为 $3 \times 128 \times 128$ 。

首先, 构建基于 ViT 的深度网络编码器, 参数设置如表 4 所示。利用式(19)、(20)和(23)的损失函数优化 ViT。学习率设为 0.000 01, 训练 epochs 设为 50, 训练样本批次为 2, Threshold 初始值设为 0.2。利用训练样本优化 ViT 网络参数过程中, 各损失函数变化情况如图 4(a) 所示。结果显示训练过程中 $loss_2$ 与 $loss_3$ 明显下降, $loss_1$ 小幅度下降, 这表明构建的损失函数实现 ViT 的网络参数优化。每个训练 epoch 后所提方法的验证精度如图 4(b) 所示, 从结果可知单独使用 $loss_1$ 无法有效训练 ViT, 单独使用 $loss_2$ 与 $loss_3$ 故障检测的验证精度相差不大, 均低于 90%, 当结合 3 个损失函数时, 所提方法的验证精度得到了明显提升, 接近 100%。

表 4 ViT 参数设置

Table 4 ViT parameter setting

网络描述	参数设置
输入格式	[3, 128, 128]
Transformer 模块数	3
多注意力头数	8
输出格式	[1, 128]

为验证提出方法在零故障样本条件下的有效性, 将

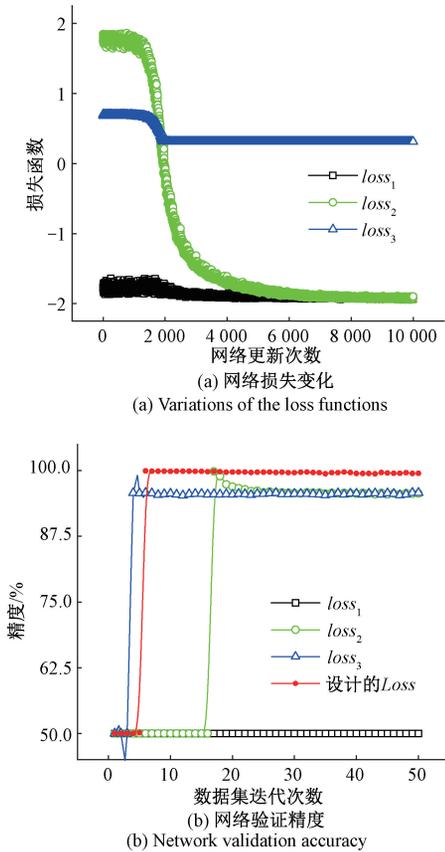


图4 设计的损失函数下 ViT 的训练结果

Fig. 4 Training results of ViT with the designed loss function

接着,验证连续小波变换知识库中连续小波变换操作数对所提方法的影响,分别选取 2 种小波母函数和 3 种小波母函数组建连续小波变换知识库。考虑到 *gaus* 函数是一种非正交与非双正交的小波函数,与基于 *mexh* 和 *fbsp* 函数的连续小波分析对训练样本的时频解析角度有所不同,*gaus* 函数可以更好地平衡时域与频域分辨率。因此,本文将基于 *gaus* 函数的连续小波变换引入至连续小波变换知识库中。为显示连续小波变换知识库中操作数对所提方法的影响,分别对 2 种连续小波变换知识库进行验证。当使用仅使用 *mexh* 小波与 *gaus* 小波时,4 000 个故障样本的 10 次检测平均精度为 94.77%;当使用 3 种连续小波变换时,4 000 个故障样本的 10 次检测平均精度为 99.26%。各类故障的 10 次检测结果如图 5 所示。从结果可知,引入第 3 种连续小波变换能进一步提升 CWTK-ViT 的故障检测性能,并能够提升故障检测的稳定性。从上述讨论可知,理论上连续小波变换知识库可通过扩充连续小波变换操作数以强化故障检测性能,然而从构建的对比损失函数可知,连续小波变换操作数的增加将会使得相关系数矩阵 M_{cc} 阶数增加,训练难度将增加。因此,在应用本文提出方法时,需

要权衡故障检测性能与模型训练消耗之间的平衡。例如,当只应用 2 种小波母函数时,正常状态样本的测试精度小于 90% 如图 5(a) 所示,因此可考虑引入新的小波母函数进一步提高所提方法性能如图 5(b) 所示。然而,扩充连续小波知识库后,所提方法将消耗更多计算资源,模型训练时间将呈指数增长,如表 5 所示。因此,建议当对正常状态数据的测试精度满意后,可停止扩充连续小波知识库。

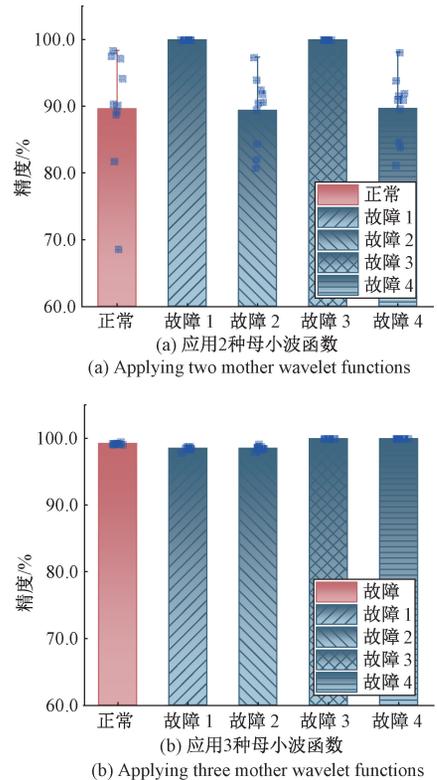


图5 2种连续小波变换知识库下所提方法 10次验证结果
Fig. 5 Ten validation results of the proposed method under two successive wavelets transform knowledge bases

表5 ViT 训练时间
Table 5 ViT training time

ViT 训练描述	训练时间/s
联合 2 种连续小波变换训练 ViT	589.5
联合 3 种连续小波变换训练 ViT	7 256.2

其次,利用 t-SNE 技术可视化正常状态样本与故障状态样本的高维特征,以证明基于本文设计的对比损失确实能够实现深度网络编码器的有效训练。正常数据样本与故障数据样本经深度网络编码器得到的高维特征可视化结果如图 6 所示。图 6(a)、(d)、(g)、(j) 表示正常状态样本与故障状态样本均采用了同一种连续小波变换操作进行时-频特征提取,图 6(a)~(c)表

示正常状态样本与一类故障状态样本采用了不同连续小波变换操作。由可视化结果可知,选取 mexh 与 fbsp 母小波函数,组建连续小波变换知识库,明显有助于区分正常状态与故障状态的测试数据样本。虽然基于 guas 函数的连续小波变换不益于检测故障 1、故障 2 与故障 4,图 6(c)、(f)、(l) 所示,但有助于检测出故障 3,如图 6(i) 所示。

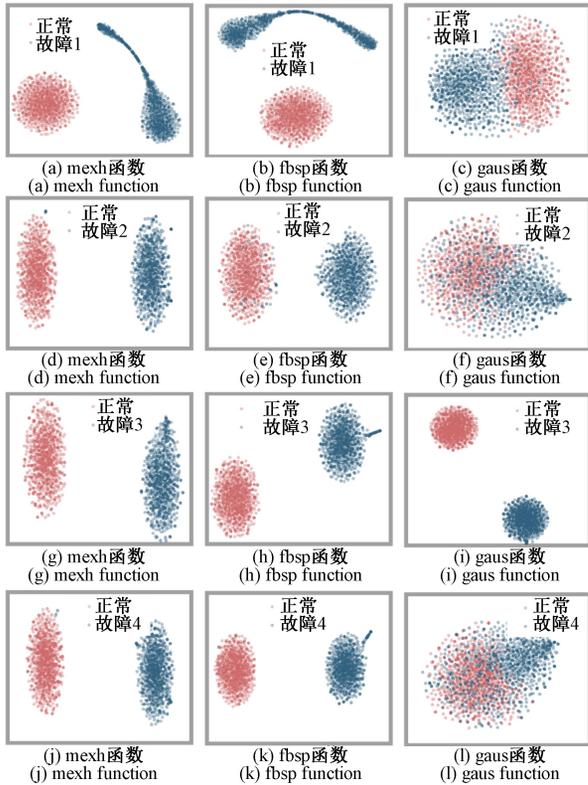


图 6 正常数据样本与故障数据样本不同小波变换后高维特征可视化

Fig. 6 Visualization of high-dimensional features after different wavelet transforms for normal and faulty samples

随后,验证检测阈值设定对所提方法的影响。由故障检测过程可知,所提方法可以通过设定检测阈值的大小来定义故障检测严苛程度,检测阈值越小表示更关注细微故障状态,检测阈值越大则表示重点关注明显的故障状态。本文检测阈值分别选取了 0.05、0.1、0.2、0.5 进行验证。在不同检测阈值下,分别对所提方法进行了 10 次验证,故障检测结果如表 6 所示。从对比结果可知,当检测阈值设的较小时,对故障状态的检测敏感度明显提升,但也容易导致正常状态误判,如检测阈值设为 0.05。当检测阈值设置的较大时,能够明显提升对正常状态的检测精度,如检测阈值设为 0.5。因此,实际应用时建议根据训练过程中相关系数矩阵的变化情况设定检

测阈值。此外,在实际中可以通过减小检测阈值,以对微弱故障状态进行检测,亦可通过增大监测阈值,以减小虚警率。

表 6 不同阈值下的检测精度对比

Table 6 Comparison of detection accuracy at different thresholds (%)

故障类型	Threshold = 0.05	Threshold = 0.1	Threshold = 0.2	Threshold = 0.5
正常状态	67.5 ± 23.3	80.5 ± 18.3	83.5 ± 14.9	94.2 ± 5.2
故障 1	100 ± 0	100 ± 0	100 ± 0	100 ± 0
故障 2	86.5 ± 8.6	83.75 ± 9.8	89.1 ± 8.3	87.15 ± 7.4
故障 3	100 ± 0	100 ± 0	100 ± 0	100 ± 0
故障 4	86.5 ± 7.7	84.0 ± 0	89.65 ± 8.4	94.06 ± 2.1

再者,对比 ViT 与其他几种流行网络的对所提方法的性能影响,分别选取 VGG16、ShuffleNet、ResNet 与 DenseNet 作为提出方法中的特征编码器,一共构建了 4 个故障检测模型。每个故障检测模型均进行 10 次验证,将正常测试样本与故障测试样本的 10 次验证结果分别与所提方法的验证结果进行对比,以本文基于 ViT 的故障检测模型的验证结果为基准,与基于其他网络的故障检测模型的验证结果作差,突出两者之间的性能差异,验证对比结果如图 7 所示。通过对结果分析,可得到以下结论:1) 所设计的损失函数均能有效优化各种网络结构使其具有故障特征提取能力;2) 零故障样本下构建的故障检测方法,能够对工业机器人某些故障进行准确检测,如基于 VGG16 的检测模型对故障 3 能够实现 100% 检测精度,对故障 1 的检测准确率为 99.92%,基于 ResNet 的检测模型对故障 1 和故障 3 的检测准确率分别为 99.96% 和 99.89%。

最后,将所提零样本故障检测方法与传统基于监督式学习的故障诊断方法进行对比。选取了 SVM、线性判别分析(linear discriminant analysis, LDA)、高斯贝叶斯网络(Gaussian Bayesian networks, GBN)和决策树(decision tree, DT)分别用于不同故障类型的检测任务,各种方法均采用监督式学习方法,即提供 1 000 个正常与 1 000 个故障样本训练得到 4 个故障检测模型,接着测试各个模型的表现。此外,利用主成分分析方法(principal component analysis, PCA)对训练样本进行降维处理,获得 2 维特征与 24 维特征,开展监督式学习建模。表 7 为各种基于监督学习的故障检测方法验证结果与本文所提方法的对比结果。从结果可知,本文提出的方法在零故障样本下,能够实现接近基于监督学习最好的故障检测模型表现,对于无法获得故障样本情形下的故障检测任务具有巨大潜在价值与意义。

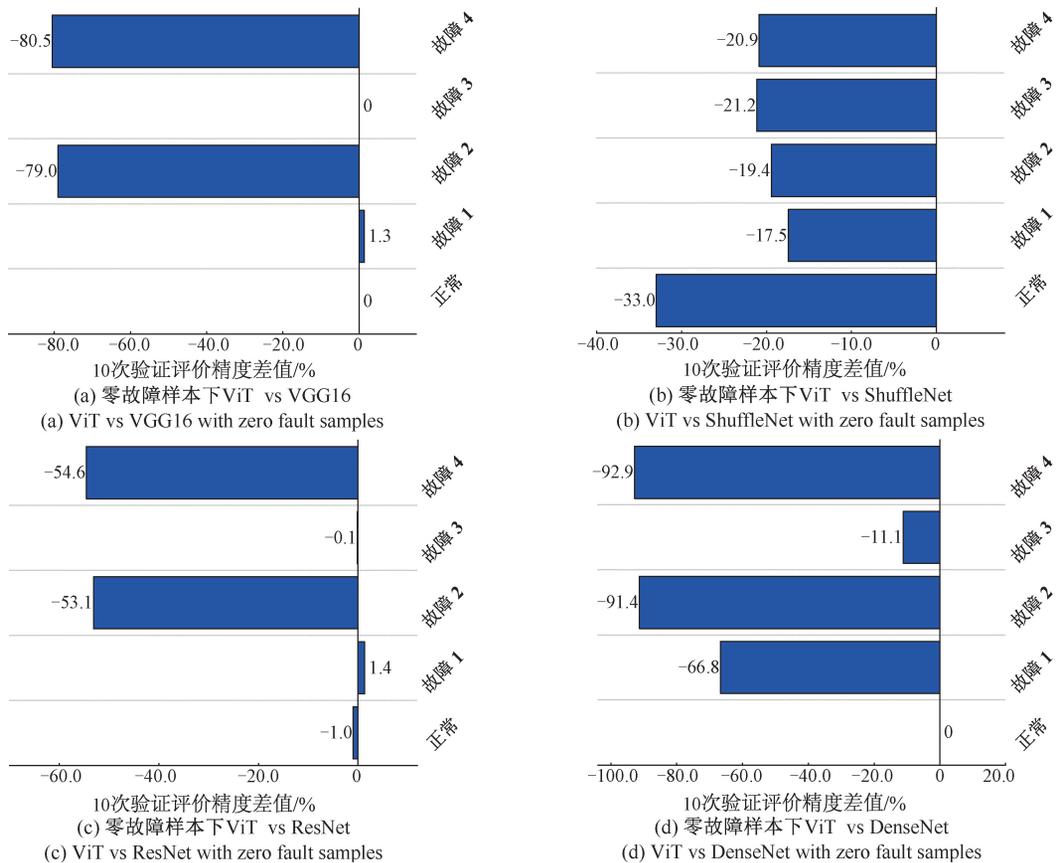


图7 与其他先进特征提取网络的性能对比

Fig. 7 Performance comparison with other state-of-the-art feature extraction networks

表7 与传统基于监督学习的故障诊断方法对比结果

Table 7 Comparison results with traditional supervised learning-based fault diagnosis methods

不同方法	训练精度/ %	测试精度/ %	FAR/ 4 000	MAR/ 4 000	训练时间/ s
本文方法	-	93.92	96	208	7 256.2
PCA(24)+SVM	100	100	0	0	0.806 2
PCA(24)+GMM	100	75.00	1 000	1 000	0.904 9
PCA(24)+LAD	100	100	0	0	0.723 4
PCA(24)+GBN	100	100	0	0	0.791 0
PCA(24)+DT	100	100	0	0	0.923 9
PCA(2)+SVM	66.61	66.53	2 671	0	0.565 0
PCA(2)+GMM	54.55	54.64	2 636	100	0.561 1
PCA(2)+LAD	74.55	72.11	1 995	41	0.482 2
PCA(2)+GNB	100	99.95	0	4	0.488 2
PCA(2)+DT	100	100	0	0	0.478 8
SVM	100	100	0	0	3.058 0
GMM	41.36	40.68	1 691	3 000	99.10
LAD	100	95.89	331	3	7.872
GBN	100	100	0	0	0.199
DT	100	99.18	31	34	6.562

4 结 论

本文提出了一种零故障样本下基于多种连续小波变换和深度网络编码器的机械装备故障检测方法,得到如下结论。

1) 根据不同连续小波变换的时频分析特点,构建了由3种连续小波变换组成的知识库,以从不同角度揭示机械装备监测数据所蕴含的时-频特征。

2) 基于正常状态数据的多种小波时-频特征设计了一种新的对比损失函数,实现了零故障样本下深度网络模型的有效训练。不同于利用迁移与生成数据训练深度网络模型的方法,本文训练得到的深度网络编码器不需要考虑迁移或生成数据对网络性能的影响,所得故障检测模型更具工程应用价值。

3) 所提出的CWTK-ViT在工业机器人试验数据集上进行了验证,结果显示CWTK-ViT对多种故障状态均能实现高精度的故障检测。

4) 实现了现有小波变换知识与数据驱动模型之间的

深度融合,为数-模联合驱动的机械装备故障诊断方法提供了新思路。

参考文献

- [1] 赵志宏,张然,刘克俭,等. 一种改进原型网络的小样本轴承故障诊断方法[J]. 振动与冲击, 2023, 42(20):214-221.
ZHAO ZH H, ZHANG R, LIU K J, et al. An improved prototype network method for small sample bearing fault diagnosis[J]. Journal of Vibration Engineering, 2023, 42(20):214-221.
- [2] 康守强,杨加伟,王玉静,等. 基于联邦多表示域适应的不同工况下滚动轴承故障诊断方法[J]. 仪器仪表学报, 2023, 44(6):165-176.
KANG SH Q, YANG J W, WANG Y J, et al. Fault diagnosis method for rolling bearings under different operating conditions based on federal multi-representation domain adaptation[J]. Chinese Journal of Scientific Instrument, 2023, 44(6):165-176.
- [3] 肖扬,王庆锋,杨哲,等. 旋转机械突发不平衡故障早期预警及诊断方法研究[J]. 机械工程学报(自然科学版), 2023, 59(11):308-318.
XIAO Y, WANG Q F, YANG ZH, et al. Research on incipient warning and diagnosis method of sudden unbalance fault for rotating machinery[J]. Chinese Journal of Mechanical Engineering (Natural Science Edition), 2023, 59(11):308-318.
- [4] LIU J, HU Y, YANG SH K. A SVM-based framework for fault detection in high-speed trains [J]. Measurement, 2021, 172: 108779.
- [5] ZHOU CH J, LI H, YANG J T, et al. Fuzzy regular least squares twin support vector machine and its application in fault diagnosis [J]. Expert Systems with Applications, 2023, 231: 120804.
- [6] JANA D, PATIL J, HERKAL S, et al. CNN and convolutional autoencoder (CAE) based real-time sensor fault detection, localization, and correction [J]. Mechanical Systems and Signal Processing, 2022, 169: 108723.
- [7] JAMIL F, VERSTRAETEN T, NOWÉ A, et al. A deep boosted transfer learning method for wind turbine gearbox fault detection[J]. Renewable Energy, 2022, 197: 331-341.
- [8] PLAKIAS S, BOUTALIS Y S. A novel information processing method based on an ensemble of auto-encoders for unsupervised fault detection [J]. Computers in Industry, 2022, 142: 103743.
- [9] HE ZH Y, SHAO H D, WANG P, et al. Deep transfer multi-wavelet auto-encoder for intelligent fault diagnosis of gearbox with few target training samples [J]. Knowledge-Based Systems, 2020, 191: 105313.
- [10] WANG ZH J, CUI J, CAI W N, et al. Partial transfer learning of multidiscriminator deep weighted adversarial network in cross-machine fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 5010010.
- [11] LI W H, HUANG R Y, LI J P, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges [J]. Mechanical Systems and Signal Processing, 2022, 167: 108487.
- [12] DAI J, WANG J, YAO L Q, et al. Categorical feature GAN for imbalanced intelligent fault diagnosis of rotating machinery [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3525212.
- [13] GUO Q W, LI Y B, LIU Y J, et al. Data augmentation for intelligent mechanical fault diagnosis based on local shared multiple-generator GAN [J]. IEEE Sensors Journal, 2022, 22(10): 9598-9609.
- [14] CHEN J Y, GENG Y X, CHEN ZH, et al. Zero-shot and few-shot learning with knowledge graphs: A comprehensive survey [J]. Proceedings of the IEEE, 2023, 111(6):653-685.
- [15] CHEN Z Y, WU K, WU J, et al. Residual shrinkage transformer relation network for intelligent fault detection of industrial robot with zero-fault samples [J]. Knowledge-Based Systems, 2023, 268: 110452.
- [16] 陈涛,屈梁生,耿中行. 小波分析及其在机械诊断中的应用 [J]. 机械工程学报(自然科学版), 1997, 33(3):76-79.
CHEN T, QU L SH, GEN ZH X. Wavelet analysis and its application to mechanical diagnosis [J]. Chinese Journal of Mechanical Engineering (Natural Science Edition), 1997, 33(3):76-79.
- [17] 侯敬宏,黄树红,申弢,等. 基于小波分析的旋转机械振动信号定量特征研究 [J]. 机械工程学报(自然科学版), 2004, 40(1):131-135.
HOU J H, HUANG SH H, SHEN T, et al. Wavelet-based quantitative analysis of vibration signal of rotary machines [J]. Chinese Journal of Mechanical Engineering (Natural Science Edition), 2004, 40(1):131-135.

- [18] BRUCE A, DONOHO D, GAO H Y. Wavelet analysis [for signal processing] [J]. IEEE Spectrum, 1996, 33(10): 26-35.
- [19] HOU T, QIN H. Continuous and discrete Mexican hat wavelet transforms on manifolds[J]. Graphical Models, 2012, 74(4): 221-232.
- [20] LIN S T, MCFADDEN P D. Gear vibration analysis by B-spline wavelet-based linear wavelet transform [J]. Mechanical Systems and Signal Processing, 1997, 11(4): 603-609.
- [21] OSOSKOV G, SHITOV A. Gaussian wavelet features and their applications for analysis of discretized signals[J]. Computer Physics Communications, 2000, 126(1/2): 149-157.
- [22] LIN J, QU L SH. Feature extraction based on morlet wavelet and its application for mechanical fault diagnosis[J]. Journal of Sound and Vibration, 2000, 234(1): 135-148.
- [23] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [J]. ArXiv preprint arXiv: 2010.11929, 2020.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30:1-11.
- [25] CHEN H T, WANG Y H, GUO T Y, et al. Pre-trained image processing transformer [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021:12294-12305.

作者简介



黎国强,2017年于大连海事大学获得学士学位,2022年于华中科技大学获得博士学位,现为集美大学讲师,主要研究方向为机械装备健康状态智能监测。
E-mail:lgq@jmu.edu.cn

Li Guoqiang received his B.Sc. degree from Dalian maritime university in 2017, and received his Ph. D.

degree from Huazhong University of Science and Technology in 2022. He is currently a lecturer at Jimei university. His main research interests include intelligent monitoring of the health status of machinery.



魏美容(通信作者),2016年于大连海事大学获得学士学位,2018年和2022年于华中科技大学获得硕士学位和博士学位,现为集美大学讲师,主要研究方向为水导激光设备作业动态仿真与可靠性分析。

E-mail:weimr@jmu.edu.cn

Wei Meirong received her B. Sc. degree from Dalian maritime university in 2016, and received her M. Sc. and Ph. D. degrees both from Huazhong University of Science and Technology in 2018 and 2022. She is currently a lecturer at Jimei University. Her main research interests include dynamic simulation and reliability analysis of water-guided laser equipment operation.



吴军,2008年于华中科技大学获得博士学位,现为华中科技大学教授,主要研究方向为装备可靠性、维修性、测试性与保障性技术。

E-mail:wuj@hust.edu.cn

Wu Jun received his Ph. D. degree from Huazhong University of Science and Technology in 2008. He is currently a professor at Huazhong University of Science and Technology. His main research interests include equipment reliability, maintainability, testing and safeguarding technologies.



段超群(通信作者),2018年于华中科技大学获得博士学位,现为上海大学副教授,主要研究方向为装备健康状态智能监测、可靠性建模与估计以及智能运维。

E-mail:chaoqun.duan@hotmail.com

Duan Chaoqun (Corresponding author) received his Ph. D. degree from Huazhong University of Science and Technology in 2018. He is currently an associate professor at Shanghai University. His main research interests include intelligent condition monitoring, reliability modeling and estimation, and intelligent operation & maintenance.