

时变小样本条件下基于对比学习的故障诊断*

乔万 刘秀丽 吴国新 黄金鹏

(北京信息科技大学现代测控技术教育部重点实验室 北京 100192)

摘要: 时变工况下的故障诊断往往具有高度动态性,而小样本下模型学习受限使得问题更加棘手。针对上述情况,提出了基于对比深度卷积网络的故障诊断方法;首先,针对数据样本量小的特点,利用速度变化引起的振动数据分布差异,无需进行人工操作自然实现数据增强;然后,在数据处理过程中,采用不同转速下相同健康状态的振动数据作为正样本,同时将不同健康状态下的振动数据作为负样本,通过比较样本之间的相似度来提取关键特征,从而缩小正样本之间的距离,同时增大负样本之间的距离;最后采用对比训练方式进行训练优化,将对比损失和交叉熵损失加权组合作为综合损失函数,使模型在学习特征表示的同时能有效进行分类任务。将该方法分别应用于两种不同时变转速下轴承故障数据集进行案例研究。试验结果表明,所提模型不仅在特征提取和分类任务中表现优异,而且在数据匮乏和时变转速工况下均能实现高准确率的故障诊断。验证了所提模型在处理时变小样本数据方面表现出较高的可行性和有效性,且优于其他先进诊断方法。

关键词: 对比学习;时变工况;小样本;深度卷积网络;故障诊断

中图分类号: TN06 **文献标识码:** A **国家标准学科分类代码:** U226.8⁺1

Fault diagnosis based on contrastive learning under time-varying small sample conditions

Qiao Wan Liu Xiuli Wu Guoxin Huang Jinpeng

(Key Laboratory of Modern Measurement and Control Technology Ministry of Education, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: In the context of time-varying operating conditions, fault diagnosis often exhibits high dynamism, while the limited model learning under small samples makes the issue more challenging. For the above situation, a fault diagnosis method based on contrastive deep convolutional networks is proposed. Firstly, considering the characteristic of small data samples, take advantage of differences in vibration data distribution caused by speed changes, and naturally realize data enhancement without manual operation. Subsequently, in the process of data processing, the vibration data of the same healthy state at different rotational speeds are used as positive samples, while the vibration data from different health states are used as negative samples. The key features are extracted by comparing the similarity between the samples so as to reduce the distance between the positive samples while increasing the distance between the negative samples. Finally, the feature extractor is trained and optimized by comparative training method, where a weighted combination of contrastive loss and cross-entropy loss is used as the composite loss function, enabling the model to effectively perform classification tasks while learning feature representations. The method is applied to two different bearing failure datasets at different time-varying rotational speeds for case studies respectively. The experimental results show that the proposed model not only performs well in the feature extraction and classification tasks, but also realizes high accuracy fault diagnosis under both data scarcity and time-varying speed conditions. It is verified that the proposed model shows high feasibility and effectiveness in dealing with time-varying small-sample data, and outperforms other advanced diagnostic methods.

Keywords: contrastive learning; time-varying operating conditions; small sample; deep convolutional neural networks; fault diagnosis

0 引言

故障诊断是现代工业中至关重要的一环,对于确保设备运行的可靠性、保障生产效率以及人员安全具有重要意义。“中国制造 2025”战略明确提出了加强工业装备智能化和故障监控与诊断的要求,旨在提高我国工业制造的水平 and 核心竞争力^[1]。因此,研究和开发高效准确的故障诊断方法对于推动工业领域的发展极其重要。

机器学习的迅猛发展引发了机械故障诊断^[2]领域的巨大变革。深度神经网络等数据挖掘模型正在成为处理大量机械监测数据^[3]的有力工具。在实际工程应用中,旋转机械通常在时变工况下运行^[4-5],导致采集到的振动信号数据随时间变化,呈现出明显的时变调制特征。这种时变调制特性容易受到噪声等干扰源的影响,从而使得对机械运行状态的准确识别变得困难。同时,复杂恶劣的工作环境导致测得的振动数据具有随机性,使得数据之间存在严重的分布差异,限制了深度学习模型的性能表现^[6]。在滚动轴承的状态检测及故障诊断技术中,时变转速工况下的故障信号复杂。传感器提取到的通常是非平稳、非线性的信号,且信息量庞大繁杂,给故障诊断增加了难度。Feng 等^[7]提出了一种通过时变振幅和频率解调谱来揭示滚动轴承时变故障特征频率的方法。Li 等^[8]提出了一种时变工况智能诊断框架和数据驱动的故障特征分离方法,去除工况特征影响的同时实现诊断。Chang 等^[9]引入基于动态选择策略的网络,通过不同尺度卷积核提取非平稳特征,实现不同速度下的故障诊断。时变转速工况下的故障诊断研究不仅对于运行在时变负载和功率下的设备具有重要意义,而且为实现设备全周期运行状态监测提供了重要的技术支持。

此外,实际运行工况下故障样本数量有限也是影响故障诊断准确率的重要因素。小样本训练会导致模型过拟合、泛化能力差、参数估计不准确等问题,并且样本代表性不足,使模型难以有效学习数据的内在规律和模式,导致模型在处理未知数据时表现不佳。为了应对这类问题,提高小样本^[10]下的故障诊断性能,目前可采用的方式主要有数据增强和模型优化。数据增强可通过数据生成模型或者人工数据增强技术来扩充故障数据量。如生成式对抗网络(generating adversarial networks, GAN)^[11]和变分自动编码器(variational auto encoder, VAE)^[12]等模型能够学习原始数据的分布,并生成与之相似的合成数据,从而增加数据集的多样性。然而,这些生成模型的训练通常需要大量的计算资源。而人工数据增强技术主要通过振动信号添加噪声、翻转时间序列、扩大局部信号等方式^[13],在不增加实际数据采集量的情况下,生成多样化的数据样本。数据增强的方式直接影响模型的性

能^[14]。考虑到小样本情况下的过拟合问题,可以采用基于模型优化的策略来提升故障诊断性能。这包括引入正则化技术、采用更复杂的网络结构,甚至进行网络集成^[15-17]。这些方法都有助于增强模型的表达能力,减少过拟合风险,从而在小样本条件下获得更好的表现。

对比学习是最具代表性的自监督学习策略,它通过手动数据增强来构建样本对,然后通过比较样本对^[18]的相似性来实现故障特征学习。由于对比学习模型是通过相似性对比而不是数据标签来训练的,所以它们可以比传统的监督学习模型^[19]更充分地利用小样本数据的价值。因此,提出了一种基于对比深度卷积模型的方法,将不同转速下相同健康状态的振动数据作为正样本,同时将不同健康状态下的振动数据作为负样本。通过比较样本间的相似度,实现了正样本之间距离的缩小和负样本之间距离的增大,并采用对比训练的方式降低模型对故障数据量的需求。实验证明,该方法在时变工况及小样本条件下具有较高的故障诊断准确率。

1 基础理论

1.1 深度卷积神经网络

深度卷积神经网络(deep convolutional neural network, DCNN)是一种基于卷积和池化操作的深度学习模型^[20],其典型结构如图 1 所示。




图 1 DCNN 结构图

Fig. 1 DCNN architecture diagram

卷积操作是 DCNN 的核心组件之一,它通过一系列的卷积核对输入时间序列进行卷积运算,提取出时间序列的特征,生成特征映射。每个卷积核与输入数据的一个局部区域进行卷积运算,并生成一个对应的特征序列。通过使用多个卷积核,卷积层能够同时提取出多个不同的特征序列,从而捕捉到序列中的多个局部特征。假设输入序列为 x_i ,卷积核为 w_i^j ,卷积操作可表示为:

$$y_{i+1}^j = x_i * w_i^j + b_i^j = \sum_m^{M-1} x_i(n+m)w_i^j(m) + b_i^j \quad (1)$$

式中: y_{i+1}^j 为第 $i+1$ 层的第 j 个卷积核的输入; $x_i(n+m)$ 为第 i 层输入序列 x_i 在位置 $n+m$ 的值; $w_i^j(m)$ 为第 i 层第 j 个卷积核在位置 m 的权重值; b_i^j 为第 i 层的第 j 个卷积核的偏置项; M 为卷积核的长度; $*$ 表示卷积运算。

池化操作位于卷积操作之后,主要用于降低特征序

列维度。通过对特征映射的局部区域进行聚合,有效减小特征映射的长度,同时保留关键信息并赋予模型平移不变性的特性,提高网络对输入序列微小变化的鲁棒性。使用最大池化(max pooling)层能够有效减少参数量、降低过拟合。在最大池化中,池化窗口会滑动地对输入序列进行扫描,每次提取窗口内的最显著特征,以此降低数据维度的同时保留关键信息。最大池化可表示为:

$$y_i = \max_{j=0}^{F-1} x_{i \times s + j} \quad (2)$$

式中: y_i 为输出的第 i 个元素; $x_{i \times s + j}$ 为输入时间序列 x 在池化窗口的内的第 $i \times s + j$ 个元素; F 为池化窗口的大小; s 为池化窗口每次移动的步长。

交替执行卷积、激活和池化操作得到的特征向量经过展平、全连接层融合和 Softmax 激活函数预测类别概率。

1.2 对比学习

对比学习框架如图2所示。每个样本对由两个时间序列组成。这些时间序列可以是来自同一类别或不同类别的数据。对于对比学习任务,同一类别的样本对应为正样本对,而不同类别的样本对为负样本对。样本对经由编码器提取特征,并通过投影空间进行转换,最后利用构建的对比损失函数进行训练和优化。




图2 对比学习框架

Fig. 2 Contrastive learning framework

假设一个样本为 $x \in \mathbf{X}$, 其所对应的正样本 x^+ 和负样本为 x^- 。可以通过定义模型获得表示函数 $f_\theta: \mathbf{X} \rightarrow \mathbf{R}^n$ 。样本通过表示函数获得特征向量 $f_\theta(x)$, 通过距离的度量函数 $D(\cdot, \cdot): \mathbf{R}^n \times \mathbf{R}^n \rightarrow \mathbf{R}$ 可以计算特征向量之间的相似性或差异性来评估样本之间的关系。对于度量函数, 可以选用欧几里得距离 $D(f_\theta(x), f_\theta(x^+))$: $\|f_\theta(x) - f_\theta(x^+)\|_2$ 来衡量样本对之间的距离, 或者可以选用内积作为距离 $\cos(f_\theta(x), f_\theta(x^+))$: $f_\theta(x) \cdot f_\theta(x^+)$, 也被称为余弦距离。式(3)和(4)是基于欧几里得距离或余弦相似度来度量特征之间的相似性, 希望样

本对的特征向量之间距离越小, 相似度越高。

距离度量公式表示为:

$$d = \sqrt{\sum_{i=1}^n (A_i - B_i)^2} \quad (3)$$

余弦相似度度量公式表示为:

$$s = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \cdot \sqrt{\sum_{i=1}^n B_i^2}} \quad (4)$$

式中: d 和 s 分别为两个 n 维特征向量之间的欧氏距离和余弦相似度; A_i 为特征向量 A 的第 i 个元素; B_i 为特征向量 B 的第 i 个元素。

对比损失基于上述度量函数的结果来引导模型的学习过程, 基本原理如式(5)所示。

$$L_{\text{ssl}} = \sum_{i=1}^N \sum_{j=1}^N \frac{1}{N_{y_i} - 1} \frac{1}{1 - \mathbb{1}_{y_i \neq y_j}} \log \left(\frac{\exp(z_i \cdot z_{j(i)} / \tau)}{\sum_{k=1}^N \mathbb{1}_{i \neq k} \exp(z_i \cdot z_k / \tau)} \right) \quad (5)$$

式中: L_{ssl} 为监督对比损失; z_i 为 Softmax 映射前的归一化输出; $z_{j(i)}$ 为 z_i 样本的同类别样本; N_{y_i} 为标签为 y_i 的样本数量; τ 为标量温度系数; z_k 为 z_i 样本的不同类别样本。 τ 用于调节相似度的尺度。通过指数和归一化操作, 公式将相似度转化为概率分布, 使得正样本对的相似度接近 1, 而负样本对的相似度接近 0。

2 基于对比深度卷积网络的故障诊断方法

基于对比学习构建对比深度卷积网络(contrastive deep convolutional neural networks, CDCNN), 利用不同健康状态的振动数据来构建正、负样本对, 通过比较样本间的欧氏距离, 实现了正样本之间距离的缩小和负样本之间距离的增大。从而提高故障诊断的准确率。

2.1 基于振动数据自然增强样本对的构建

样本对的构建需要确保正样本对和负样本对在某种程度上具有相似性或差异性, 以便模型能够学习不同故障特征之间的差异。传统的对比学习是通过数据增强的方式来构造样本对, 而选择不同数据增强的方法可以直接影响基于对比学习模型的性能^[14]。由于时变数据本身存在自然分布差异, 这种由速度变化引起的分布差异可以看作是振动数据的自然增强。因此, 从可变工作条件下收集的训练集中构造样本对, 即从同一健康状态下采集两种时变转速的振动数据作为正样本对, 而负样本对则从不同健康状态下的振动数据采集。样本对的构建方法如图3所示。

2.2 损失函数构建

对比损失函数一般以正、负样本对来构建, 用于衡量样本之间的相似性, 能有效表达成对样本的匹配程度。




图 3 构建样本对

Fig. 3 Constructing sample pairs

通过对比损失函数迫使模型将相似样本映射到特征空间中的相近位置,而将非相似样本映射到远离位置。其目的是在特征空间中增大正样本对的相似度,减小负样本对的相似度。通过这种方式,模型能够学习到更具区分性的特征表示,从而提升模型的泛化能力和鲁棒性。

对于样本对 (x_i, x_j) , 有样本对匹配标签 $y \in \{0, 1\}$, 其中 $y = 1$ 表示样本对互为正样本, $y = 0$ 表示样本对互为负样本,对比损失函数 L_{con} 为:

$$L_{con}((x_i, x_j), y) = yL_p(D(f_\theta(x_i), f_\theta(x_j))) + (1 - y)L_n(D(f_\theta(x_i), f_\theta(x_j))) \quad (6)$$

$$D(f_\theta(x_i), f_\theta(x_j)) = \|f_\theta(x_i) - f_\theta(x_j)\|_2 = \left(\sum_{i=1}^P (f_\theta^k(x_i) - f_\theta^k(x_j))^2 \right)^{\frac{1}{2}} \quad (7)$$

$$L_p(D) = \frac{1}{N} \sum_{n=1}^N D^2 \quad (8)$$

$$L_n(D) = (\max\{0, m - D\})^2 \quad (9)$$

式中: $D(\cdot, \cdot)$ 为两个特征向量的欧氏距离; P 为特征维度; $L_p(\cdot)$ 为递增函数; $L_n(\cdot)$ 为递减函数; m 为阈值,控制负样本的范围; N 为样本数量。

当样本对互为正样本时,经过模型提取后特征的欧氏距离很大,那么计算的损失会越高以增加模型的惩罚从而使损失减小;当样本对互为负样本时,经过模型提取后的特征的欧氏距离很小,那么计算的损失会越高,如果超过阈值 m 则把其损失看作 0。

交叉熵损失 L_{ce} 通常用于分类任务中,衡量了模型输出的概率分布与真实标签之间的差异。通过最小化交叉熵损失,模型能够更准确地预测样本的类别。结合对比损失和交叉熵损失的优点,使用两者的加权和损失作为综合损失函数 L_{sys} 。

$$L_{ce} = \frac{1}{N} \sum_i L_i = - \frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_\theta(x_i)_c) \quad (10)$$

$$L_{sys} = \alpha L_{ce} + (1 - \alpha) L_{con} \quad (11)$$

式中: M 为类别数量; y_{ic} 为符号函数,如果是样本 x_i 的真实类别 c 取 1,否则取 0; $p_\theta(x_i)_c$ 为观测样本 x_i 属于类别 c 的预测概率; α 为加权超参数。

通过调整 α ,充分利用样本之间的相似性信息和类别标签信息,从而达到更好地平衡学习特征和进行分类任务的目的。

2.3 网络结构

DCNN 具有强大的特征提取能力,多层卷积和池化层能够有效地学习和捕获振动数据中的局部和全局特征。通过卷积操作实现了对输入数据的局部不变性,也就意味着即使通过数据增强,DCNN 仍能识别出相同的特征,有助于在对比学习过程中关注样本对之间的关键差异。此外,DCNN 具有逐层提取特征的多层架构,有助于利用对比学习从数据中抽取更丰富的信息,更好地衡量样本之间的相似性或差异性。因此,基于 DCNN 的网络结构构建 CDCNN,通过比较两个输入样本的特征差异来进行故障诊断。表 1 为网络结构的主要组成部分。

表 1 CDCNN 的结构参数

Table 1 Structural parameters of CDCNN

网络层	通道	核尺寸	步长	输出尺寸	激活函数
Input	/	/	/	(1,4 096)	/
Convolution 1	32	64	16	(32,253)	ReLU
MaxPooling 1	/	2	2	(32,126)	/
Convolution 2	32	4	1	(32,123)	ReLU
MaxPooling 2	/	2	2	(32,61)	/
Convolution 3	64	4	1	(64,58)	ReLU
MaxPooling 3	/	2	2	(64,29)	/
Convolution 4	64	4	1	(64,26)	ReLU
MaxPooling 4	/	2	2	(64,13)	/
Convolution 5	128	4	1	(128,10)	ReLU
MaxPooling 5	/	2	2	(128,5)	/
Convolution 6	128	4	1	(128,2)	ReLU
MaxPooling 6	/	2	2	(128,1)	/
Flatten	/	/	/	(128)	/

通过卷积神经网络作为特征提取器,可以从时间序列数据中自动学习到丰富的特征表示,为后续的分类任务提供更具有判别性和泛化能力的特征表示。

基于 CDCNN 端到端故障诊断流程如图 4 所示。

1) 数据预处理。将传感器采集到的时间序列数据通过无重叠滑窗分割成子样本,对所有样本进行归一化等操作,构建正负样本对,划分训练集和测试集。

2) 模型训练和优化。利用 DCNN 作为特征提取器,将训练样本对输入,提取出对比学习所需的特征表示。利用对比损失函数计算正样本对的相似度损失和负样本对的差异度损失。使用交叉熵函数作为分类损失函数,通过梯度下降反向传播算法更新网络参数。

3) 模型验证。将测试集输入训练后的 CDCNN 模型中,根据相似度判断故障类别,得到相应的诊断结果。




图 4 故障诊断流程图

Fig. 4 Fault diagnosis flowchart

3 试验与讨论

所提出的网络在时变数据集下分别进行不同小样本量和不同模型的对比试验。此外,还进行了超参数消融试验来确定最优模型参数。

3.1 实验设置

为了能从多角度对所提模型在小样本及时变转速下的诊断效果进行评价,使用 5 种典型针对小样本及变工况的智能诊断模型进行比较。端到端长短期记忆(long short-term memory network, LSTM)^[21]在变转速的风力涡轮机数据集上有效处理时间序列数据中的长期依赖关系。卷积长短期记忆(convolutional neural network and bidirectional long short-term memory, CNN-BLSTM)^[22]在时变转速的渥太华轴承数据集上结合 CNN 和 LSTM 的优点,在提取局部时空特征的同时又捕捉长时间序列的动态变化。辅助分类器的生成对抗网络(auxiliary classifier generative adversarial networks, ACGAN)^[23]使用类别标签作为辅助信息增强 GAN 的生成能力,适用于小样本的数据增强和分类问题。基于多模块梯度惩罚生成对抗网络(gradient penalized generative adversarial networks, MGPGAN)^[24]针对小样本条件下缺乏故障信号的问题,在 GAN 基础上引入多模块梯度惩罚机制更好地模拟故障数据分布。自监督对比学习框架(a simple framework for contrastive learning of visual representations, SimCLR)^[14]通过对比学习方式来学习有用的特征表示解决样本稀缺的问题。各模型的具体结构如表 2 所示。

为了排除数据量对模型的影响,对每种健康状况的数据采用无重叠滑动窗分割随机采样构成样本,每个数据样本包含 4 096 个数据点。在所有的故障诊断实验中,

表 2 对比模型的结构参数

Table 2 Architecture parameters of the comparative models

模型名称	结构参数
端到端长短期记忆 LSTM	LSTM 隐藏层的单元数:hidden_size = 10 LSTM 层的数量:num_layers = 2
CNN 部分:	
Conv1: channels = 16; kernel = 8; stride = 2;	
Conv2: channels = 32; kernel = 3; stride = 2;	
Conv3: channels = 64; kernel = 3; stride = 2;	
Functional: elu MaxPool; kernel = 3	
LSTM 部分:	
LSTM 隐藏层的单元数:hidden_size = 64	
LSTM 层的数量:num_layers = 1	
辅助分类器的生成 对抗网络 ACGAN	生成器:一系列卷积块组成,包括批量归一化、上采样、卷积、激活函数等 判别器:一系列卷积块和分类器组成
基于多模块梯度惩罚 生成对抗网络 MGPGAN	生成器:噪声向量维度 100、5 个线性层 判别器:6 个线性层 分类器:6 层一维卷积
SimCLR	卷积层; Conv2d 编码器类型: Resnet18 3 个线性层; 节点 256、128、64

特征提取器和故障分类器训练 100 个批次,批量大小为 20,优化器为 Adam,学习率为 0.001 5,阈值 m 为 5,加权超参数 α 为 0.97,分类器的损失函数为分类交叉熵损失。另外,每组实验重复 10 次,得到平均结果进行分析。实验中使用的计算机运行在一个 64 位的 Ubuntu 系统上。计算机的 GPU 是 NVIDIA 的 GeForce RTX 3060。此外,使用 python 3.7.16 进行编程,算法运行在 Pytorch 1.11.0 的应用程序接口上进行实验。

3.2 渥太华轴承数据集

考虑到一般变速情况,选择在时变转速条件下的渥太华轴承数据集^[25]来验证所提出的方法在小样本和时变转速场景下的诊断性能。实验所用的振动数据是在一台机械故障综合模拟实验台(machinery fault simulator, MFS-PK5M),试验台设置如图 5 所示。电机驱动轴,转速由 AC 驱动器控制,安装两个 ER16K 球轴承来支撑轴,左侧为健康轴承,右侧为实验轴承,实验轴承由不同健康状况的轴承代替。编码器(EPC-775 型)用来测量轴的转速,加速度计(IPC 加速计,623C01 型)放置在实验轴承外壳用来采集振动数据。信号采样频率为 200 kHz,每次实验采样持续时间为 10 s,包括加速和减速两个过程。轴承数据集详细描述如表 3 所示。因为实验的目的是能正确诊断轴承故障,所以不考虑轴承转速的变化情况,只需要考虑轴承健康状况。




图 5 试验台设置
Fig. 5 Test bench configuration

表 3 轴承数据集信息
Table 3 Bearing dataset information

轴承状态	时变转速/(r·min ⁻¹)				标签
	加速	减速	加速后减速	减速后加速	
健康	846-1 428 1 734-822	882-1 518-1 260	1 452-888-1 236		H
内圈故障	750-1 668 1 458-594	906-1 464-1 122	1 518-888-1 164		I
外圈故障	888-1 626 1 494-588	840-1 302-870	1 569-1 134-1 470		O

1) 超参数消融试验

在机器学习领域,对于超参数的确定没有系统的参照方法,且通常不是主要讨论对象。因此,仅对模型中的主要的两个超参数进行讨论,其他参数保持不变,通过试验找到最优的故障诊断模型。从每个类别中随机采样 10 个训练样本和 200 个测试样本,每个参数分别进行 10 次试验取平均准确率作为评价指标。

图 6 展示了加权超参数 α 和批次大小对诊断结果的影响。随着加权超参数 α 和批次大小的增加,诊断准确率先提高后降低。无论 α 和批次大小如何变化,所提模

型的平均测试准确率总是高于 87%,这也表明该方法对这两个参数具有良好的鲁棒性。当 α 为 0.97、批次大小为 20 时,准确率达到最大值 95.36%,选取这组参数进行后续试验。此外,当 $\alpha = 1$ 时,即所提模型不存在对比损失而仅使用 DCNN 进行故障诊断,平均测试准确率仍有 78.41%。这体现了深度卷积作为特征提取器的强大优势;同时也侧面证明了对比学习在时变小样本工况下诊断的优越性。




图 6 不同超参数的试验结果
Fig. 6 Experimental results for different hyperparameters

2) 不同样本量对比试验

从每种健康状态下的时变数数据中分别随机采样 2、5、10、20、30 个样本作为训练样本,而测试样本则是对每种健康状态随机采样 200 个。使用准确率作为主要的评价指标,以评估模型在不同样本量下的性能变化。此外,关注了模型的过拟合情况,以确保模型在不同样本量下的泛化能力。

如图 7 展示了不同训练样本数量对模型诊断性能的影响。随着训练样本数的增加,模型的分类准确率呈上升趋势。在 2 个样本的情况下,CDCNN 的准确率为 77.82%。当样本的数量增加到 20 个,准确率提高到 97.77%。最终,在 30 个样本的情况下,该方法的准确率达到 98.75%。所提出的方法可以有效地提高时变转速下的小样本量的诊断精度。基于以上结果足以验证模型在处理时变工况方面能准确提取故障特征且具有较强的鲁棒性和适应性。

图 8 是模型在不同样本对训练后测试集的准确率的收敛情况,可以看出在 30 个样本的情况下随着训练的进行,准确率开始稳步上升。当训练达到 40 次时,测试集上的准确率趋于稳定,并在后续的训练中保持在一个相对稳定的水平。进一步说明模型在复杂的时变工况下依然能够快速学习并保持稳定的诊断性能。




图 7 不同样本量下的诊断准确率及性能指标

Fig. 7 Diagnostic accuracy and performance metrics with different sample size

为了进一步分析所提模型在不同训练样本数量下对





图 9 不同样本量下诊断结果的混淆矩阵

Fig. 9 Confusion matrix for different sample sizes in diagnostic results

3) 不同模型对比试验

每个模型均使用相同的训练集和测试集,每个类别中都有个 30 个训练样本。在实验中,首先训练了每个模型使用相同的训练数据量。然后,使用测试集来评估模型在小样本情况下的性能。图 10 结果显示,CDCNN 在这个小样本故障诊断任务中表现出色,达到了 98.63% 的准确率。SimCLR 的诊断效果相比 CDCNN 稍显逊色,准确率为 98.15%。由于训练数据的数量非常有限且受速度波动的影响,因此 LSTM 在此任务中表现较差,模型无法充分捕捉数据特征,导致泛化性能不佳,只达到了 62.50% 的准确率。而 CNNBLSTM 相较 LSTM 的效果更优,这足以验证卷积作为特征提取方法的优越性。而专门针对小样本诊断问题的 ACGAN 和 MGPGAN 的效果不如 CDCNN,原因可能是速度波动影响了振动信号的频



每个类别的预测能力,对某次测试结果进行了混淆矩阵分析,如图 9 所示。随着样本量的增加,模型的分类准确率逐步提高。当样本数为 30 时,模型能够有效区分各类健康状态数据,整体诊断准确率达到近 99%。因此,所提网络在小样本故障诊断任务中的性能受到样本量的显著影响。这表明了在小样本情况下样本量的重要性。

率、振幅和周期性特征,增加了故障诊断的难度。此外,SimCLR 在训练中需对一维输入信号二维化后进行比较而导致训练时间更长。相比之下,CDCNN 网络的训练时间则更短。

为了更直观地观察所提模型在时变转速下的样本在低维空间中的分布情况,对测试集的原始数据特征及网络结构的输出特征利用 t -分布随机邻域嵌入 (t -distributed stochastic neighbor embedding, t -SNE) 技术在二维空间中可视化。如图 11 所示,可以看出,原始振动数据的分布重叠严重,难以区分不同故障;经过模型提取的特征呈现类内聚集、类间分离的趋势,3 个类别样本在图中形成了 3 个紧密的群集,这表明在二维空间中它们在一定程度上是可分的。然而,类别为 I 的样本则分布得相对分散,这可能意味着该样本在特征空间中的差异性较大。




图 10 对比模型的诊断准确率

Fig. 10 The diagnostic accuracy of the comparative models




图 11 CDCNN 测试集的 T-SNE

Fig. 11 T-SNE of the CDCNN test set

综上所述,尽管样本量有限,CDCNN 在小样本故障诊断任务中取得了最佳的准确率,而 SimCLR 网络在保持合理训练时间的情况下也表现不错。LSTM 则在这个任务中表现不尽人意,这些结果可能受限于样本量的大小、模型架构和参数的选择。

3.3 Spectra Quest 时变转速数据集

为了进一步验证所提模型在时变转速及小样本情况下故障诊断的有效性,采用西安交通大学的 Spectra Quest 时变转速数据集^[26-27]进行试验。试验台由电机、转子和

负载组成,实验采用压电式加速度传感器采集电机轴承信号,所用的数据采集仪为 CoCo80,采样频率为 25.6 kHz,电机轴承型号为 NSK6203。故障轴承通过机械加工人为制造 4 mm² 的损伤面积和 0.5 mm 的损伤深度(基于二代小波包分析和冲击脉冲法的轴承故障)。收集了内圈故障(I)、外圈故障(O)和健康状态(H)轴承的振动信号。每次实验采集时长为 15 s,包含一个完整的从静止状态逐渐加速至 3 000 rpm,再保持稳定,最后逐渐减速为 0 的加减速过程。图 12 展示了 3 种轴承状态的振动信号波形图和对应的转速变化曲线图。

1) 不同样本量对比试验

该小节实验与 Ottawa 的小样本实验设置一致,只为进一步验证所提模型在小样本情况下故障诊断的有效性。

表 4 给出了不同训练样本量下的 10 次平均测试准确率。由表可知,随着训练样本数的增加,模型分类准确率依旧呈上升趋势。当每个类别仅有 2 个训练样本时,由于训练样本量不足而导致训练样本所覆盖的转速范围有限,同时该数据集涵盖启停阶段的全周期速度变化使诊断难度加大,从而影响了诊断的准确性。但当每个类别有 30 个训练样本时,准确率则达到了 88.58%,进一步验证了所提模型能在有限的训练样本和时变转速下具有良好的诊断性能。

表 4 不同训练样本数量下的诊断结果

Table 4 Diagnosis results with different training samples

训练样本量/对	2	5	10	20	30
平均准确率/%	60.67	65.73	72.63	82.03	88.58

如图 13 所示,从混淆矩阵可以看出所提模型对轴承外圈故障(O)的识别能力相对较弱,而对于识别健康状态(H)的效果最佳。随着训练样本逐渐增多,模型的泛化性能和预测性能显著提高,但依然存在部分样本未被正确识别的情况。这说明速度波动引起的频率变化和噪声增加会掩盖故障特征信号,同时导致数据分布域的偏离,从而干扰故障识别并影响诊断的准确性。当训练样本数由 2 个逐渐提升为 30 个时,模型对于外圈故障的识别能力大幅提升,也进一步说明样本量这一因素对于模型诊断准确率的影响最为重要。

2) 不同模型对比试验

该小节实验与 Ottawa 的对比方法实验设置一致,只为进一步验证所提模型的优越性。

如表 5 所示,在有限的数量和时变转速下,所提模型的准确率最高。LSTM 的诊断效果最差,可能是小样本导致数据的关键特征未被准确提取,速度波动大使得数据分布差异更大,从而影响对故障的识别能力。




图 12 轴承振动信号波形图和对应的转速变化曲线

Fig. 12 Bearing vibration signal waveform and corresponding speed change curve




图 13 不同样本量下诊断结果的混淆矩阵

Fig. 13 Confusion matrix for different sample sizes in diagnostic results

CNNBLSTM 相比 LSTM 的准确率更高,诊断时间更短,说明 CNN 具有强大特征提取能力,但相比所提模型依旧无法达到优越的诊断效果。针对小样本诊断问题的 ACGAN 和 MGPGAN 的准确率也只有 75%左右。可能是速度波动幅度较大导致振动信号呈现多尺度复杂性以致

于训练数据不够多样化;其次就是小样本会使生成器无法捕捉到数据的真实分布,导致生成数据质量较低且缺乏多样性。此外,基于对比学习的 SimCLR 的诊断准确率只有 73.34%,且其诊断时间远大于所提模型。

表 5 对比模型的诊断准确率

模型	LSTM	CNNBLSTM	ACGAN	MGPGAN	SimCLR	CDCNN
平均准确率/%	54.67	70.93	76.59	74.43	77.34	88.58
诊断时间	36 s 503 ms	3 s 865 ms	20 s 218 ms	9 m 33 s 648 ms	4 m 33 s 580 ms	12 s 275 ms

如图 14 的 T-SNE 所示,所提模型的特征提取能力较强,能够有效区分 3 种类别。其中有少量数据出现混叠,

可能是时变的转速使振动信号具有复杂的动态特征导致故障特征被淹没。但整体呈现类内聚集、类间分离的趋

势,也进一步证明了所提模型在时变转速下具有良好的泛化性。




图 14 CDCNN 测试集的 T-SNE

Fig. 14 T-SNE of the CDCNN test set

4 结 论

结合对比学习善于捕捉关键特征的优势及深度卷积神经网络强大学习能力的优势,提出了一种对比深度卷积神经网络 CDCNN,在时变工况和小样本条件下验证了其有效性,实现了旋转机械关键部件健康状态的准确识别。首先,充分利用了速度变化引起的振动数据的自然分布差异,通过对比损失函数,缩小了正样本间距离、增大了负样本间距离,避免了繁琐的人工数据增强;其次,引入深度卷积神经网络特征提取器,成功优化振动数据表示,通过对比训练方式,降低了模型对故障数据量的需求;最后,在时变转速的渥太华轴承数据集和西安交通大学的 Spectra Quest 数据集上验证了该方法能从较少的样本中提取关键特征,区分不同故障类别间的差异,进而对故障做出准确的诊断。未来,课题组将聚焦于噪声环境等复杂故障场景分析、模型性能优化及实际工程应用验证。

参考文献

- [1] 周济. 智能制造——“中国制造 2025”的主攻方向[J]. 中国机械工程, 2015, 26(17): 2273-2284.
ZHOU J. Intelligent manufacturing—main direction of “made in china 2025” [J]. China Mechanical Engineering, 2015, 26(17): 2273-2284.
- [2] PAN T, CHEN J. A novel deep learning network via multiscale inner product with locally connected feature extraction for intelligent fault detection [J]. IEEE Transactions on Industrial Informatics, 2019, 15(9): 5119-5128.
- [3] PAN J, ZI Y Y, CHEN J L, et al. LiftingNet: A novel deep learning network with layerwise feature learning from

- noisy mechanical data for fault classification [J]. IEEE Transactions on Industrial Electronics, 2018, 65(6): 4973-4982.
- [4] 林京, 赵明. 变转速下机械设备动态信号分析方法的回顾与展望[J]. 中国科学: 技术科学, 2015, 45: 669-686.
LIN J, ZHAO M. Dynamic signal analysis for speed-varying machinery: a review [J]. Scientia Sinica (Technologica), 2015, 45: 669-686.
- [5] 桂勇, 韩勤锴, 李峥, 等. 变速行星齿轮系统故障诊断方法[J]. 振动. 测试与诊断, 2016, 36(2): 220-226, 396.
GUI Y, HAN Q K, LI ZH, et al. Fault diagnosis of planetary gear system undertime-varying speed conditions [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(2): 220-226, 396.
- [6] LI C, ZHANG S, QIN Y, et al. A systematic review of deep transfer learning for machinery fault diagnosis [J]. Neurocomputing, 2020, 407: 121-135.
- [7] FENG Z, CHEN X, WANG T. Time-varying demodulation analysis for rolling bearing fault diagnosis under variable speed conditions [J]. Journal of Sound and Vibration, 2017, 400: 71-85.
- [8] LI S, AN Z, LU J. A novel data-driven fault feature separation method and its application on intelligent fault diagnosis under variable working conditions [J]. IEEE Access, 2020, 8: 113702-113712.
- [9] CHANG Y H, CHEN J, CHNE Q, et al. CFs-focused intelligent diagnosis scheme via alternative kernels networks with soft squeeze-and-excitation attention for fast-precise fault detection under slow & sharp speed variations [J]. Knowledge-Based Systems, 2022, 239: 108026.
- [10] ZHANG T C, CHEN J, LI F D, et al. Intelligent fault diagnosis of machines with small & imbalanced data: a state-of-the-art review and possible extensions [J]. ISA Transactions, 2022, 119(1): 152-171.
- [11] DIXIT S, VERMA N K, GHOSH A K, et al. Intelligent fault diagnosis of rotary machines: Conditional auxiliary classifier GAN coupled with meta learning using limited data [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [12] DIXIT S, VERMA N K. Intelligent condition-based monitoring of rotary machines with few samples [J]. IEEE Sensors Journal, 2020, 20(23): 14337-14346.
- [13] 李巍华, 何琛, 陈祝云, 等. 基于对称式对比学习的齿轮箱无监督故障诊断方法[J]. 仪器仪表学报, 2022, 43(3): 121-131.

- LI W H, HE CH, CHE ZH Y, et al. Unsupervised fault diagnosis of gearbox based on symmetrical contrast learning[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 121-131.
- [14] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations[C]. ICML'20: Proceedings of the 37th International Conference on Machine Learning, 2020, (149): 1597-1607.
- [15] SAUFI MS RBM, BINAZA, LEONG M S, et al. Gearbox fault diagnosis using a deep learning model with limited data sample [J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6263-6271.
- [16] ZHAO B, ZHANG X, LI H, et al. Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions [J]. Knowledge-Based Systems, 2020, 199(8): 16.
- [17] ZHAO X, JIA M, LIN M. Deep laplacian auto-encoder and its application into imbalanced fault diagnosis of rotating machinery[J]. Measurement, 2020, 152: 21.
- [18] LIU X, ZHANG F, HOU Z, et al. Self-supervised learning: Generative or contrastive [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(1): 857-876.
- [19] LE-KHAC P H, HEALY G, SMEATON A F. Contrastive representation learning: A framework and review[J]. IEEE Access, 2020, 8: 193907-193934.
- [20] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [21] LEI J, LIU C, JIANG D. Fault diagnosis of wind turbine based on long short-term memory networks [J]. Renewable Energy, 2019, 133: 422-432.
- [22] YOU D Z, CHEN L B, LIU F, et al. Intelligent fault diagnosis of bearing based on convolutional neural network and bidirectional long short-term memory [J]. Shock and Vibration, 2021: 1-12.
- [23] SHAO S, WANG P, YAN R. Generative adversarial networks for data augmentation in machine fault diagnosis [J]. Computers in Industry, 2019, 106: 85-93.
- [24] ZHANG T, CHEN J, LI F, et al. A small sample focused intelligent fault diagnosis scheme of machines via multimodules learning with gradient penalized generative adversarial networks[J]. IEEE Transactions on Industrial Electronics, 2021, 68(10): 10130-10141.
- [25] HUANG H, BADDOUR N. Bearing vibration data collected under time-varying rotational speed conditions[J]. Data in Brief, 2018, 21: 1745-1749.
- [26] LIU S, CHEN J L, HE SH L, et al. Subspace network with shared representation learning for intelligent fault diagnosis of machine under speed transient conditions with few samples[J]. ISA Transactions, 2022, 128: 531-544.
- [27] SHI Z, CHEN J, ZI Y, et al. A novel multitask adversarial network via redundant lifting for multicomponent intelligent fault detection under sharp speed variation[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.

作者简介



乔万, 2021 年于辽宁科技大学机械工程学院获得学士学位, 现为北京信息科技大学现代测控技术教育部重点实验室在读硕士研究生, 主要研究方向为基于深度学习的机电装备故障诊断与健康管理的。

E-mail: 993409074@qq.com

Qiao Wan received his B. Sc. degree from Mechanical Engineering College of University Science and Technology Liaoning in 2021. Now he is a M. Sc. candidate in the Key Laboratory of Modern Measurement and Control Technology of the Ministry of Education, Beijing Information Science and Technology University. His main research interests include deep learning-based fault diagnosis and health management of electromechanical equipment.



刘秀丽 (通信作者), 2016 年于北京理工大学获得博士学位。现为北京信息科技大学现代测控技术教育部重点实验室副研究员, 硕士生导师, 主要研究方向为可解释深度学习、机电装备健康管理。

E-mail: liuxiuliw@163.com

Liu Xiuli (Corresponding author), received her Ph. D. degree from Beijing Institute of Technology in 2016. Now she is an associate researcher and master's tutor in the Key Laboratory of Modern Measurement and Control Technology of the Ministry of Education, Beijing Information Science and Technology University. Her main research interests include interpretable deep learning and electromechanical equipment health management.