

DOI:10.3969/j.issn.1001-4551.2023.03.002

# 基于 1D-DCGAN 和 1D-CAE 的小样本 轴承故障跨域诊断方法 \*

林 培<sup>1</sup>, 许杨剑<sup>1</sup>, 傅军平<sup>2</sup>, 陈栋栋<sup>2</sup>, 鞠晓喆<sup>1</sup>, 梁利华<sup>1\*</sup>

(1. 浙江工业大学 机械工程学院,浙江 杭州 310014;2. 浙江省特种设备科学研究院,浙江 杭州 310020)

**摘要:**充足的故障样本是基于深度学习的故障诊断方法取得良好效果的保证。然而,数据不平衡是工业大数据的典型特征。为了减小智能诊断方法对样本数量的依赖,同时为了解决小样本下同种设备以及不同设备间的故障诊断问题,提出了一种基于一维卷积生成对抗网络(1D-DCGAN)与一维卷积自编码器(1D-CAE)的轴承故障诊断方法。首先,利用一维卷积层构建了1D-DCGAN网络,凭借其强大的数据生成能力扩充了故障数据集;然后,利用一维卷积层构建了1D-CAE网络,通过无监督学习的方式,有效地提取出了故障样本中的潜在特征,实现了对设备的故障诊断功能;基于迁移学习思想,通过对1D-CAE模型参数进行迁移,进一步地对小样本下的轴承故障进行了跨域诊断;最后,为验证基于1D-DCGAN和1D-CAE的轴承故障诊断方法的效果,采用了美国凯斯西储大学(CWRU)以及西安交通大学(XJTU)轴承数据集进行了实验。实验结果表明:基于1D-DCGAN和1D-CAE的方法明显优于其他对比模型,同种设备的故障识别精度达到了99.21%,不同设备之间的跨域故障识别精度达到了98.87%。研究结果表明:即使在样本数量较少的场景下,基于1D-DCGAN和1D-CAE的方法也能进行同种设备的故障诊断以及不同设备之间的跨域诊断。

**关键词:**旋转机械故障诊断;一维卷积生成对抗网络;一维卷积自编码器;迁移学习;深度学习;样本数量

中图分类号:TH133.3;TP183

文献标识码:A

文章编号:1001-4551(2023)03-0326-09

## Cross domain diagnosis method for bearing faults with small samples based on 1D-DCGAN and 1D-CAE

LIN Pei<sup>1</sup>, XU Yang-jian<sup>1</sup>, FU Jun-ping<sup>2</sup>, CHEN Dong-dong<sup>2</sup>, JU Xiao-zhe<sup>1</sup>, LIANG Li hua<sup>1</sup>

(1. College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

2. Zhejiang Academy of Special Equipment Science, Hangzhou 310020, China)

**Abstract:** Sufficient fault samples are the guarantee for the fault diagnosis method based on deep learning to achieve good results. However, data imbalance is a typical feature of industrial big data. In order to reduce the dependence of intelligent diagnosis methods on the number of samples, and to solve the problem of fault diagnosis between the same device and different devices under small samples, a fault diagnosis method combining one-dimensional convolutional generative adversarial network (1D-DCGAN) and one-dimensional convolutional auto-encoder (1D-CAE) was proposed. Firstly, a 1D-DCGAN network was constructed by one-dimensional convolution layer, and the fault data set was expanded by its powerful data generation capability. Secondly, the 1D-CAE network was constructed by using the one-dimensional convolutional layer, and the potential features in the fault samples were effectively extracted by unsupervised learning to realize the fault diagnosis of the equipment. Based on the idea of transfer learning, the parameters of 1D-CAE model were transferred to further realize cross-domain diagnosis under limited samples. Finally, in order to verify the effectiveness of the proposed method, the bearing datasets of Case Western Reserve University (CWRU) and Xi'an Jiaotong University (XJTU) were used for the experiment. The experimental results show that the proposed method is superior to other comparative model, the fault identification accuracy of same device reached 99.21%, the cross

收稿日期:2022-08-18

基金项目:浙江省重点研发计划资助项目(2019C01SAB51402)

作者简介:林培(1995-),男,安徽六安人,硕士研究生,主要从事机械设备故障诊断方面的研究。E-mail:lin842765694@163.com

通信联系人:梁利华,男,博士,教授,博士生导师。E-mail:lianglihua@zjut.edu.cn

domain fault identification accuracy between different equipments reach 98.87%. The results show that, even in the proposed procedure under the scenario of less sample size, the method based on 1D-DCGAN and 1D-CAE can effectively achieve the same equipment fault diagnosis and the cross-domain diagnosis between different devices.

**Key words:** fault diagnosis of rotating machinery; one-dimensional convolutional generative adversarial network (1D-DCGAN); one-dimensional convolutional auto-encoder (1D-CAE); transfer learning; deep learning; sample size

## 0 引言

近年来,随着先进传感技术、工业大数据技术以及人工智能技术的不断发展,深度学习被广泛地应用于机械设备的故障诊断当中<sup>[1]</sup>。

李恒等人<sup>[2]</sup>利用卷积神经网络构建了故障诊断模型,并以加速度信号的时频谱作为输入数据,实现了对滚动轴承进行故障诊断的目的。AI Shao-jie 等人<sup>[3]</sup>将小波变换与时域卷积神经网络相结合,利用遗传算法优化了原有的故障诊断模型的参数,实现了对高超声速飞行器传感器故障进行实时诊断的目的。卞景艺等人<sup>[4]</sup>利用多个一维卷积层,提取了振动信号不同尺度的特征,实现了对设备进行故障诊断的目的,并利用轴承故障数据集和行星齿轮故障数据,对该方法进行了验证,取得了较好的诊断效果。

充足的故障样本是基于深度学习的故障诊断方法取得良好性能的保证。然而,数据不平衡又是工业大数据的典型特征。因此,为了解决故障样本获取较为困难的问题,研究人员们做了大量研究。

向家伟<sup>[5]</sup>以齿轮、轴承、转子系统等典型机械传动系统为例,建立了上述传动系统故障状态的有限元模型,通过动力学仿真,生成其故障加速度信号,并将其用于训练智能诊断模型。BAI Ming-liang 等人<sup>[6]</sup>利用卷积神经网络,构建了燃气轮机的故障诊断模型,通过对不同燃气轮机间的故障知识进行迁移,在一定程度上解决了训练数据缺乏的问题。YANG Dao-guo<sup>[7]</sup>和 KE Zhao<sup>[8]</sup>利用自编码器强大的特征提取能力,凭借有限的故障样本,构建起了相关机械设备的故障诊断模型。

此外,GOODFELLOW I J 等人<sup>[9]2673-2680</sup>在 2014 年提出了生成对抗网络(generative adversarial network, GAN),并证明了其在数据生成方面具有强大的能力。现如今,GAN 已经在图像识别领域大放异彩<sup>[10-12]</sup>,甚至一些学者已经开始尝试将 GAN 应用于故障诊断领域。

徐林等人<sup>[13]</sup>构建了半监督生成对抗网络,将振动信号的时频图作为模型的输入数据,实现了对轴承故障进行分类目的。为了解决数据种类不平衡场景下故

障诊断不精确的问题,ZHOU Yue 等人<sup>[14]</sup>采用生成对抗网络生成了样本,实现了故障样本数据增强目的;同时,为了提高生成样本的质量,ZHOU Yue 等人还采用了高斯判别器替换原有的全连接判别器。WANG Bing 等人<sup>[15]</sup>对生成对抗网络进行了改进,使其能够生成更多样化的样本,并结合自编码器和隐马尔可夫模型,成功地对电焊质量进行了判断。

尽管 GAN 在数据生成方面具有强大的能力,但其在训练过程中容易出现训练不稳定、样本生成质量较差等问题。因此,如何让 GAN 学习到真实数据的分布规律,并且生成高质量的样本,一直是其是否能够得到广泛应用的关键。

作为当前人工智能研究的热点问题,迁移学习旨在利用现有知识解决相似但不同的问题。近几年来,迁移学习逐渐引起了智能诊断领域学者们的关注<sup>[16,17]</sup>;同时,小样本的跨域诊断成为解决故障样本不充足问题的一种途径。然而,当前的研究大多只考虑了同种设备、不同工况的跨域诊断,没有涉及不同设备间的跨域诊断。

针对现有方法存在的不足,笔者提出一种基于一维卷积生成对抗网络和一维卷积自编码器的故障诊断方法。

该方法利用一维卷积生成对抗网络学习故障样本的分布规律,通过生成故障样本的方式,扩充故障数据集;并利用一维卷积自编码器提取故障样本的潜在特征,进行故障诊断;同时,通过对一维卷积自编码器模型参数的迁移,实现对小样本下不同设备间进行跨域诊断目的。

## 1 相关理论

### 1.1 卷积生成对抗网络

GAN 是 GOODFELLOW I J<sup>[9]2674</sup> 提出的一种生成模型。它由生成器 G 和判别器 D 组成。其中,生成器 G 尽可能地生成接近真实样本分布的样本,判别器 D 尽可能区分真实的样本和生成的样本,二者对抗学习,不断提升;最终,生成器 G 将学到真实样本的分布。

GAN 的训练过程可以看成是一个极小极大化的问题,其目标函数为:

$$V(G, D) = \min_{G} \max_{D} E_{x \sim P_{\text{data}}} [\log(D(x))] + E_{z \sim P_z} [\log(1 - D(G(z)))] \quad (1)$$

式中: $E$ —期望; $P_{\text{data}}$ —真实样本  $x$  的概率分布; $P_z$ —随机向量  $z$  的先验分布,如高斯分布等。

为了解决 GAN 训练不稳定的问题,ALEG R<sup>[18]</sup> 提出了深度卷积生成对抗网络 (deep convolutional generative adversarial Networks, DCGAN),并在生成器和判别器中使用了批量标准化,提升了模型的稳定性,降低了模型崩溃的几率。

## 1.2 自编码器

自编码器是一种无监督学习模型。它由输入层、隐含层和输出层组成。它通过对原始输入数据进行重构,提取输入数据的潜在特征。

典型的自编码器由全连接网络构成,其结构如图 1 所示。

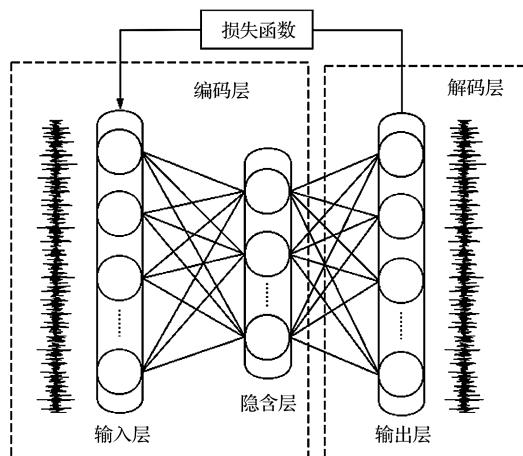


图 1 典型自编码器结构

假设自编码器的输入数据为  $\mathbf{x} = \{x_1, x_2, x_3 \dots x_m\}$ ,则网络的编码阶段可以表示为:

$$\mathbf{h} = f(\mathbf{w}\mathbf{x} + \mathbf{b}) \quad (2)$$

网络的解码阶段可以表示为:

$$\mathbf{z} = f(\mathbf{w}'\mathbf{h} + \mathbf{b}') \quad (3)$$

式中: $\mathbf{w}, \mathbf{w}'$ —编码层和解码层的权重矩阵; $\mathbf{b}, \mathbf{b}'$ —编码层和解码层的偏移矩阵; $\mathbf{h}$ —隐含层; $\mathbf{z}$ —重构数据。

自编码器根据重构误差函数,利用反向传播算法来调整  $\mathbf{w}, \mathbf{w}', \mathbf{b}, \mathbf{b}'$ 。

常见的重构误差损失函数为均方根误差 (mean-squared loss, MSE),其定义如下:

$$L = \frac{1}{2} \| \mathbf{z}_i - \mathbf{x}_i \|^2 \quad (4)$$

## 1.3 一维卷积神经网络

一维卷积神经网络 (one dimensional convolutional neural Networks, 1D-CNN) 是一种特殊的卷积神经网

络。它的输入为一维数据,可以无需经过数据维度的转化,即可实现对一维时序信号进行分析的目的。

常见的一维卷积神经网络结构如图 2 所示。

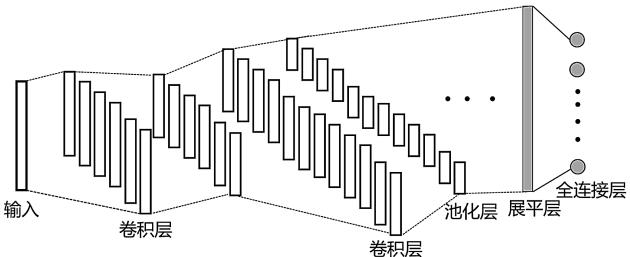


图 2 一维卷积神经网络结构示意图

## 2 基于 1D-DCGAN 和 1D-CAE 的故障诊断方法

此处,笔者所提出的方法是通过对振动信号的特征进行学习,从而进行故障诊断。所以笔者采用一维卷积层构建网络,最大程度地发挥模型自主学习信号特征的优势。

为了实现小样本下的故障诊断目的,笔者提出了一种基于一维卷积生成对抗网络 (1D-DCGAN) 和一维卷积自编码器 (1D-CAE) 的故障诊断方法。

该故障诊断方法的整体训练流程如图 3 所示。

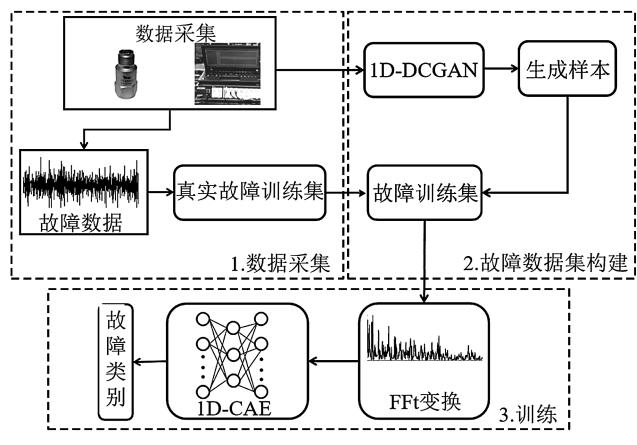


图 3 整体训练方法流程图

首先,笔者将加速度传感器采集到的少量故障样本输入 1D-DCGAN 中,进行训练,利用生成器生成故障样本,构建故障训练集;然后,对故障训练集中的样本进行 FFT 变换,并将结果输入 1D-CAE 网络中,进行训练,借助其强大的特征提取能力,对故障进行分类。

### 2.1 基于 1D-DCGAN 的样本生成

GAN 网络在训练过程中容易出现训练不稳定、样本生成质量较差等问题,为了解决这些问题,笔者利用一维卷积层构建 1D-DCGAN,利用少量的一维故障信号生成新的故障信号,作为扩充样本,以构建故障训练集。

其中,基于1D-DCGAN的数据扩充流程如图4所示。

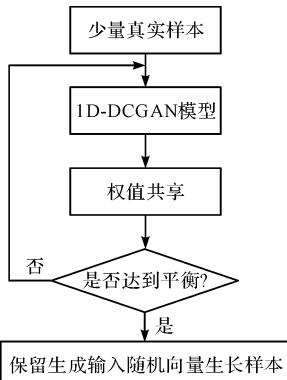


图4 基于1D-DCGAN的数据扩充流程

在神经网络的训练过程中,生成器的输出层采用Tanh激活函数,其余层采用修正线性单元(rectified linear unit, ReLU)作为激活函数,判别器统一采用带泄露的修正线性单元(leaky rectified linear unit, Leaky ReLU)激活函数。

1D-DCGAN生成器网络具体参数如表1所示。

表1 1D-DCGAN生成器网络参数

网络层	卷积核数目	卷积核大小	步长	激活函数	
生成器	卷积层1	32	3×1	1	ReLU
	上采样层1	—	2×1	2	—
	卷积层2	32	3×1	1	ReLU
	上采样层2	—	2×1	2	—
	卷积层3	128	3×1	1	ReLU
	卷积层4	16	3×1	1	ReLU
	上采样层4	—	2×1	2	—
	卷积层5	1	3×1	1	Tanh

1D-DCGAN判别器网络参数如表2所示。

表2 1D-DCGAN判别器网络参数

网络层	卷积核数目	卷积核大小	步长	激活函数	
生成器	卷积层1	64	3×1	1	LeakyReLU
	池化层1	—	2×1	2	—
	卷积层2	32	3×1	1	LeakyReLU
	池化层2	—	2×1	2	—
	卷积层3	16	3×1	1	LeakyReLU
	池化层3	—	2×1	2	—
	卷积层4	8	3×1	1	LeakyReLU
	池化层4	—	2×1	2	—
	全连接层1	1	—	—	Sigmoid

## 2.2 基于1D-CAE的故障诊断

如何从一维振动信号中提取有用信息,这是决定故障诊断准确与否的关键。自编码器是一种无监督学

习模型,具有强大的特征提取能力,可以提取样本中的潜在特征。

为了能够更好地从故障信号中提取潜在特征,笔者利用一维卷积层构建了一维卷积自编码器(1D-CAE);同时,由于故障信号的频域信息比时域信息能反映出更多的故障特征,笔者选取振动信号的频谱作为1D-CAE模型的输入样本。

1D-CAE的模型结构如图5所示。

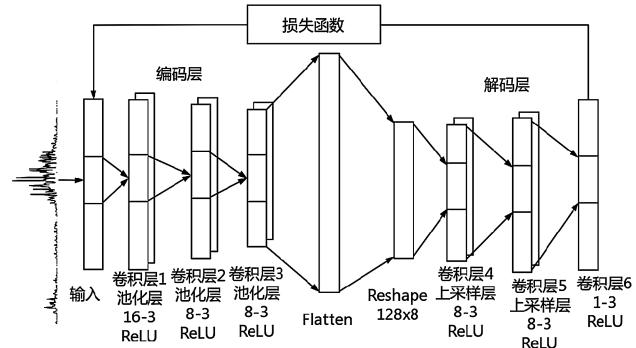


图5 预训练模型结构图

CAE模型的网络结构参数如表3所示。

表3 CAE网络结构参数

网络层	卷积核数目	卷积核大小	步长	激活函数
卷积层1	16	3×1	1	ReLU
编 码 器	池化层	—	2×1	—
卷积层2	8	3×1	1	ReLU
池化层	—	2×1	2	—
卷积层3	8	3×1	1	ReLU
池化层	—	2×1	2	—
卷积层4	8	3×1	1	ReLU
解 码 器	上采样层	—	2×1	—
卷积层5	8	3×1	1	ReLU
上采样层	—	2×1	2	—
卷积层6	1	3×1	1	ReLU

机械设备在运转时,振动信号中充斥着噪声和异常值。MSE损失函数对非高斯噪声比较敏感,会使自编码器的性能下降。

为了提升自编码器对抗噪声的能力,可以将自编码器提取的特征稀疏化,以提高其对抗异常值的能力,使模型具有更好的泛化能力<sup>[19,20]</sup>;或者,在自编码器训练时,对输入样本人为地添加随机噪声,使模型具有一定的泛化能力<sup>[21-23]</sup>。

在信息处理领域,相关熵可以通过度量两个信号的相似度,将数据映射至高维空间。这在处理非高斯噪声以及异常值方面具有不错的效果<sup>[24,25]</sup>。

为了减小非高斯噪声对一维卷积自编码器性能的影响,笔者利用相关熵构建损失函数<sup>[26]</sup>,以代替MSE作为1D-CAE的损失函数。

采用高斯核函数的相关熵定义如下:

$$\kappa_\sigma = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{x^2}{2\sigma^2}\right\} \quad (5)$$

相关熵构建新的损失函数为:

$$L = 1 - \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(y - \bar{y})^2}{2\sigma^2}\right\} \quad (6)$$

相关熵损失函数的梯度为:

$$\frac{\partial L}{\partial(y - \bar{y})} = \frac{(y - \bar{y})}{\sigma^3 \sqrt{2\pi}} \exp\left\{-\frac{(y - \bar{y})^2}{2\sigma^2}\right\} \quad (7)$$

式中: $y$ —预测值;  $\bar{y}$ —真实值;  $\sigma$ —高斯核;

核宽度  $\sigma$  取不同值时, 相关熵损失函数与 MSE 损失函数的梯度值比较结果, 如图 6 所示。

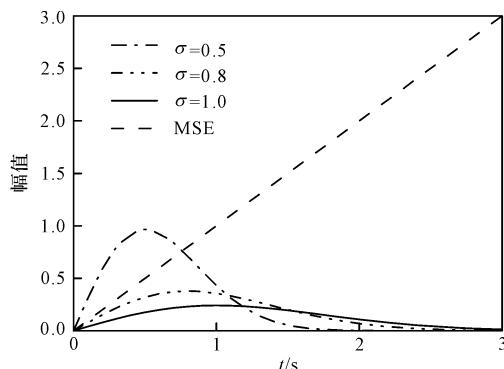


图 6 MSE 损失函数与相关熵损失函数的梯度值

从图 6 可以观察到:MSE 损失函数的梯度值是随着误差值线性增大的, 其个别异常值产生的较大误差会造成 MSE 损失函数的梯度值过大, 不利于梯度的反向传播; 而相关熵损失函数的梯度值又被限制在了一定的范围内。因此, 相关熵损失函数受到异常值的影响要比 MSE 损失函数小很多。

在 1D-CAE 训练完成以后, 笔者去除 1D-CAE 的解码层, 将其接入分类器, 以构成故障的分类模型。

故障分类模型结构如图 7 所示。

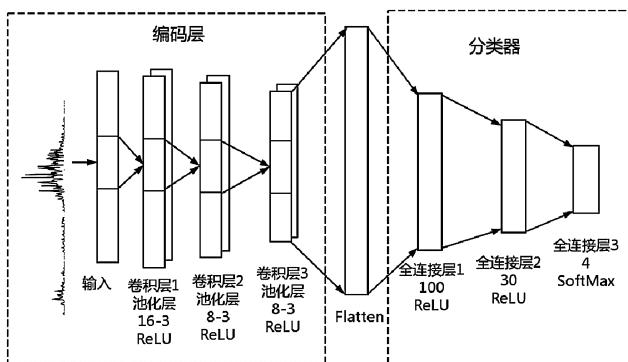


图 7 故障分类模型结构

故障分类模型参数如表 4 所示。

在进行训练时, 笔者固定编码层参数, 利用含标签数据进行有监督训练, 得到分类器参数。

表 4 故障分类模型参数

	网络层	大小	激活函数
分类器	Dense1	100	ReLU
	Dense2	30	ReLU
	Dense3	4	Sigmoid

### 2.3 小样本跨域迁移

在实际工程中, 无法针对每个设备去采集足够的样本。因此, 如何利用训练好的模型, 使用少量的样本, 实现相似设备间的跨域诊断目的, 具有实际的应用价值。

由于从不同设备上采集到的信号存在差异, 不满足独立同分布假设。这会导致常规的故障诊断模型运用在不同设备上时, 性能会存在巨大差异。

笔者采用参数迁移的方式, 将已有模型的参数迁移至只有少量样本的新任务中, 进行小样本下的跨域诊断。

首先, 笔者使用源域数据进行训练, 得到 1D-CAE 故障分类模型, 而后冻结特征, 提取网络的参数, 利用少量的目标域数据对模型的分类器进行微调, 以实现模型的参数迁移。

笔者所提出的跨域诊断框架如图 8 所示。

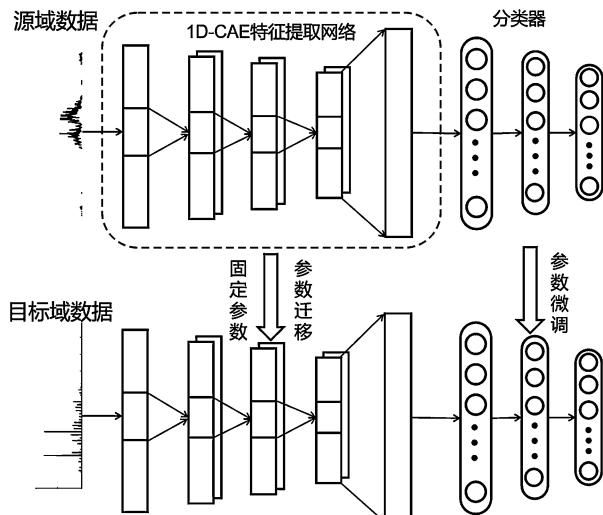


图 8 故障迁移诊断方法

## 3 实验及结果分析

为了对基于 1D-DCGAN 和 1D-CAE 的故障诊断方法的有效性进行验证, 此处, 笔者采用美国凯斯西储大学故障轴承数据集进行实验。

该数据集包含了不同工况下, 内圈故障、外圈故障、滚动体故障以及正常状态的轴承振动加速度信号。

为构建实验所用的训练集, 笔者对原始加速度信号进行重叠采样。其中, 采样间隔为 100, 每个样本包含了 1 024 个数据点。

信号的采样方式如图 9 所示。

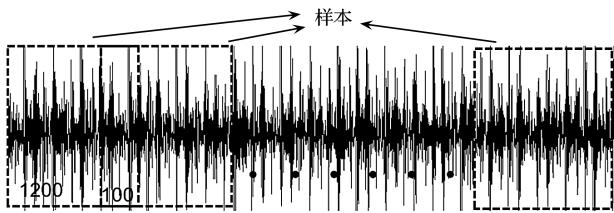


图9 信号采样示意图

实验数据集信息如表5所示(其中,A、B、C为不同功率下的数据集,表示3种不同工况)。

### 3.1 数据生成实验

为了验证1D-DCGAN的数据生成能力,笔者以工

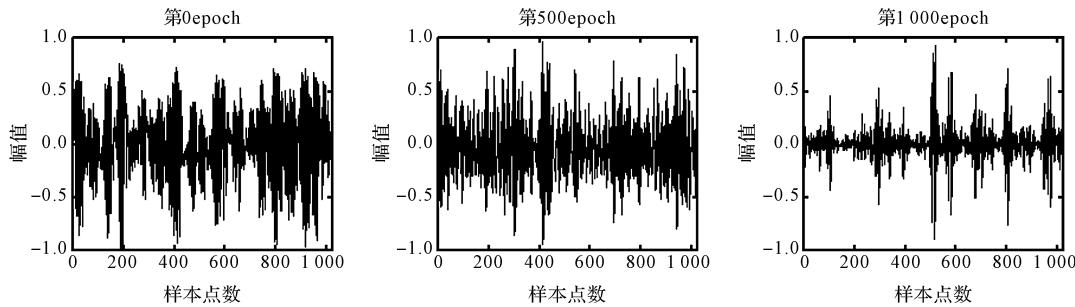
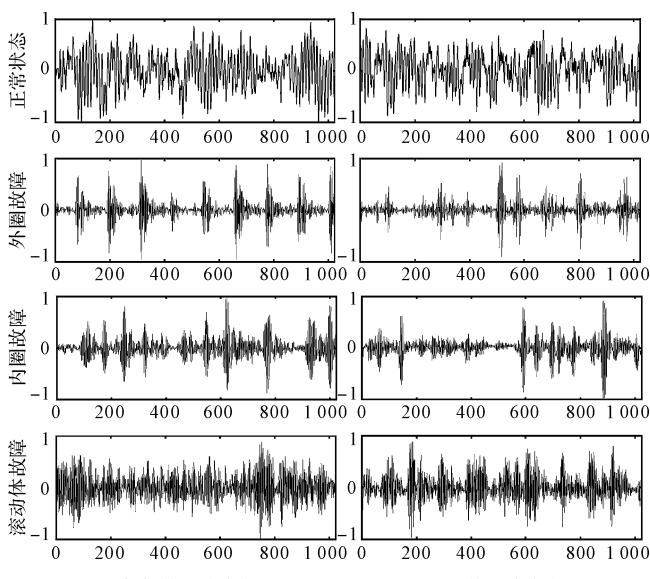


图10 生成信号随迭代次数的演变

从图10可以看出:随着模型迭代次数的不断增加,生成的信号质量越来越好,说明1D-DCGAN在不断地学习真实信号的分布。

为更直观地观察1D-DCGAN的数据生成效果,笔者展示了不同状态的真实样本与生成样本的波形图,如图11所示。

从图11中可以看出:真实样本与生成样本的时域波形虽不相同,但真实样本与生成样本在频域的分布类似。



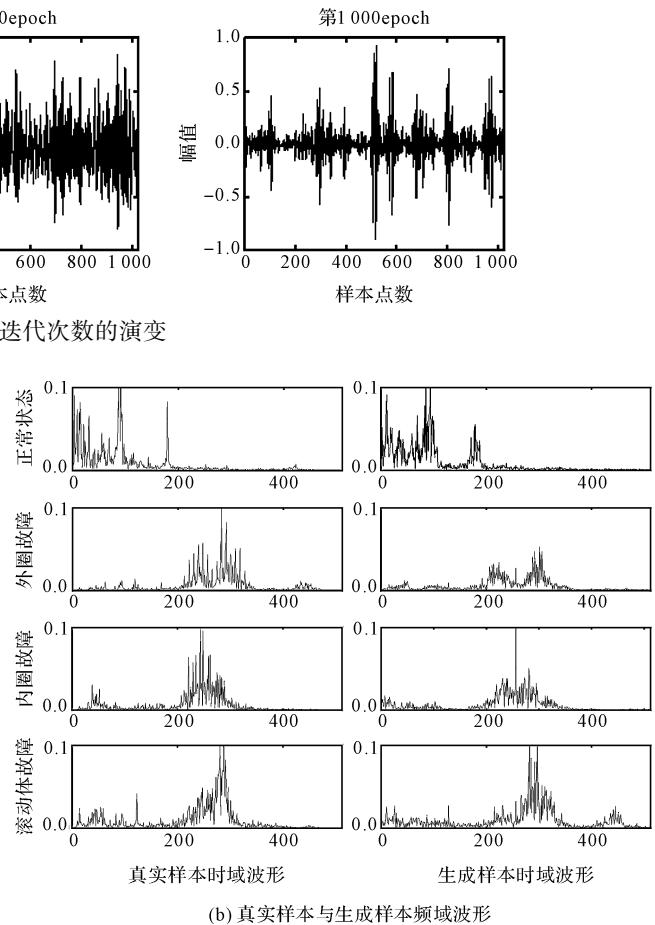
(a) 真实样本与生成样本时域波形

表5 实验样本数量信息

	工况 A	工况 B	工况 C
正常	1 000	1 000	1 000
内圈故障	1 000	1 000	1 000
外圈故障	1 000	1 000	1 000
滚动体故障	1 000	1 000	1 000

况A为例,在每种状态下依次取500个样本,将其输入1D-DCGAN中进行训练,共得到4个生成器,分别用来生成不同状态的样本。

不同迭代次数下信号的生成情况如图10所示。



(b) 真实样本与生成样本频域波形

图11 真实样本与生成样本波形图

图11说明,1D-DCGAN可以学到数据的分布规律。

### 3.2 同工况实验对比

首先,笔者进行单一工况下的故障诊断实验及对比。

工况A下,笔者在每种状态随机取50%的样本,利用1D-DCGAN构建包含6 000个样本的训练集,用于1D-CAE模型的训练;剩余50%的样本,用于1D-CAE模型的测试。

为了验证1D-CAE模型的有效性,笔者将1D-CAE

同堆栈自编码器(DAE)以及传统机器学习中算法中的 LGB 模型进行比较。

每种方法各进行 5 次实验,实验结果取平均值,最终得到同工况下不同方法的准确率对比结果,如图 12 所示。

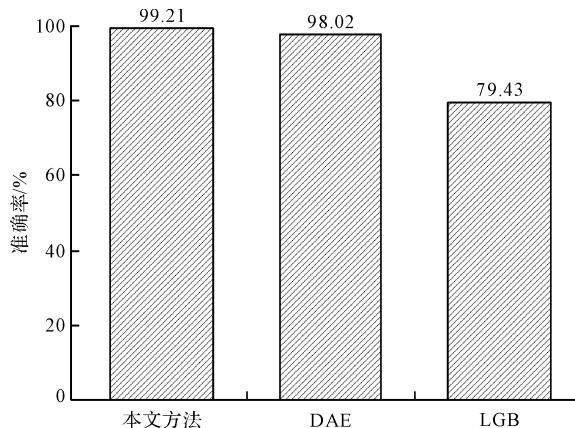


图 12 同工况下不同方法的准确率对比

从图 12 可以看出:1D-CAE 的诊断准确率达到了 99.21%,明显高于其余 2 种方法。

为了直观地展示 1D-CAE 的特征提取能力,笔者利用  $t$  分布-随机邻近嵌入( $t$ -distributed Stochastic Neighbor Embedding,  $t$ -SNE)降维可视化方法<sup>[27]</sup>,对 1D-CAE 提取的特征进行降维聚类,并将其所得结果与人工提取的时域特征进行对比。

同工况下不同方法的特征降维可视化结果,如图 13 所示。

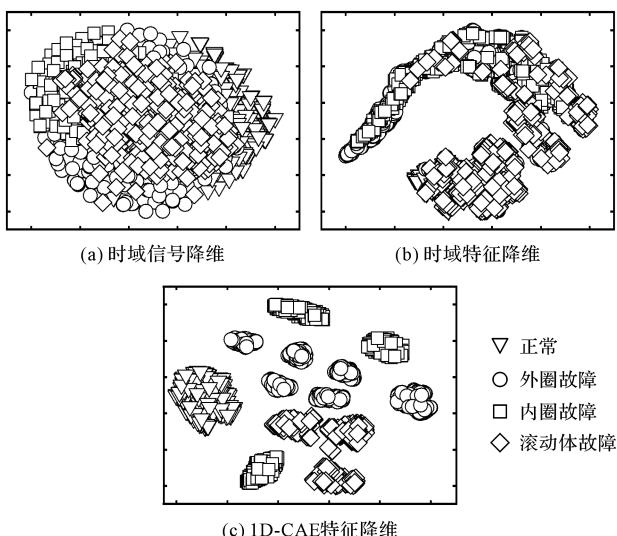


图 13 同工况下不同方法的特征降维结果

从图 13 中可以看出:1D-CAE 提取的特征更具代表性,可以将不同类别的样本区分开。

### 3.3 变工况实验对比

为了验证上述模型在不同工况下的泛化能力,笔者

取某一种工况下的样本用于模型的训练,其余工况下的样本用作测试(比如:“A-B”表示工况 A 下的样本用作训练,工况 B 下的样本用作测试。其他情况以此类推),同样,将其与 DAE 和 LGB 两种方法进行对比研究。

变工况下,3 种方法的故障诊断准确率结果对比如图 14 所示。

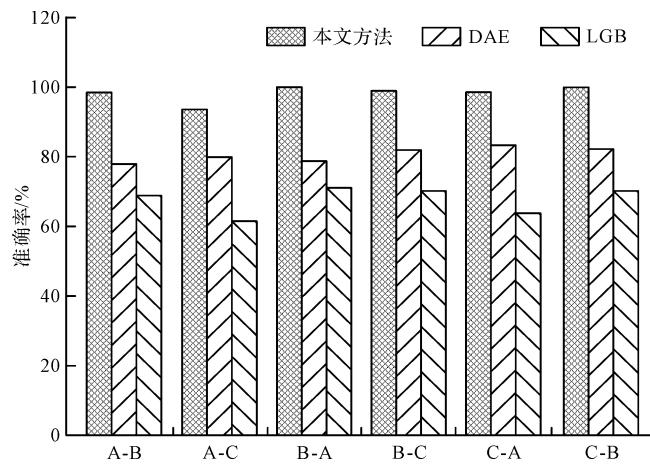


图 14 变工况下不同方法的准确率对比

变工况下,3 种方法的泛化能力对比结果如表 6 所示。

表 6 变工况下不同方法的泛化能力对比(%)

	A-B	A-C	B-A	B-C	C-A	C-B
1D-CAE	98.47	93.59	100	98.92	98.54	99.92
MSE + DAE	77.88	79.92	78.78	81.94	83.34	82.24
LGB	68.82	61.53	71.12	70.15	63.74	70.15

由表 6 可以看出:DAE 与 LGB 泛化能力较差,而笔者所提出的 1D-CAE 方法在变工况下仍能保持不错的故障识别精度。

这说明,1D-CAE 能够提取振动信号中更本质的特征,使得模型具有更好的泛化能力。

### 3.4 跨域诊断实验

为了对迁移学习及 1D-CAE 跨域诊断性能进行测试,笔者利用在不同设备上采集的故障样本进行实验。

笔者采用美国凯斯西储大学(CWRU)轴承数据集作为源域数据,采用西安交通大学(XJTU-SY)轴承数据集<sup>[28]</sup>作为目标域数据,用来模拟不同设备之间的跨域诊断。

源域数据包括了正常状态、内圈故障、外圈故障以及滚动体故障样本。目标域数据包括了正常状态、内圈故障和外圈故障样本。

跨域诊断实验数据集描述情况如表 7 所示。

为了验证 1D-CAE 方法的跨域诊断效果,笔者挑选了另外几种方法进行对比分析。对比方法为基于 LGB

表7 跨域诊断实验数据描述

故障类别	源域数据个数	目标域训练个数	目标域测试个数
正常	500	500	500
内圈	500	500	500
外圈	500	500	500
滚动体	500	—	—

模型和 DAE 模型的参数迁移方法,以及基于 DAE 模型 + MMD 模型的特征迁移方法。

4 种方法的跨域诊断实验结果,即基于迁移学习的跨域诊断准确率对比,如图 15 所示。

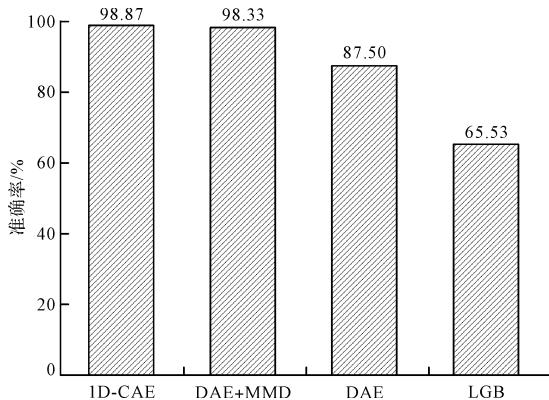


图 15 基于迁移学习的跨域诊断准确率对比

从图 15 可以看出:1D-CAE 参数迁移方法与 DAE + MMD 特征迁移方法诊断效果较好,故障分辨率均达到了 98% 以上;相比于 DAE + MMD 特征迁移方法,1D-CAE 方法在跨域诊断时,无需源域数据参与训练,简单易行,更有利于工程上的应用。

为清晰地展现不同迁移学习模型的训练结果,笔者利用 1D-CAE、DAE 以及 DAE + MMD 方法对目标域进行特征提取,并利用 t-SNE 降维可视化。

不同迁移学习方法的目标域特征降维可视化结果图,如图 16 所示。

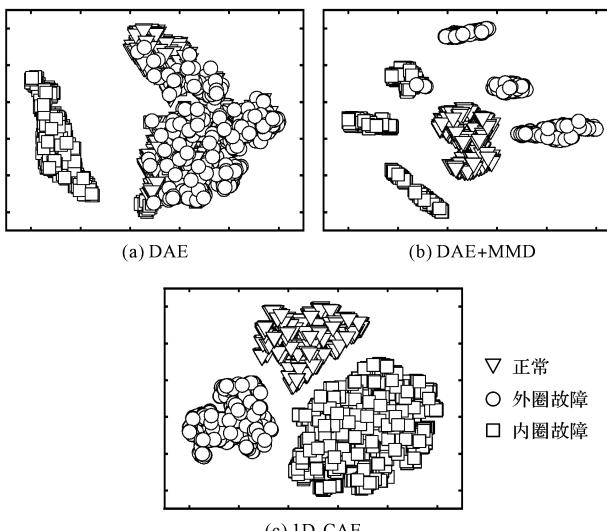


图 16 不同迁移学习方法的目标域特征降维可视化结果

从图 16 可以看出:DAE 参数迁移效果较差;1D-CAE 参数迁移和 DAE + MMD 特征迁移 2 种方法都可以将目标域中不同故障类型的数据投射到相应区域,都表现出了较好的聚类性和可分性。

## 4 结束语

为了解决小样本下,同种设备以及不同设备间的轴承故障诊断问题,笔者提出了一种基于一维卷积层构建生成对抗网络与自编码器,结合迁移学习的轴承故障诊断方法。

笔者利用美国凯斯西储大学(CWRU)和西安交通大学(XJTU-SY)轴承数据集,对相关方法进行了实验验证。

研究结论如下:

(1)1D-DCGAN 可以直接利用一维故障信号作为样本进行训练,学习真实样本的分布特点,生成的样本可以作为扩充样本,用于构建故障训练集;

(2)利用相关熵作为损失函数的 1D-CAE 模型具有较强的特征提取能力。相比于传统机器学习算法 LGB,以及深度学习算法 DAE 等智能诊断方法,1D-CAE 具有更好的泛化能力,其诊断准确率可达 99.21%,即使在变工况下,该方法也能保有较高的故障识别精度;

(3)1D-CAE 模型具有很强的域适应能力,采用过参数迁移方式,它可以充分地将源域上学到的知识应用到不同的目标域中,实现小样本下的跨域故障诊断目的,且故障准确率达到 98% 以上。

因为轴承的故障诊断只是机械系统故障诊断中的一小部分,所以在后续的研究工作中,笔者将对现有故障诊断模型的结构进行优化改进,使模型可以适用于更加复杂的机械系统。

## 参考文献(References):

- [1] 吴春志,冯辅周,吴守军,等.深度学习在旋转机械设备故障诊断中的应用研究综述[J].噪声与振动控制,2019,39(5):1-7.
- [2] 李恒,张氢,秦仙蓉,等.基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J].振动与冲击,2018,37(19):124-131.
- [3] AI Shao-jie, JIANG Song, CAI Guo-biao. A real-time fault diagnosis method for hypersonic air vehicle with sensor fault based on the auto temporal convolutional network [J]. Aerospace science and technology, 2021, 119(12):107220.
- [4] 卞景艺,刘秀丽,徐小力,等.基于多尺度深度卷积神经网

- 络的故障诊断方法 [J]. 振动与冲击, 2021, 40 (18) : 204-211.
- [5] 向家伟. 数值模型驱动的传动系统故障个性化诊断原理 [J]. 机械工程学报, 2021, 57(15) : 116-128.
- [6] BAI Ming-liang, YANG Xu-sheng, LIU Jin-fu, et al. Convolutional neural network-based deep transfer learning for fault detection of gas turbine combustion chambers [J]. *Applied Energy*, 2021, 302(1) : 117509-117533.
- [7] YANG Dao-guo, KARIMI H R, SUN Kang-kang. Residual wide-kernel deep convolutional auto-encoder for intelligent rotating machinery fault diagnosis with limited samples [J]. *Neural Networks*, 2021, 141(9) : 133-144.
- [8] KE Zhao, JIANG Hong-kai, LIU Chao-qiang, et al. A new data generation approach with modified Wasserstein auto-encoder for rotating machinery fault diagnosis with limited fault data [J]. *Knowledge-based systems*, 2022, 238 (1) : 107892.
- [9] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Nets [C]. //International Conference on Neural Information Processing Systems. MIT Press, 2014 : 2672-2680.
- [10] 何沛松, 李伟创, 张婧媛, 等. 面向 GAN 生成图像的被动取证及反取证技术综述 [J]. 中国图象图形学报, 2022, 27(1) : 88-110.
- [11] 温佩芝, 陈君谋, 肖雁南, 等. 基于生成式对抗网络和多级小波包卷积网络的水下图像增强算法 [J]. 浙江大学学报:工学版, 2022, 56(2) : 213-224.
- [12] MAZA B, SO A. InfraGAN: a GAN architecture to transfer visible images to infrared domain [J]. *Pattern recognition letters*, 2022, 155(3) : 69-76.
- [13] 徐林, 郑晓彤, 付博, 等. 基于改进 GAN 算法的电机轴承故障诊断方法 [J]. 东北大学学报:自然科学版, 2019, 40(12) : 1679-1684.
- [14] ZHOU Yue, GE Zhi-qiang. Gaussian discriminative analysis aided GAN for imbalanced big data augmentation and fault classification [J]. *Journal of Process Control*, 2020, 92(11) : 271-287.
- [15] WANG Bing. A study on spot welding quality judgment based on improved generative adversarial network and auto-encoder [J]. *Mechanical Systems and Signal Processing*, 2022, 165(3) : 108318-108337.
- [16] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究 [J]. 西安交通大学学报, 2021, 55 (10) : 30-37.
- [17] LIU Yong-zhi, SHI Ke-ming, LI Zhi-xuan, et al. Transfer learning method for bearing fault diagnosis based on fully convolutional conditional wasserstein adversarial networks [J]. *Measurement*, 2021, 180(8) : 109553-109564.
- [18] ALEC R, LUKE M, SOUMITH C. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. *Computer Science*, 2015, 2(12) : 1-16.
- [19] ZHANG Cheng-yi, YU Jian-bo, YE L. Sparsity and manifold regularized convolutional auto-encoders-based feature learning for fault detection of multivariate processes [J]. *Control Engineering Practice*, 2021, 111(7) : 104811.
- [20] ZHAO Xiao-li, JIA Min-ping, LIN Ming-yao. Deep laplacian auto-encoder and its application into imbalanced fault diagnosis of rotating machinery [J]. *Measurement*, 2019, 152(2) : 107320.
- [21] LI Chuan-kun, ZHAO Dong-feng, MU Shan-jun, et al. Fault diagnosis for distillation process based on CNN-DAE [J]. *Chinese Journal of Chemical Engineering*, 2019, 27(3) : 598-604.
- [22] PENG Peng, ZHANG Yi, WANG Hong-wei, et al. Towards robust and understandable fault detection and diagnosis using denoising sparse autoencoder and smooth integrated gradients [J]. *ISA. Transactions*, 2021, 125 (6) : 371-383.
- [23] YANG Zheng, XU Bin-bin, LU Wei, et al. Autoencoder-based representation learning and its application in intelligent fault diagnosis [J]. *Measurement: journal of the International Measurement Confederation*, 2021, 189(5-6) : 110460.
- [24] SHAO Hai-dong, JIANG Hong-kai, ZHAO Hui-wei, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2017, 95(10) : 187-204.
- [25] 杨南海, 黄明朋, 赫然, 等. 基于最大相关熵准则的鲁棒半监督学习算法 [J]. 软件学报, 2012, 23 (2) : 279-288.
- [26] 朱强, 吴芮, 慎明俊, 等. CEEMDAN 辅助快速谱峭度的滚动轴承故障诊断方法 [J]. 轻工机械, 2022, 40 (3) : 74-79, 84.
- [27] VAN DERMAATEN L, HINTON G. Visualizing data using t-SNE [J]. *Journal of machine learning research*, 2008, 9(2605) : 2579-2605.
- [28] WANG Biao, LEI Ya-guo, LI Nai-peng, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. *IEEE. Transactions on Reliability*, 2018, 69(1) : 401-412.

[ 编辑: 司红岩 ]

## 本文引用格式:

林培, 许杨剑, 傅军平, 等. 基于 1D-DCGAN 和 1D-CAE 的小样本轴承故障跨域诊断方法 [J]. 机电工程, 2023, 40(3) : 326-334.

LIN Pei, XU Yang-jian, FU Jun-ping, et al. Cross domain diagnosis method for bearing faults with small samples based on 1D-DCGAN and 1D-CAE [J]. *Journal of Mechanical & Electrical Engineering*, 2023, 40(3) : 326-334.《机电工程》杂志: <http://www.meem.com.cn>