

# 小样本条件下轴承故障的 DCGAN 诊断方法\*

柳雅倩<sup>1,2</sup>, 蔡浩原<sup>1</sup>, 李文宽<sup>1,2</sup>, 赵晟霖<sup>1,2</sup>, 刘春秀<sup>1</sup>

(1. 中国科学院空天信息创新研究院 北京, 100190)

(2. 中国科学院大学电子电气与通信工程学院 北京, 100049)

**摘要** 针对基于故障数据图像的诊断方法所需训练数据严重不足以及在小样本故障库条件下诊断准确率较低等问题,提出了一种基于深度卷积生成对抗网络(deep convolutional generative adversarial networks, 简称 DCGAN)的扩充滚动轴承故障小样本库的方法,以丰富故障信息,在小样本故障库条件下提高故障诊断准确率。为了改善传统算法易产生的棋盘格效应,设计上采样卷积(up-sampling convolution, 简称 USCONV)层,将传统 DCGAN 算法与双线性插值的上采样及卷积相结合,对故障数据小波变换图像进行训练学习,输出逼真的生成样本。该模型针对多种故障情况,在小样本故障库条件下能准确完善数据集,缓解过拟合等问题,提高了再诊断的准确性。实验结果表明,USCONV 层对棋盘格问题有明显改善,小样本库扩充后诊断模型对包含多种故障情况的测试集识别率由 91.67% 提升至 98.96%,证明了该方法的可行性和有效性。

**关键词** 故障诊断;小样本;深度卷积生成对抗网络;深度学习;滚动轴承  
**中图分类号** TH17;TH165.3;TP277

## 引言

随着人工智能的快速发展,基于深度学习方法的智能化故障诊断成为研究热点。卷积神经网络(convolutional neural networks, 简称 CNN)在故障诊断领域的应用趋于成熟。赵小强等<sup>[1]</sup>从轴承故障的二维特征图中自动提取状态特征,说明了故障信号二维化诊断的有效性。但是,深度学习需要大量数据支撑训练,数据不足时难以取得令人满意的结果<sup>[2]</sup>。在实际工业生产中,滚动轴承故障往往偶发且少发的现状造成了可供采集的轴承故障类型不均衡、样本数据量较少的情况。在小样本故障库条件下,传统方法易产生过拟合等问题,影响诊断效果。针对样本不均衡等问题,传统解决方案对诊断性能的优化十分有限<sup>[3]</sup>。Godfellow 等<sup>[4]</sup>提出了生成对抗网络(generative adversarial networks, 简称 GAN)。Ding 等<sup>[5]</sup>对生成对抗网络进行改进,使用少量标记的真实样本以监督的方式训练判别器,并对原始小样本进行扩充,诊断效果较好,验证了生成对抗网络及其变体在故障诊断领域的可行性。

卷积网络利用其特征提取功能,从轴承故障数据的矩阵或频谱图像中提取更为准确的特征<sup>[6]</sup>,同

时 GAN 在图像领域中的应用相对成熟<sup>[7]</sup>,但是针对故障数据二维图像的生成及样本库扩充的研究较少。Radford 等<sup>[8]</sup>提出的 DCGAN 作为 GAN 的重要变体,得益于卷积神经网络对图像的强大处理能力,其在图像生成领域应用广泛<sup>[9]</sup>。Du 等<sup>[7]</sup>将 DCGAN 应用于化学工业故障不平衡数据集的心血管磁共振(cardiovascular magnetic resonance, 简称 CMR)图像的生成。Viola 等<sup>[10]</sup>将 CMR 图像与连续小波变换图像相结合,验证了时频变换对特征的提取能力。但是,上述 2 种方法均存在不足:①无法说明数据的故障类型;②生成的单通道灰度图像对比度较低,在训练过程中易损失故障特征细节;③使用的转置卷积在二维图像生成中易产生棋盘格效应<sup>[11]</sup>,影响二维图像生成的准确性。

笔者提出一种小样本库条件下滚动轴承故障的 DCGAN 诊断方法,对小样本库进行扩充后再诊断。针对不同损伤位置及损伤深度,设计 USCONV 层以缓解生成样本的棋盘格效应。将预处理后的小样本数据输入模型,生成含有丰富特征信息的三通道彩色样本图像,完成小样本库的扩充,并将扩充后的数据集输入 CNN 模型进行再诊断。结果显示,模型识别率有较大提升,验证了该方法的有效性。

\* 国家自然科学基金资助项目(61774157, 81771388);北京市自然科学基金资助项目(4182075)

收稿日期:2021-02-10;修回日期:2021-04-21

# 1 实验算法

## 1.1 GAN 与 DCGAN

### 1.1.1 生成对抗网络

图 1 为 GAN 网络架构示意图。生成器和判别器分别使用独立网络模型,生成器捕捉真实样本的潜在特征分布,使用随机噪声信号作为输入,生成足以以假乱真的生成样本;判别器接受真实样本和生成样本作为输入,判断其是否为真实样本。

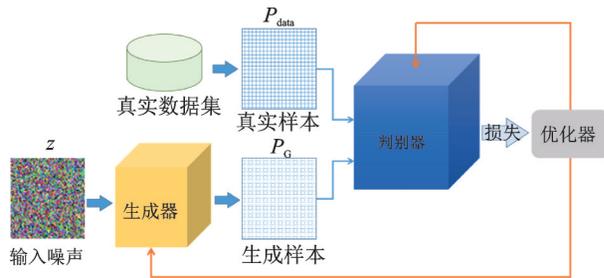


图 1 GAN 网络架构示意图

Fig.1 The network architecture of GAN

GAN 的主要目标表达式为

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

其中:  $V(D, G)$  为目标函数;  $G$  为生成器;  $D$  为判别器;  $x$  为真实数据, 其分布为  $P_{data}(x)$ ;  $z$  为输入  $G$  的随机噪声, 其分布为  $P_z(z)$ ;  $D(x)$  为判别器判定输入为真实数据的概率;  $G(z)$  为生成数据;  $D(G(z))$  为判别器判定输入为生成数据的概率。

根据式(1)可得, GAN 最终的目标就是求解  $\min_G(\cdot)$ , 即希望  $D(G(z)) = 1$ , 使生成器生成更逼真的样本, 达到以假乱真的目的。内部嵌套  $\max_D(\cdot)$  则代表在给定  $G$  的情况下, 求解使  $V$  最大化的  $D$ 。对于真实数据  $x$ ,  $D(x)$  要接近于 1; 对于生成数据  $G(z)$  时,  $D(G(z))$  要接近于 0, 即可得到识别能力更强的判别器。二者相互对抗的过程是判别器的判别能力不断上升且生成器“造假”能力也不断上升的过程, 目标是达到纳什均衡。

二者达到纳什均衡的条件是真实数据分布与生成数据分布相近, 令  $G(z) = x$ , 此时  $P_z(z)$  可用  $P_G(x)$  表示。

给定  $G$  以求解  $D$

$$V = E_{x \sim P_{data}} [\log D(x)] + E_{z \sim P_G} [\log(1 - D(x))] =$$

$$\int [P_{data}(x) \log D(x) + P_G(x) \log(1 - D(x))] dx \quad (2)$$

得到最优  $D$  的表达式为

$$D(x) = P_{data}(x) / (P_{data}(x) + P_G(x)) \quad (3)$$

将其代入式(1), 求解最优  $G$ , 当且仅当  $P_{data}(x) = P_G(x)$  时,  $G$  取得最优解, 此时生成样本与真实样本的分布最为接近, 生成对抗网络的训练达到均衡。

### 1.1.2 深度卷积生成对抗网络

深度卷积生成对抗网络结构是对 GAN 算法的改进, 将卷积算法和 GAN 相融合, 使用卷积层构建 GAN 模型中的生成器和判别器, 增强了网络的实用性和稳定性。

DCGAN 算法特点<sup>[8]</sup> 主要在于: 采用全卷积网络, 用带步长的转置卷积层代替池化, 实现图像放大功能; 引入全局平均池化(global average pooling, 简称 GAP), 将卷积特征分别与生成器和判别器的输入输出直接相连, 以提高模型稳定性; 利用批标准化层(batch normalization, 简称 BN) 稳定训练。

为防止梯度稀疏等问题, DCGAN 普遍使用泄露修正线性单元(leaky rectified linear unit, 简称 LeakyReLU) 函数代替传统的修正线性单元(rectified linear unit, 简称 ReLU) 函数作为中间层的激活函数。LeakyReLU 是 ReLU 的一个变体, 不同于 ReLU 函数的是, LeakyReLU 函数在输入的  $x < 0$  时输出不为 0, 从而解决了输入值为负时神经元停止工作的问题。其函数表达式为

$$y = \begin{cases} x & (x > 0) \\ \lambda x & (x < 0) \end{cases} \quad (4)$$

其中:  $\lambda \in (0, 1)$ 。

在 DCGAN 算法中, 转置卷积起到了放大图像的作用, 卷积核大小和步长是转置卷积的 2 个重要参数。由于转置卷积操作经常会在卷积核大小不能被步长整除时出现不均匀重叠的现象, 故导致模型在实际运行时易出现棋盘格效应<sup>[11]</sup>, 如图 2 所示, 尤其是二维图像的两轴不均匀重叠部分会相互叠加, 在特征较为显著的区域形成大小不同的棋盘状特征图案, 使生成图像失真, 在实际实验中会使生成样本

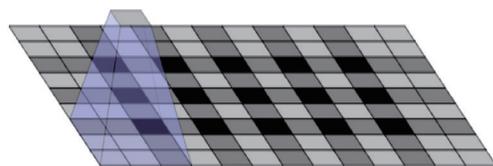


图 2 棋盘格效应

Fig.2 Checkerboard pattern

的像素分布不均匀,影响样本扩充。

在实际情况中,卷积核通常取较小的奇数,由于步长无法整除,故实践中无法完全避免棋盘格现象。

### 1.2 连续小波变换

连续小波变换(continuous wavelet transform, 简称 CWT)基于在计算每个频率成分时可以改变窗口形状的这一特性,被广泛用于非平稳信号处理领域<sup>[12]</sup>,故选择 CWT 对原始轴承故障数据进行预处理。

### 1.3 双线性插值法

双线性插值法利用原图像中待计算点周围 4 个真实像素点的像素值来计算待求像素进而实现图像的放大,相较于其他方法,该方法处理后的图像质量高。因此,笔者选择双线性插值对图像进行上采样。

## 2 模型结构

### 2.1 生成器网络结构

生成器网络结构如图 3 所示,以随机噪声作为网络输入,经过维度重塑、多层卷积和上采样等操作,接受来自判别器的反馈,对轴承故障信号的小波图像进行训练学习,最终生成以假乱真的小波图像。

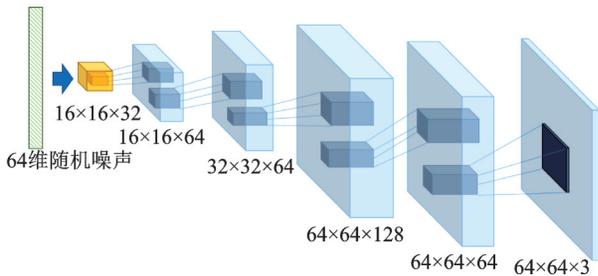


图 3 生成器网络结构

Fig.3 Generator network structure

生成器网络组成及输入输出参数如图 4 所示,由输入层和多层卷积、BN层及两层 USCONV 层组成。输入层输入 64 维潜空间高斯分布噪声数据,密集连接到 8 192 个神经元,将其尺寸重塑为  $16 \times 16 \times 32$ ;借鉴深度卷积生成对抗网络的结构思想,使用卷积层代替密集连接层作为输出;在卷积之后引入 BN 层,对数据进行标准化以稳定训练;卷积层使用 ReLU 函数激活,输出层使用 tanh 函数激活。

为了更好地提取特征、稳定训练,同时缓解转置卷积操作导致的棋盘格问题,设计 USCONV 层对传统 DCGAN 进行调整与改进,代替带步长的转置卷积层。改进后的网络特点在于,使用双线性插值法的上采样层对特征图像做尺寸重塑,结合卷积层

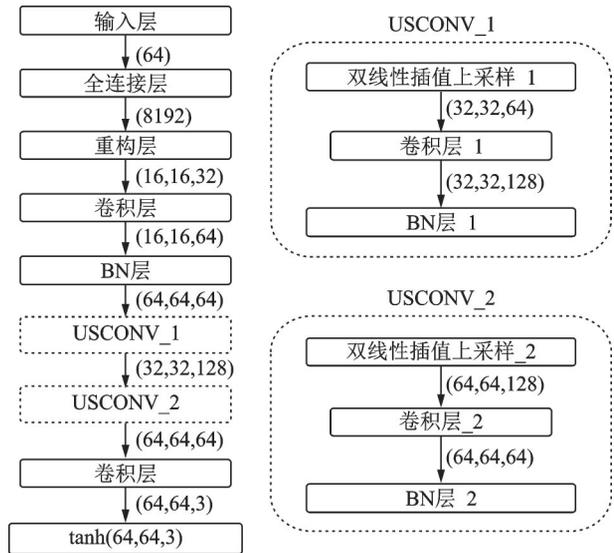


图 4 生成器网络组成及输入输出参数

Fig.4 Generator composition and input/output

对图像特征进行提取,同时将卷积处理后的数据再次通过 BN 层做标准化处理。卷积层的卷积核尺寸皆为  $3 \times 3$ ,第 1 层卷积为 64 组卷积核,两层 USCONV 层中的卷积层各含有 128 和 64 组卷积核,最后作为输出的卷积层含有 3 组卷积核,生成三通道彩色图片。经多次实验,将 BN 层的参数调整为 0.8,以适度保留各批次之间的持续影响,使网络在保证训练效果的前提下尽可能提高训练速度。

### 2.2 判别器网络结构

判别器网络组成及输入输出参数如图 5 所示。通过训练,判别器会对真实样本和生成样本进行二元诊断,并将区分结果反馈至生成器。输入层接受来自真实样本库的小波图像和生成器生成的图像作为输入,样本图像大小皆为  $64 \times 64 \times 3$ 。主体部分为 3 层卷积网络,每一层具体结构如图 5 右侧所示,卷积层的卷积核大小皆为  $3 \times 3$ ,3 层各含有 32, 64,

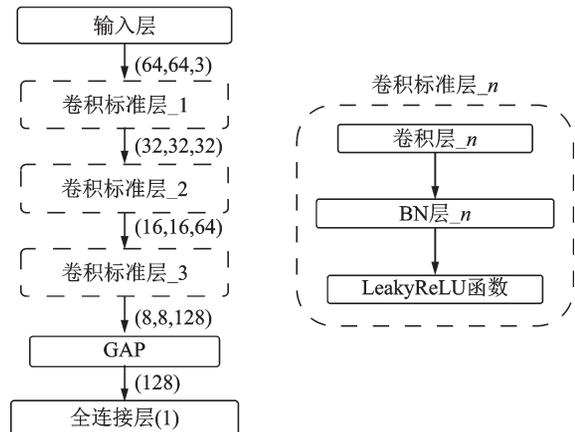


图 5 判别器网络组成及输入输出参数

Fig.5 Discriminator composition and input/output

128组卷积核。不同之处在于:数据除经过卷积层之后,还经过参数为0.8的BN层处理,使用 $\lambda$ 为0.1的LeakyReLU函数进行激活。在输出层使用GAP将卷积得到的特征图转为一维,将特征图的特征平均化,降低空间参数,使其与判定结果之间的转换更加简单。最后,经过密集连接层输出1或0,判定结果是否为真实样本,输出层使用sigmoid函数激活。

### 2.3 DCGAN模型结构

将生成器网络与判别器网络结合,使用学习率为0.000 2, $\beta_1$ 为0.5的Adam损失优化器进行优化,使用二维分类交叉熵损失函数计算模型的损失。在训练过程中,每次从训练集中随机抽取 $n$ 组数据组成一批,每若干轮存储一次生成图像,记录生成器和判别器的损失值以及判别器的准确率。

## 3 实验过程

实验平台是以TensorFlow 1.13为底层的Keras框架。实验过程主要分为3部分:①数据准备,即对数据进行包括小波变换等一系列预处理;②DCGAN模型的搭建与运行,生成逼真样本,扩充小样本库;③对扩充后样本数据集再诊断,检验模型的有效性。实验流程如图6所示。

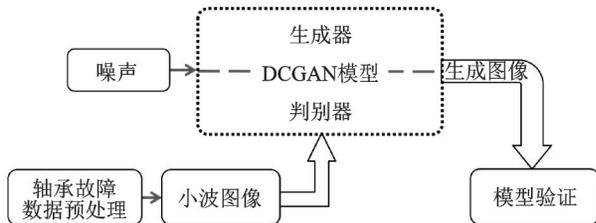


图6 实验流程

Fig.6 Experimental process

### 3.1 数据准备

使用美国凯斯西储大学的人工加工单点损伤轴承故障开源数据集,被测故障轴承为深沟球轴承。选取包括内圈、外圈、滚珠、不同损伤程度以及正常情况下的6类数据,其标签和故障种类如表1所示。

选用效果更好的Ricker函数作为小波基函数对故障数据进行小波变换。为了增强小波图像对比度,将变换后的频域数据转换为PRGn颜色格式的三通道彩色图像,形状尺寸为 $64 \times 64 \times 3$ 。表2为故障数据的时域图和小波变换图。根据小波变换图可知,不同故障种类的频率分布有较大区别,而同一类别的小波图像相似,由此可知相同故障种类频率分布相似。

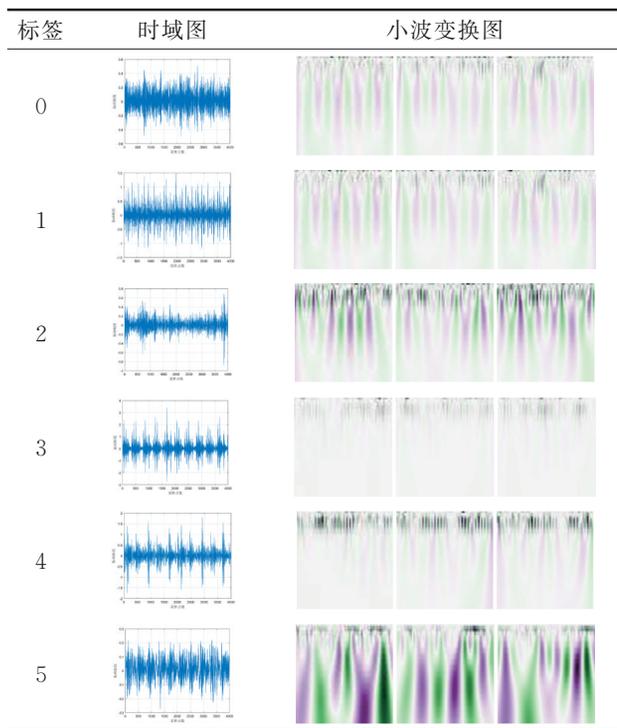
表1 标签与故障种类

Tab.1 Label and category

标签	损失直径/mm	损伤种类
0	0.177 8	滚珠
1	0.177 8	内圈
2	0.355 6	滚珠
3	0.533 4	内圈
4	0.533 4	外圈
5	正常情况	

表2 故障数据的时域图和小波变换图

Tab.2 Fault data time and frequency diagram



### 3.2 模型训练

#### 3.2.1 参数变化情况

将小波图像集作为输入DCGAN模型的真实样本集,为验证模型在不同数量样本集上的表现,使用不同数量的样本作为原始小样本故障集进行3组实验,每组实验输入的样本数如表3所示。

将3组实验样本输入同一训练模型。生成器输入64维高斯噪声,输出生成样本。判别器对真实样

表3 实验样本数

Tab.3 Number of experimental samples

实验	样本总和	平均每类样本数
1	382	64
2	770	128
3	1 434	240

本和生成样本做二元诊断。在训练过程中,每次抽取32个样本作为一个批次,共训练3 000批次,同时对生成样本图像进行存储。

以实验3的训练为代表,图7,8分别为3 000批次训练后,DCGAN模型下生成器和判别器的损失值变化曲线以及判别器准确率变化曲线。

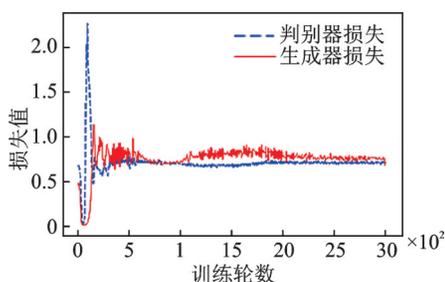


图7 生成器和判别器的损失值变化曲线

Fig.7 Generator and discriminator loss value change curve

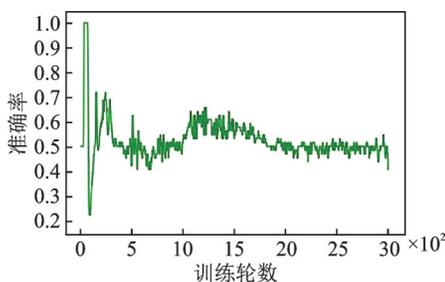


图8 判别器准确率变化曲线

Fig.8 Discriminator accuracy value change curve

由图7,8可知:①判别器的损失在训练初期振荡,但迅速减小并趋于平稳,生成器的损失值经过初期的剧烈振荡后也逐渐趋于平稳,二者损失值的变化趋势符合DCGAN网络训练的基本要求;②生成器在趋于稳定后,损失波动幅度较判别器大,这是因为判别器只需要完成二分类的任务,而生成器需要拟合真实数据分布,后者训练难度相对更大;③模型的判别器识别准确率在前期对抗训练的过程中有一定的波动,但经过3 000批次训练后,识别准确率稳定在0.5左右。这证明了生成器和判别器在经过多轮训练后达到纳什均衡。

上述损失和准确率等模型参数的变化均符合对生成对抗网络模型训练的基本预期要求。

### 3.2.2 生成样本与真实样本对比

以实验3为代表,真实样本图像与生成样本图像的对比如表4所示。

从图7,8及表4可以看出,模型训练优化程度已达到完善,真实样本图像与生成样本图像十分相似。

表4 真实样本图像与生成样本图像的对比

Tab.4 Comparison between real and generated samples

标签	真实样本图像	生成样本图像
0		
1		
2		
3		
4		
5		

### 3.3 模型验证

#### 3.3.1 检验模型结构

为验证DCGAN方法的有效性,将生成样本与扩充后样本集输入CNN网络进行再诊断。检验模型结构如图9所示。

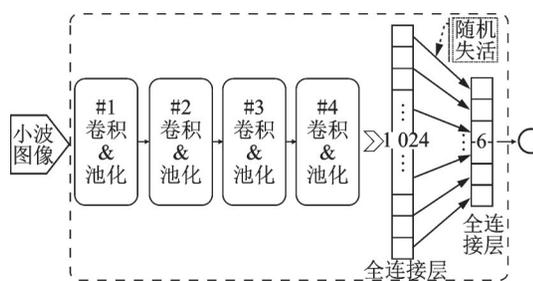


图9 检验模型结构

Fig.9 Structure of test model

检验模型由输入层、隐藏层和输出层3部分组成,接受小波图像作为输入,经训练输出分类诊断结果。隐藏层主要由4层卷积、4层卷积以及2层全连接层组成。4层卷积分别含有32,64,128,128组卷积核,使用ReLU函数激活。池化方式选择2×2最大池化;最后一个池化层与含1 024个神经元的全

连接层相连,经参数为 0.5 的随机失活层连接到由 softmax 激活的含有 6 个神经元的全连接层。检验模型使用学习率为 0.001 的 Adam 损失优化器进行优化,使用分类交叉熵损失函数计算模型的损失,每一批次输入 32 个样本,根据检验要求进行训练。

### 3.3.2 棋盘格效应的改善验证

棋盘格效应在图像最显著或色彩最强烈的区域内表现更为明显。根据表 2 可知,标签 5 对应的小波图像色彩更为强烈,在棋盘格效应的改进对比中更具有代表性,故选标签 5 改进前后生成图像的相似区域进行对比分析。图 10 为改进前后生成图像局部细节对比。

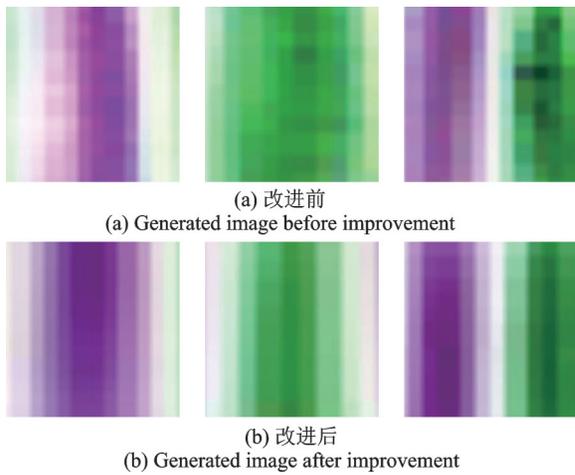


图 10 改进前后生成图像局部细节对比

Fig.10 Generated image comparison before and after improvement

改进前的生成图像具有较为明显的棋盘格效应,图像像素深浅分布不均匀,而添加 USCONV 层后,网络生成图像的棋盘格效应大大减弱,生成图像的像素分布更为均匀,更接近真实图像的分布,有利于生成图像对小样本库的扩充完善,提升了样本库训练识别的准确性。

### 3.3.3 模型准确性验证

选取 3 组实验中每一类生成样本最后保存的 210 张图片、共 1 260 张图片输入真实样本训练后的检验模型中进行准确性验证。图 11 为生成样本验证效果。

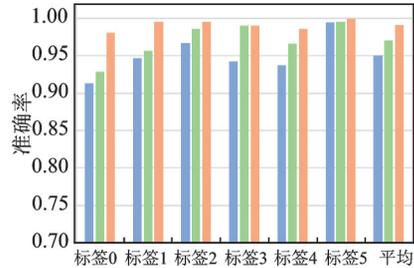


图 11 生成样本验证效果

Fig.11 Generated sample verification results

图 11 列出了 3 组实验中生成样本具体的准确率,最高平均识别准确率达 99.13%,最低平均可达 95% 以上,6 种轴承故障状况生成小波样本图像的真实程度都非常高,证明了基于 DCGAN 方法的模型能够有效提取频谱图像特征,以及模型在小样本故障库条件下故障诊断分析的可行性。

### 3.3.4 样本库扩充前后对比

将扩充前后的训练样本库分别输入笔者提出的检验模型、文献[13]以及文献[14]的模型中进行训练,并对包含 6 类故障类别、共 192 个测试样本的测试集进行识别。扩充前,原始小样本库训练集含有 6 类共 768 个样本,每一类平均含有 128 个样本。将实验 3 中 DCGAN 网络的生成样本加入训练集,对其进行样本扩充。扩充后,训练集的训练分为 2 部分:扩充样本集 1 共有 1 378 个样本,每一类含有 230 个样本;扩充样本集 2 共有 1 990 个样本,每一类含有 332 个样本。表 5 为样本库扩充前后故障诊断准确率对比。

表 5 样本库扩充前后故障诊断准确率对比

Tab.5 Results before and after sample expansion

训练集种类	样本数		准确率/%		
	总和	每一类	文献[13]模型	文献[14]模型	本检验模型
原始小样本集	768	128	93.75	88.54	91.67
扩充样本集 1	1 378	230	95.83	94.79	96.35
扩充样本集 2	1 990	332	97.22	95.83	98.96

可见,样本扩充后,3 种模型的故障诊断准确率都有大幅提高,在本检验模型中,最高提升了 7.29% 的识别率,验证了 DCGAN 算法在频域特征提取领

域的优势,同时,生成样本能够丰富并完善频域数据,明显改善过拟合问题,证明了 DCGAN 模型在小样本库完善与扩充方面的有效性。

## 4 结 论

1) DCGAN将CNN与GAN结合,利用小波变换得到滚动轴承故障的时频信息,并生成对比度更强的二维彩色图像。基于CNN在图像处理领域的优势,DCGAN能够有效提取图像特征,精准完成在小样本库条件下故障数据小波图像样本的生成,有效完成样本库的扩充和完善工作。

2) 设计USCONV层,用双线性插值的上采样结合卷积算法代替转置卷积,极大地克服了传统DCGAN转置卷积操作中易产生的棋盘格效应,提高了生成样本的质量。

3) 通过在检验模型上的对比验证可知:基于DCGAN方法生成的小波图像样本真实度高,平均识别准确率可达99.13%;扩充后的样本库对含有多类故障情况的测试集的诊断能力有大幅提升,诊断准确率最高可达98.96%。

## 参 考 文 献

- [1] 赵小强,张青青.改进 Alexnet的滚动轴承变工况故障诊断方法[J].振动、测试与诊断,2020,40(3):472-480. ZHAO Xiaoqiang, ZHANG Qingqing. Improved alexnet based fault diagnosis method for rolling bearing under variable conditions[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3):472-480. (in Chinese)
- [2] 谷玉海,朱腾腾,饶文军,等.基于EMD二值化图像和CNN的滚动轴承故障诊断[J].振动、测试与诊断,2021,41(1):105-113. GU Yuhai, ZHU Tengting, RAO Wenjun, et al. Fault diagnosis for rolling bearing based on EMD binarization image and CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1):105-113. (in Chinese)
- [3] ZHANG H, WANG R, PAN R, et al. Imbalanced fault diagnosis of rolling bearing using enhanced generative adversarial networks [J]. IEEE Access, 2020, 8: 185950-185963.
- [4] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [5] DING Y, MA L, MA J, et al. A generative adversarial network-based intelligent fault diagnosis method for rotating machinery under small sample size conditions [J]. IEEE Access, 2019, 7: 149736-149749.
- [6] 李忠智,尹航,左剑凯,等.不平衡训练数据下的基于生成对抗网络的轴承故障诊断[J].小型微型计算机系统,2021,42(1):46-51. LI Zhongzhi, YIN Hang, ZUO Jiankai, et al. Bearing fault diagnosis based on generative adversarial network on imbalanced data [J]. Journal of Chinese Computer Systems, 2021, 42(1):46-51. (in Chinese)
- [7] DU Y, ZHANG W, WANG J, et al. DCGAN based data generation for process monitoring[C]//2019 IEEE 8th Data Driven Control and Learning Systems Conference. Dali, China: IEEE, 2019: 410-415.
- [8] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [M/OL]. [2021-02-01]. <http://arxiv.org/abs/1511.06434>.
- [9] ANTIPOV G, BACCOUCHE M, DUGELAY J L. Face aging with conditional generative adversarial networks [C]//IEEE International Conference on Image Processing. [S. l.]: IEEE, 2017: 2089-2093.
- [10] VIOLA J, CHEN Y Q, WANG J. Fault face: deep convolutional generative adversarial network (DCGAN) based ball-bearing failure detection method[J]. Information Sciences, 2021, 542: 195-211.
- [11] ODENA A, DUMOULIN V, OLAH C. Deconvolution and checkerboard artifacts [J/OL]. [2020-09-23]. <http://doi.org/10.23915/distill>.
- [12] YANG Z, GAO L. Wavelet analysis and fault feature extraction of rolling bearing [C]//Engineering Asset Management 2011. London: Springer, 2014: 571-578.
- [13] GAO D, ZHU Y, WANG X, et al. A fault diagnosis method of rolling bearing based on complex morlet CWT and CNN [C]//2018 Prognostics and System Health Management Conference. Chongqing: [s. n.], 2018: 1101-1105.
- [14] VERSTRAETE D, FERRADA A, LOPEZ D E, et al. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings[J]. Shock and Vibration, 2017(6):1-17.



**第一作者简介:**柳雅倩,女,1998年6月生,硕士生。主要研究方向为工业智能传感器。

E-mail: liuyaqian06@qq.com

**通信作者简介:**蔡浩原,男,1977年4月生,博士、副研究员。主要研究方向为MEMS传感器及其微系统、无线工业物联网传感器及移动机器人室内导航。

E-mail: hycail@mail.ie.ac.cn