

DOI: 10.19783/j.cnki.pspc.210939

# 基于改进降噪自编码器的风机轴承故障诊断方法

宋威<sup>1</sup>, 林建维<sup>1</sup>, 周方泽<sup>2</sup>, 李召岩<sup>2</sup>, 赵凯<sup>2</sup>, 周晖<sup>2</sup>

(1. 国投电力控股股份有限公司, 北京 100034; 2. 北京交通大学电气工程学院, 北京 100044)

**摘要:** 滚动轴承是风电机组中故障最为频繁的部件之一, 准确有效的轴承故障诊断方法有助于保障风电机组安全稳定运行。针对轴承振动信号特征微弱、难以诊断的问题, 提出了一种基于改进降噪自编码器的风电机组轴承故障检测方法。首先引入了一维信号的图像化预处理, 将原始的时域信号转化为二维特征灰度图。然后利用卷积神经网络在图像特征提取上的强大优势, 构建了堆叠降噪自编码器与卷积神经网络的集成模型, 去除了传统卷积神经网络中的池化层, 进一步提升提取特征的鲁棒性和泛化性。整体诊断流程由数据驱动, 减少了对于经验的依赖。最后的实验结果表明, 该方法能够精确诊断不同类型的轴承故障。此外, 通过与其他方法的对比实验进一步验证了该方法在故障诊断方面的优越性。

**关键词:** 风电机组; 轴承; 故障诊断; 降噪自编码器

## Wind turbine bearing fault diagnosis method based on an improved denoising AutoEncoder

SONG Wei<sup>1</sup>, LIN Jianwei<sup>1</sup>, ZHOU Fangze<sup>2</sup>, LI Zhaoyan<sup>2</sup>, ZHAO Kai<sup>2</sup>, ZHOU Hui<sup>2</sup>

(1. SDIC Power Holding Co., Ltd., Beijing 100034, China; 2. College of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** The rolling bearing is one of the most frequently faulty components in wind turbines. Accurate and effective bearing fault diagnosis methods can help ensure safe and stable operation. Bearing vibration signal characteristics are weak and difficult to diagnose, so a fault diagnosis method based on an improved denoising AutoEncoder is proposed. First, a one-dimensional signal imaging method to convert the original time domain signal into a two-dimensional feature grayscale image is introduced. Secondly, using the advantage of a convolutional neural network in image feature extraction, a combination model based on a stacked denoising AutoEncoder and convolutional neural network is proposed. The pooling layer in the traditional convolutional neural network is removed to ensure the robustness and generalization of extracted features. The overall diagnosis process is driven by data, reducing reliance on expert experience. Lastly, experimental results show that this method can accurately diagnose different types of bearing faults. Comparison experiments with other methods further verify the superiority of this method in fault diagnosis.

This work is supported by the National Key Research and Development Program of China (No. 2017YFB0903403).

**Key words:** wind turbine; rolling bearing; fault diagnosis; denoising AutoEncoder

## 0 引言

在“碳达峰”“碳中和”国家战略减碳目标为牵引的能源革命大背景下, 风电作为一种绿色能源<sup>[1]</sup>, 是推动“双碳”目标实现的关键环节。风力发电机

组叶轮通过主轴与机舱连接, 该过程的动能传递枢纽是主轴轴承。主轴轴承在风力发电机组中的重要性极为突出, 其运转状态关系着整个机组的运行状态, 一旦故障将产生高额的维修费用和长时间的停机。研究表明, 轴承故障作为风电机组最常见的故障之一, 占整体机械故障的 1/3<sup>[2]</sup>。轴承振动信号通常表现为时变、非线性、非平稳信号, 并且在采集过程中掺杂着大量噪声, 导致轴承在不同故障情形下的振动信号特征微弱, 识别困难<sup>[3]</sup>。如何在缺乏

**基金项目:** 国家重点研发计划项目资助(2017YFB0903403); 国投电力控股股份有限公司科技项目大规模风电场设备检修维护优化决策研究(000052-21XB0008)

先验知识的情况下对轴承故障进行快速、准确的诊断，对于维护风电机组持续稳定运行具有重要的实际意义。

振动分析法是目前应用最为广泛的风电机组轴承故障诊断方法，该方法首先利用加速度或者速度传感器采集轴承运行过程中的加速度或速度振动信号，然后利用合适的信号处理方法将故障的特征提取出来，最后进行故障模式的识别<sup>[4]</sup>。针对这一问题，长期以来国内外专家应用了不同的建模方法与数据处理技术进行了探索<sup>[5]</sup>。但大致的过程基本类似，即先对原始的时域信号进行处理和变换，然后提取信号特征，最后应用机器学习等方法进行故障诊断的建模。如通过傅里叶变换<sup>[6]</sup>、小波变换<sup>[7]</sup>、短时傅里叶变换<sup>[8]</sup>等方法，将原始的一维时域信号转为频域或时频域信号，对振动信号进行预处理和特征提取，再利用机器学习方法对特征进行分类，完成轴承故障的识别与诊断。文献[9]使用三层小波包分解提取故障特征，并基于改进的多分类相关向量机完成故障分类，文献[10]人为选取了 9 个时域特征向量，利用极限学习机来对轴承故障进行诊断。以上方法虽然取得了较高的诊断准确率，但都涉及人工特征选取过程，而这一过程具有相当的主观性，特征值选取的准确性将最终影响到故障诊断结果。

随着机器学习技术的发展，深度学习提供了一种“端到端”的解决方案，通过构建深层次的非线性网络，建立振动数据与设备运行状态之间精确的映射关系，避免了人为的特征设计过程。文献[11]利用深度信念网络直接从原始振动数据中学习分布不变特性，克服了工况变化导致特征分布变化的缺点，提高了故障诊断准确率；文献[12]提出了一种基于多尺度卷积神经网络的诊断模型，进一步增强了网络提取特征的鲁棒性，提升了诊断精度；文献[13]提出了一种时频域建模方法，综合考虑了发电机轴承故障信号的时域信息和频域信息，通过门控循环神经网络对五种不同的故障进行诊断。

自编码器(AutoEncoder, AE)作为一种特征提取模型，在数据降维和特征提取方面性能优越，由 AE 衍生出的深度神经网络已经广泛应用于轴承故障诊断，并取得了较高的诊断准确率<sup>[14]</sup>。文献[15]以堆叠自编码器作为主要架构，通过计算样本间的特征距离，进一步提升了模型的特征提取能力，最后用支持向量机完成故障的分类；文献[16]提出了由三种不同自编码器模型构成的集成(ensemble)模型，通过动态加权平均对各编码器学习到的特征进行集成，整体的故障诊断精度达到了 99%；文献[17]首先计算原始时域信号的相关峭度值，基于全连接神

经网络构建了深度自编码器，对振动信号进行故障识别；文献[18]构建了一种基于奇异值分解的稀疏自编码器轴承故障诊断模型。以上研究表明，将自编码器与其他模型进行混合集成或者改进数据预处理技术，能够进一步提升其特征学习的能力<sup>[19]</sup>。

基于以上研究，提出了一种改进的降噪自编码器(Denosing AutoEncoder, DAE)轴承故障诊断集成模型，在数据预处理技术和网络结构上进行了改进。在数据预处理上，引入了将原始一维时域信号转化为二维灰度图像的方法<sup>[20]</sup>，利用二维卷积神经网络实现信号特征的提取，深度挖掘故障特征。在网络结构上，去掉了传统 CNN 网络中的池化层，完整地保留了原始一维振动信号的信息，进一步提升了模型的鲁棒性和泛化性，在每个卷积层后加入批归一化层，加速网络训练速度。实验结果表明，提出的故障检测模型能够高精度地实现轴承故障的识别和分类。

## 1 基本原理

### 1.1 自编码器

自编码器是一种通过无监督方式来学习一组数据有效特征的神经网络模型<sup>[21]</sup>。自编码器网络结构可以分为编码网络(Encoder)和解码网络(Decoder)两个部分，如图 1 所示。编码网络学习原始数据  $x$  的有效特征生成隐变量  $z$ ，解码网络尝试通过隐变量  $z$  重构生成  $\hat{x}$ ，学习目标是使得重构误差最小化，网络参数优化目标可以描述为

$$f, g = \arg \min_{f, g} L(x, f(g(x))) \quad (1)$$

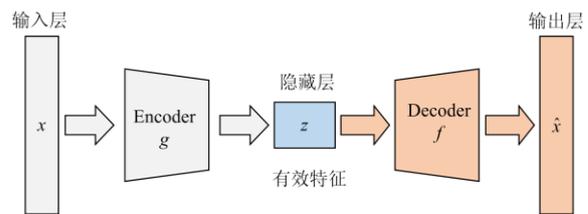


图 1 自编码器网络结构

Fig. 1 Network structure of AutoEncoder

自编码器在训练过程中无需使用样本标签，其本质是将样本的输入同时作为神经网络的输入和输出，通过最小化重构误差来学习样本的有效特征。该特性使得自编码器可以作为强大的特征提取器，应用于深度模型的预训练。在预训练结束后，编码器的输出可以直接作为后续模型的输入。

### 1.2 降噪自编码器

高维数据一般都具有一定的信息冗余，使用自

编码器是为了得到有效的数据表示, 而有效的数据表示除了具有最小重构错误的性质外, 还可以要求其具备其他性质, 比如对数据部分损坏(Partial Destruction)的鲁棒性。降噪自编码器是一种通过引入噪声来增加编码鲁棒性的自编码器<sup>[22]</sup>, 核心思想是在输入层中加入随机噪声进行训练, 通过对污染数据的特征映射还原原始无污染的数据, 从而使得编码器能够学习到更具鲁棒性和泛化性的特征表达。

设  $\mathbf{X} = (x_1, x_2, \dots, x_n)$  为原始信号, 通过随机置零或添加噪声的方法“污染”,  $\mathbf{X}$  并生成带噪声信号  $\mathbf{X}' = (x'_1, x'_2, \dots, x'_n)$ , 这一过程可以表示为<sup>[23]</sup>

$$\mathbf{X}' \sim N(\mathbf{X}' | (\mathbf{X} + N)) \quad (2)$$

式中,  $N$  为由原始输入层和加入  $\mathbf{X}$  随机噪声的类型确定的一种分布。然后通过编码器网络  $g$  将  $\mathbf{X}'$  映射至隐含层, 如式(3)所示。

$$\mathbf{z} = g(\mathbf{W}\mathbf{X}' + \mathbf{b}) \quad (3)$$

式中:  $\mathbf{z}$  为隐藏层的有效特征;  $\mathbf{W}$  为映射至隐藏层网络的权重参数;  $\mathbf{b}$  为映射至隐藏层网络的偏置项。 $\mathbf{z}$  在经过解码器的反向映射后, 最终构造出一个与原始信号相同的输出  $\hat{\mathbf{X}}$ , 如式(4)所示。

$$\hat{\mathbf{X}} = f(\mathbf{W}'\mathbf{z} + \mathbf{b}') \quad (4)$$

式中:  $\mathbf{W}'$  为有效特征逆映射至输出层网络的权重参数;  $\mathbf{b}'$  为反映至网络层输出的偏置项。目标结果是使得输出值  $\hat{\mathbf{X}}$  尽可能地接近原始信号  $\mathbf{X}$ , 构建一个平方重构误差函数如式(5)所示, 并对该函数进行最小化, 从而得到优化后的权重和偏置项等网络参数, 如式(6)所示。

$$L(\mathbf{W}, \mathbf{b}) = \sum_{i=1}^n (\hat{x}_i - x_i)^2 \quad (5)$$

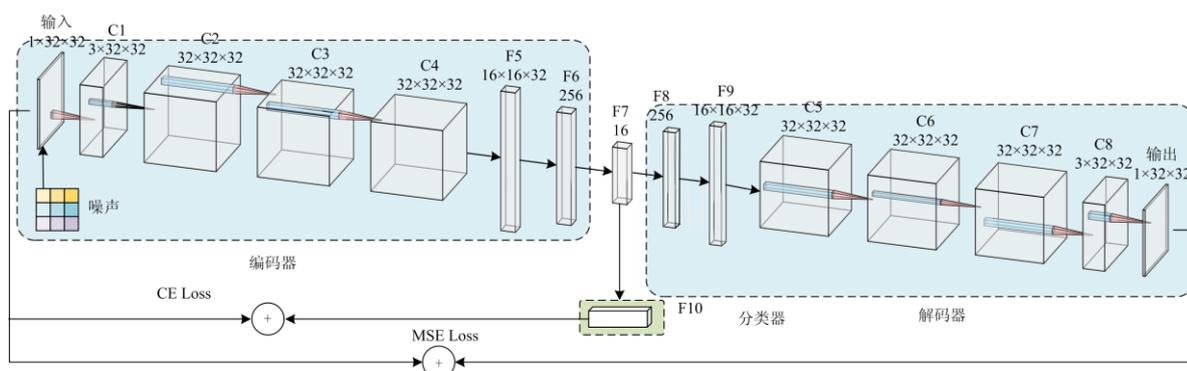


图2 基于降噪自编码器的轴承故障诊断框架

Fig. 2 Bearing fault diagnosis framework based on denosing AutoEncoder

为了充分保留信号的边缘信息, 对输入卷积层的灰度图像进行像素填充, padding 取值为1; 同时考虑到原始振动信号特征微弱, 且输入灰度图像维

$$\mathbf{W}_{\text{opt}}, \mathbf{b}_{\text{opt}}, \mathbf{W}'_{\text{opt}}, \mathbf{b}'_{\text{opt}} = \arg \min_{\mathbf{W}_{\text{opt}}, \mathbf{b}_{\text{opt}}, \mathbf{W}'_{\text{opt}}, \mathbf{b}'_{\text{opt}}} (L(\mathbf{W}, \mathbf{b})) \quad (6)$$

式中, 下标 opt 代表了网络权重和偏置的最优值。

### 1.3 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是一种具有局部连接、权重共享等特性的深层前馈神经网络, 在模式分类领域被广泛使用, 关于CNN的详细结构与原理可参见文献<sup>[24]</sup>。

在信号处理中, 通常采用一维卷积神经网络。由于一维卷积神经网络存在感受野(Receptive Field)受限和过拟合的风险, 一些研究者将一维的原始信号转化为二维特征图来对模式进行识别。文献<sup>[20]</sup>引入了一种灰度图像变换方法, 文献<sup>[25]</sup>则将原始信号映射至极坐标系, 转化为格拉姆角场(Gramian Angular Field, GAF)特征图, 再利用卷积神经网络在图像识别上的强大优势, 完成原始信号的诊断与分类。这些预处理方法能够更多地保留原信号的特征, 提升故障诊断的精度。

## 2 轴承故障诊断框架

### 2.1 改进的降噪自编码器

本文提出了一种降噪自编码器与卷积神经网络的集成模型, 整体网络结构如图2所示, 包含了一个编码器、一个解码器和一个故障分类器。其中自编码器网络由4层卷积神经网络(C1~C4)和两层全连接神经网络构成(F5~F6), 在每个2D卷积层后均添批归一化(Batchnorm)层, 提升神经网络的训练速度<sup>[26]</sup>, 激活函数选择整流线性单元(Rectified Linear Unit, ReLU), 避免深度网络中梯度消失的问题。

度较低, 去除了传统卷积神经网络中的池化层(Pooling)。原始输入在经过编码器后被压缩为(1x16)的一维有效特征, 解码器的网络结构与编码器基本

对称, 区别在于用反卷积层(C5~C8)替代了编码器中的卷积层。相似地, 在解码器的每一个反卷积层后添加批归一化层, 激活函数选择 ReLU。在编码器完成有效特征提取后, 设置了一个由全连接神经网络构成的分类器(F10), 完成轴承故障分类的任务。

## 2.2 轴承故障诊断流程

轴承故障检测模型训练过程分为两个阶段, 自编码器预训练和分类器训练, 整体流程如图 3 所示。

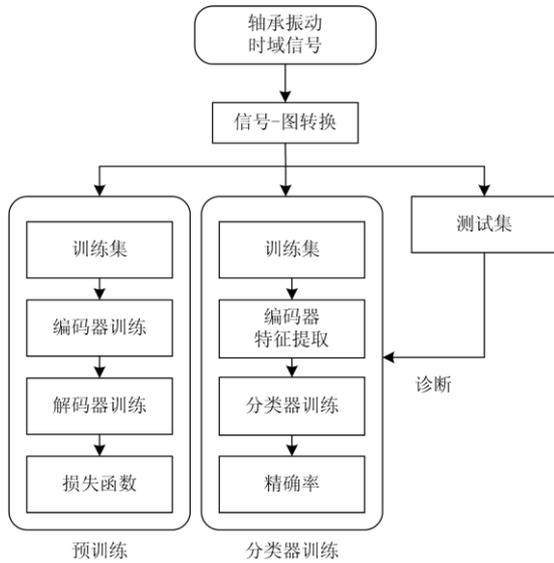


图 3 轴承故障训练-诊断流程

Fig. 3 Bearing fault training-diagnosis process

预训练阶段通过向灰度图像中添加随机噪声, 得到含噪数据, 进一步通过自编码器得到重构图像。预训练的目标是保证编码器能够在含噪声的情况下提取到输入的有效特征, 使得解码器的重构输出尽可能地与输入接近, 即最小化均方误差损失。

$$\min L_{\text{MSE}} = \sum_{i=1}^n (\hat{x}_i - x_i)^2 \quad (7)$$

设置预训练轮次为 50 次, 采用 Adma 优化器更新网络参数, 批次大小为 32, 学习率设置为 0.001, 通过输出损失函数判断模型的鲁棒性。

预训练结束后, 编码器已经能够从输入信号中提取出有效特征并映射至低维隐藏空间。进一步通过训练分类器来实现轴承故障的检测和分类, 训练的目标函数是分类器的预测标签  $\hat{y}$  尽可能地符合实际标签  $y$ , 即最小化交叉熵损失。

$$\min L_{\text{CE}} = \left(-\sum_{i=1}^n y_i \log(\hat{y}_i)\right) \quad (8)$$

对于分类器, 同样设置训练轮次为 50 次, 优化器选择 Adam, 批次大小为 32, 学习率为 0.001, 通

过数据集验证故障诊断模型分类准确率。

## 3 实验验证

使用配置为 Intel I7 3.0 GHz CPU、16 GB RAM、GTX 1050 Ti GPU 以及系统为 Windows10 64 位操作系统的 PC, 以 Pytorch 为深度学习框架编制 Python 程序, 以公开数据集对所提模型的性能进行了验证。

### 3.1 实验数据集

采用美国凯斯西储大学(Case Western Reserve University, CWRU)的公开轴承数据作为实验数据集, CWRU 数据集作为标准数据集, 被广泛用于滚动轴承故障诊断算法的测试<sup>[27]</sup>。轴承故障采集实验平台如图 4 所示, 由 1 个 2hp 的电机、力矩传感器、测力器和控制系统组成, 采用电火花加工模拟轴承故障。其中故障类型分为内圈故障(IR Fault)、外圈故障(OR Fault)和滚动体故障(BA Fault), 不同故障类型又分为 0.007 mm、0.014 mm 和 0.021 mm 三种不同的损伤尺寸, 故数据集中共包括 9 种故障信号和 1 种正常信号。

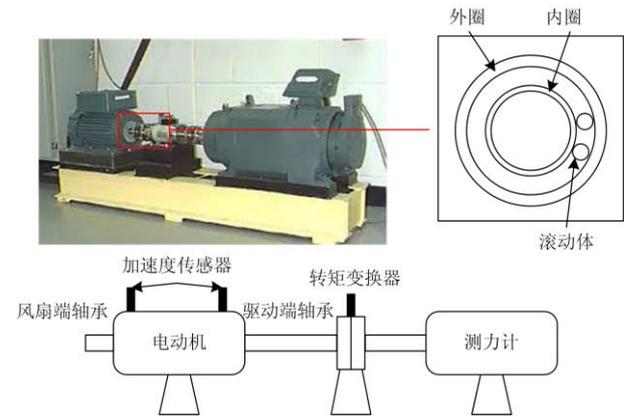


图 4 CWRU 数据实验平台

Fig. 4 Experimental platform of CWRU dataset

选择驱动端传感器数据用于分析, 将原始信号按 1 024 个点进行截取, 共得到 1 305 条时域数据。将数据的 80% 随机划分为训练集、20% 随机划分为测试集进行实验。

### 3.2 数据预处理

为了保证数据符合卷积神经网络的输入要求, 将一维的时域信号按照文献[20]的方法转换成为二维灰度图像, 转换后的信号维度为(32×32)。这种数据处理方法的优点是不依赖人工经验, 并保留了原始信号特征。不同类型故障对应的灰度图如图 5 所示。

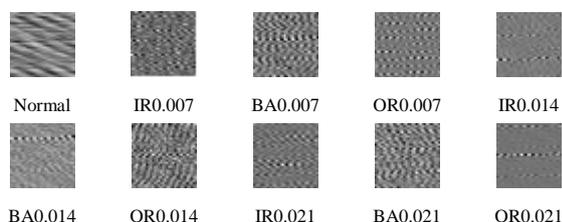


图5 轴承故障信号灰度转化图

Fig. 5 Bearing fault signal grey-image conversion

信噪比(Signal Noise Ratio, SNR)是指在某段信号中目标信号功率与噪声信号功率的比值, 在一定程度上能够反映信号的质量, 信噪比计算公式为

$$\text{SNR} = 10 \lg \frac{P_{\text{signal}}}{P_{\text{noise}}} \quad (9)$$

式中,  $P_{\text{signal}}$ 、 $P_{\text{noise}}$  分别为目标信号功率和噪声信号功率, 单位为 dB。信噪比越大, 混杂在该信号中的噪声越少。在原始信号中加入 10 dB 的随机噪声信号, 加入噪声后的故障信号灰度转化结果如图 6 所示。

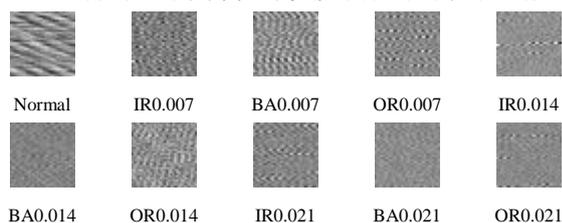


图6 加入随机噪声后的轴承故障灰度图

Fig. 6 Bearing fault grey-image with random noise

可以看出, 不同轴承故障类型表征出不同的纹理和形状, 这意味着可以利用降噪自编码器的特征提取能力, 隐式地学习到这些特征并利用其进行识别和分类。

### 3.3 实验结果

为了进一步提升训练速度, 整体训练过程部署在 GPU 上运行, 整体训练过程中的损失函数变化如图 7 所示。

由图 7 可知, 大约经过 35 个训练轮次后, 预训练过程中的均方误差损失函数开始收敛, 在 0.01 上下小幅振荡。第二阶段的分类器交叉熵损失约在训练 20 个轮次后开始收敛, 在第 40 个轮次后达到稳定, 在训练集上的损失约为 0.000 1, 略小于在测试集上的损失。预训练耗时为 59.86 s, 分类器训练耗时为 26.78 s, 第二阶段耗时比预训练阶段短, 其原因是无须将编码器提取到的有效特征送入解码器进行重构, 分类器为一层全连接神经网络, 其参数远少于由 4 层卷积神经网络构成的解码器。需要指出的是, 在预训练完成后才进行分类器的训练。

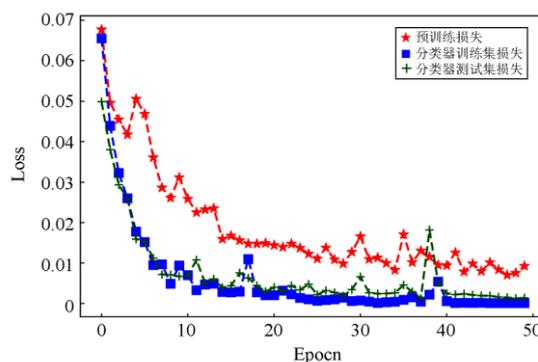


图7 训练损失函数变化

Fig. 7 Change of training loss function

为了验证模型自适应提取特征的能力, 利用 Tsne 降维算法将测试集原始的高维数据映射至二维空间, 绘制散点图如图 8 所示, 每一种颜色代表不同类型的轴承故障。可以看到, 原始轴承振动故障信号的特征相互重叠, 难以进行区分。同样地, 将编码器卷积层 C4 提取出的特征映射至二维空间进行可视化, 如图 9 所示, 经过卷积神经网络的特征

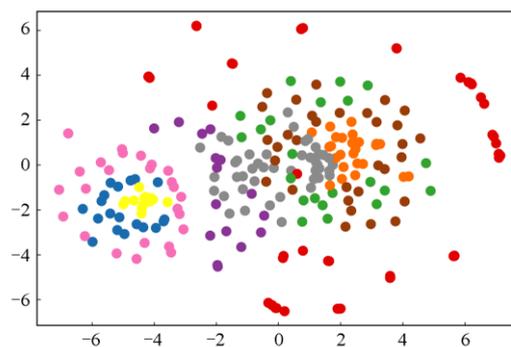


图8 原始数据特征降维可视化

Fig. 8 Dimension reduction visualization of original data

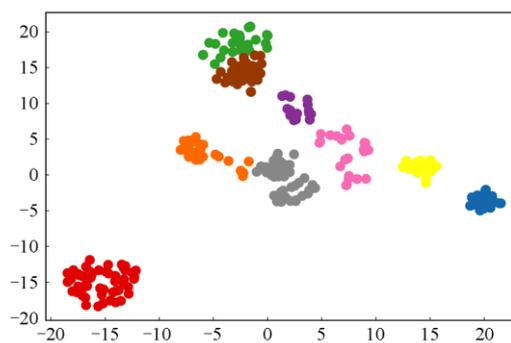


图9 卷积层 C4 提取特征降维可视化

Fig. 9 Dimension reduction visualization of the output features of convolutional layer C4

提取后,不同类型的故障分布在二维空间的不同区域,区分度明显,证明了模型在特征提取上的有效性。

训练集和测试集的故障诊断准确率如图 10 所示,随着训练轮次的增加,模型整体的检测精确率逐步上升,约在 20 个训练轮次后达到稳定,在测试集上的准确率达到到了 99.60%。在图像像素为 32×32 和 10 dB 噪声信号干扰的情况下,诊断准确率较文献[20]提升了约 7%。

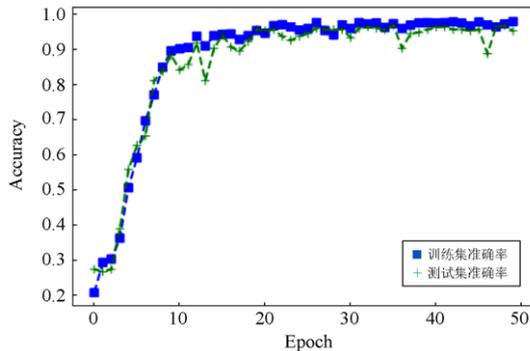


图 10 训练集与测试集诊断准确率

Fig. 10 Diagnosis accuracy of train set and test set

采用混淆矩阵来评估分类器可信度,混淆矩阵显示了分类器所有可能的分类结果。图 11 为模型在测试集上的故障识别矩阵,其中列对应于故障的实际类别,行对应于分类器的预测类别,0~9 分别代表轴承不同类型的故障标签。可以看出,除了一个实际为 BA0.021 的故障被误识别为 BA0.007 的故障外,其余故障检测结果均正确。实验结果证明提出的降噪自编码器风机轴承故障识别模型能够提取原始数据的有效特征,故障分类准确率高。

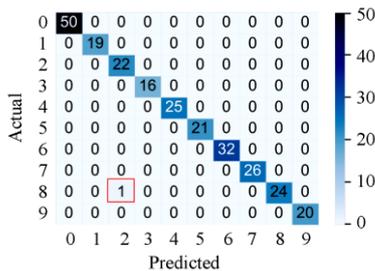


图 11 故障诊断结果混淆矩阵

Fig. 11 Confusion matrix of fault diagnosis results

### 3.4 噪声干扰验证

为了验证模型在不同噪声信号下的表现,向数据集集中的故障信号分别加入 14 dB、12 dB、8 dB 和 6 dB 的随机噪声信号进行实验,验证结果如表 1 所示。

表 1 不同噪声信号下诊断准确率

Table 1 Diagnosis accuracy with different noise

信噪比	14 dB	12 dB	10 dB	8 dB	6 dB
准确率/%	98.43	99.21	99.60	97.98	96.93

由表 1 可知,在噪声信号较小(14 dB 和 12 dB)时,降噪自编码器所提取的特征泛化性和鲁棒性相较于 10 dB 噪声时稍弱,但是整体识别率仍然保持在一个较高的水平。随着噪声信号的进一步增大,在一定程度上破坏了原始数据的分布,导致整体识别率开始下降。这说明降噪自编码器在预训练时需要加入合适的噪声信号,过大或过小的噪声信号都会影响降噪自编码器的性能。因而,人为加入的噪声信号可以视为一个超参数,加入合适的噪声信号可以增强模型特征提取的鲁棒性。

### 3.5 对比实验

为进一步验证该方法的优越性,分别将一维原始振动信号和二维灰度图像作为输入,进行普通降噪自编码器、稀疏自编码器、降噪自编码器三种模型的对比实验。区别在于普通自编码器去掉了噪声输入,稀疏自编码器在普通自编码器的基础上加入了一个稀疏性损失,以限制神经网络神经元的激活概率<sup>[28]</sup>,施加的稀疏性损失用 KL 散度(Kullback-Leibler Divergence)度量,表示为

$$KL(\rho^* \parallel \rho_j) = \log \frac{\rho^*}{\rho_j} + (1 - \rho^*) \log \frac{1 - \rho^*}{1 - \rho_j} \quad (10)$$

式中:  $\rho_j$  为第  $j$  个神经元激活的概率;  $\rho^*$  为一个超参数,即期望的神经元激活概率,在对比实验中设置为 0.5。由式(10)可以看出,当  $\rho_j = \rho^*$  时,  $KL = 0$ ,即稀疏性损失达到最小,从而实现对神经网络的稀疏约束,迫使编码器实现对数据特征的稀疏提取,增强自编码器的性能。

对于原始一维时域信号,三种自编码器网络的编码器(F1~F4)和解码器(F6~F9)均用四层全连接网络构建,网络结构参数如表 2 所示。为了提升全连接神经网络的泛化性,隐藏层的神经元数设置为 64,同样在各全连接层间加入批归一化层加速运算,激活函数选择 ReLU。对于降噪自编码器,在输入中加入 10 dB 的随机噪声信号。

对于二维灰度图像信号,普通自编码器和稀疏自编码器的网络结构均与第 2 节中一致,对比实验结果如表 3 所示。

由表 3 可知,三种自编码器网络在原始时域信号的表现均不佳,整体轴承故障分类识别率在 70% 左右,引入二维灰度图像的数据预处理方式能够显著地提高模型的识别能力,这也说明了卷积神经

网络在特征提取上的性能要显著优于全连接神经网络。普通自编码器和稀疏自编码器在以二维灰度图像作为输入时, 均取得了较高的分类准确率, 稀疏自编码器略高于普通自编码器。实验结果表明, 所提出的模型能够作为风机轴承故障检测与分类的有效诊断方法。

表 2 一维自编码器网络结构

Table 2 Network structure of 1-D AutoEncoder

编号	网络层	神经元数
F1	全连接层 1	1 024
F2	全连接层 2	512
F3	全连接层 3	256
F4	全连接层 4	128
F5	全连接层 5	64
F6	全连接层 6	128
F7	全连接层 7	256
F8	全连接层 8	512
F9	全连接层 9	1 024

表 3 对比实验结果

Table 3 Results of comparison experiments

检测模型	输入	分类准确率
普通自编码器	原始时域信号	64.37%
	二维灰度图像	93.19%
稀疏自编码器	原始时域信号	67.28%
	二维灰度图像	95.47%
降噪自编码器	原始时域信号	70.92%

## 4 结论

针对风电机组滚动轴承故障特征微弱、诊断困难等问题, 提出了一种改进的降噪自编码器诊断方法, 引入了一维振动信号灰度图像化的数据预处理方法, 并对自编码器的特征提取网络进行了改进。该方法能够从带噪信号中学习更具鲁棒性和泛化性的有效特征表征, 避免了需要经验的人为特征选取过程, 是一种端到端(end to end)的故障识别与检测方法。通过与普通自编码器和稀疏自编码的对比实验, 证明了该集成方法在故障诊断上的优越性。

## 参考文献

- [1] BADAL F R, DAS P, SARKER S K, et al. A survey on control issues in renewable energy integration and microgrid[J]. Protection and Control of Modern Power Systems, 2019, 4(1): 87-113.
- [2] HUANG W, CHENG J, YANG Y. Rolling bearing fault diagnosis and performance degradation assessment under variable operation conditions based on nuisance attribute projection[J]. Mechanical Systems & Signal Processing, 2019, 114(1): 165-188.
- [3] 常淼, 沈艳霞. 基于改进卷积神经网络的风电轴承故障诊断策略[J]. 电力系统保护与控制, 2021, 49(6): 131-137. CHANG Miao, SHEN Yanxia. Fault diagnosis strategy of a wind power bearing based on an improved convolutional neural network[J]. Power System Protection and Control, 2021, 49(6): 131-137.
- [4] 刘文艺. 风力发电机组振动监测与故障诊断技术[M]. 北京: 中国矿业大学出版社, 2016.
- [5] 王致杰, 徐余法, 刘三明. 大型风力发电机组状态监测与智能故障诊断[M]. 上海: 上海交通大学出版社, 2013.
- [6] 欧璐, 于德介. 路图傅里叶变换及其在滚动轴承故障诊断中的应用[J]. 机械工程学报, 2015, 51(23): 76-83. OU Lu, YU Dejie. Path graph fourier transformation and its applications to rolling bearing fault diagnosis[J]. Journal of Mechanical Engineering, 2015, 51(23): 76-83.
- [7] CHEN J, PAN J, LI Z, et al. Generator bearing fault diagnosis for wind turbine via empirical wavelet transform using measured vibration signals-ScienceDirect[J]. Renewable Energy, 2016, 89: 80-92.
- [8] GAO H, LIANG L, CHEN X, et al. Feature extraction and recognition for rolling element bearing fault utilizing short-time fourier transform and non-negative matrix factorization[J]. Chinese Journal of Mechanical Engineering, 2015, 1(1): 96-105.
- [9] 王波, 王志乐, 熊鑫州, 等. 一种改进的 MRVM 方法及其在风电机组轴承诊断中的应用[J]. 太阳能学报, 2021, 42(1): 215-221. WANG Bo, WANG Zhile, XIONG Xinzhou, et al. An improved multi-class relevance vector and its application to wind turbine bearing diagnosis[J]. Acta Energetica Solaris Sinica, 2021, 42(1): 215-221.
- [10] 卢锦玲, 绳菲菲, 赵洪山. 基于极限学习机的风电机组主轴承故障诊断方法[J]. 可再生能源, 2016, 34(11): 1588-1594. LU Jinling, SHENG Feifei, ZHAO Hongshan. Fault diagnosis method of wind turbine main bearing based on extreme learning machine[J]. Renewable Energy Resources, 2016, 34(11): 1588-1594.
- [11] XING S B, LEI Y G, WANG S H, et al. Distribution in variant deep belief network for intelligent fault diagnosis of machines under new working conditions[J]. IEEE Transactions on Industrial Electronics, 2021, 68(3): 2617-2625.
- [12] 许子非, 金江涛, 李春. 基于多尺度卷积神经网络的滚动轴承故障诊断方法[J]. 振动与冲击, 2021, 40(18): 212-220. XU Zifei, JIN Jiangtao, LI Chun. New method for the fault diagnosis of rolling bearings based on a multiscale convolutional neural network[J]. Journal of Vibration and Shock, 2021, 40(18): 212-220.
- [13] 尹诗, 侯国莲, 胡晓东, 等. 风力发电机组发电机前轴承故障预警及辨识[J]. 仪器仪表学报, 2020, 41(5): 242-251. YIN Shi, HOU Guolian, HU Xiaodong, et al. Fault warning

- and identification of front bearing of wind turbine generator[J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 242-251.
- [14] 杜先君, 贾亮亮. 基于优化堆叠降噪自编码器的滚动轴承故障诊断[J/OL]. 吉林大学学报(工学版): 1-10[2021-10-11]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20210415>.
- DU Xiangjun, JIA Liangliang. Fault diagnosis of rolling bearing based on optimized stacked denoising auto encoders[J/OL]. Journal of Jilin University (Engineering and Technology Edition): 1-10[2021-10-11]. <https://doi.org/10.13229/j.cnki.jdxbgxb.20210415>.
- [15] CUI M, WANG Y, LIN X, et al. Fault diagnosis of rolling bearings based on an improved stack Autoencoder and support vector machine[J]. IEEE Sensors Journal, 2021, 21(4): 4927-4937.
- [16] ZHANG Y, LI X, GAO L, et al. Intelligent fault diagnosis of rotating machinery using a new ensemble deep auto-encoder method[J]. Measurement, 2020, 151.
- [17] 杨蕊, 李宏坤, 王朝阁, 等. 利用 FCKT 以及深度自编码神经网络的滚动轴承故障智能诊断[J]. 机械工程学报, 2019, 55(7): 65-72.
- YANG Rui, LI Hongkun, WANG Chaoge, et al. Intelligent fault detection for rolling element bearing based on FCKT and deep auto-coding neural network[J]. Journal of Mechanical Engineering, 2019, 55(7): 65-72.
- [18] 曹浩, 陈里里, 司吉兵, 等. 奇异值分解和稀疏自编码器的轴承故障诊断[J]. 计算机工程与应用, 2019, 55(20): 257-262, 270.
- CAO Hao, CHEN Lili, SI Jibing, et al. Singular value decomposition and sparse automatic encoder for bearing fault diagnosis[J]. Computer Engineering and Applications, 2019, 55(20): 257-262, 270.
- [19] 陈志强, 陈旭东, DE OLIVIRA JV, 等. 深度学习在设备故障预测与健康中的应用[J]. 仪器仪表学报, 2019, 40(9): 209-229.
- CHEN Zhiqiang, CHEN Xudong, DE OLIVIRA J V, et al. Application of deep learning in equipment prognostics and health management[J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 209-229.
- [20] 肖雄, 王健翔, 张勇军, 等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558-4568.
- XIAO Xiong, WANG Jianxiang, ZHANG Yongjun, et al. A two-dimensional convolutional neural network optimization method for bearing fault diagnosis[J]. Proceedings of the CSEE, 2019, 39(15): 4558-4568.
- [21] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2019.
- [22] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[C] // Proceedings of the Twenty-Fifth International Conference on Machine Learning (ICML 2008), June 5-9, 2008, Helsinki, Finland.
- [23] 殷敬伟, 罗五雄, 李理, 等. 基于降噪自编码器的水声信号增强研究[J]. 通信学报, 2019, 40(10): 119-126.
- YIN Jingwei, LUO Wuxiong, LI Li, et al. Enhancement of underwater acoustic signal based on denoising automatic-encoder[J]. Journal on Communications, 2019, 40(10): 119-126.
- [24] 王维博, 张斌, 曾文入, 等. 基于特征融合一维卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(6): 53-60.
- WANG Weibo, ZHANG Bin, ZENG Wenru, et al. Power quality disturbance classification of one-dimensional convolutional neural networks based on feature fusion[J]. Power System Protection and Control, 2020, 48(6): 53-60.
- [25] 郑炜, 林瑞全, 王俊. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97-104.
- ZHENG Wei, LIN Ruiquan, WANG Jun. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [26] IOFFE S, CHRISTIAN S. Batch normalization: accelerating deep network training by reducing internal covariate shift[C] // International Conference on Machine Learning, PMLR, July6-11, 2015, Lille, France.
- [27] SMITH W A. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study[J]. Mechanical Systems and Signal Processing, 2015, 64-65: 100-131.
- [28] 赵晶晶, 贾然, 陈凌汉, 等. 基于深度学习和改进 K-means 聚类算法的电网无功电压快速分区研究[J]. 电力系统保护与控制, 2021, 49(14): 89-95.
- ZHAO Jingjing, JIA Ran, CHEN Linghan, et al. Research on fast partition of reactive power and voltage based on deep learning and an improved K-means clustering algorithm[J]. Power System Protection and Control, 2021, 49(14): 89-95.

收稿日期: 2021-07-20; 修回日期: 2021-11-10

作者简介:

宋威(1973—), 男, 本科, 高级工程师, 研究方向为发电工程生产技术、风电设备可靠性管理; E-mail: songwei@sdic.com.cn

林建维(1991—), 男, 硕士, 工程师, 研究方向为发电工程生产技术、风电场技术监督管理; E-mail: 10021912@sdic.com.cn

周方泽(1993—), 男, 通信作者, 博士研究生, 研究方向为配电网建模仿真以及深度学习在新能源中的应用。E-mail: zhoufangze@gmail.com

(编辑 许威)