

DOI:10.19651/j.cnki.emt.2312607

# 基于 EMD-GAF 和改进的 SERE-DenseNet 的 滚动轴承故障诊断方法<sup>\*</sup>

赵国威 曾 静

(沈阳化工大学信息工程学院 沈阳 110000)

**摘要:**为了解决滚动轴承一维振动信号中故障特征微弱难以提取和深度学习模型层数加深容易导致梯度消失或梯度爆炸从而引起模型恶化、导致故障诊断准确率低和鲁棒性差的问题,本文提出一种基于 EMD-GAF 和改进的 SERE-DenseNet 的滚动轴承故障诊断方法。将滚动轴承一维振动信号通过滚动采样后利用 EMD 对其进行分解并重构,再使用 GAF 将重构的一维信号转换为二维图像作为模型输入,模型方面选取 DenseNet121 为主干,引入了 SERE 模块,并将 2 层卷积的 Dense Layer 改进为 3 层稀疏的、基数为 8 的模块;将二维图像作为输入通过该模型进行特征提取和故障分类。采用凯斯西储大学的轴承数据集进行仿真实验,实验结果表明,本文方法能够准确地完成滚动轴承故障诊断,故障诊断最大准确率 100%,10 次实验平均准确率 99.91%,与常见的深度学习模型进行比较,本文方法具有较大的优越性;在信噪比为 10 dB 的环境下故障诊断准确率为 96.48%,本文方法具有较强的鲁棒性。

**关键词:**故障诊断;滚动轴承;GAF;SERE-DenseNet

中图分类号: TP277 文献标识码: A 国家标准学科分类代码: 510.40

## Fault diagnosis method of rolling bearing based on EMD-GAF and improved SERE-DenseNet

Zhao Guowei Zeng Jing

(College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110000, China)

**Abstract:** In order to solve the problem of weak fault feature extraction in one-dimensional vibration signal of rolling bearing; In order to solve the problem that the deepening of deep learning model layer is easy to lead to the disappearance of gradient or the deterioration of gradient explosion, which leads to the low accuracy and poor robustness of fault diagnosis, this paper proposes a rolling bearing fault diagnosis method based on EMD-GAF and improved SERE-DenseNet. One-dimensional vibration signals of rolling bearings were decomposed and reconstructed by EMD after rolling sampling, and the reconstructed one-dimensional signals were converted into two-dimensional images by GAF as model input. DenseNet121 was selected as the main task in terms of model, and SERE module was introduced. The Dense Layer with 2 convolution layers is improved into 3 sparse modules with base number of 8. Feature extraction and fault classification are carried out by using 2D image as input. The bearing data set of Case Western Reserve University was used for simulation experiments. The experimental results show that the proposed method can accurately diagnose rolling bearings, with the maximum accuracy of 100% and the average accuracy of 99.91% in 10 experiments. Compared with the common deep learning model, the proposed method has great advantages. The fault diagnosis accuracy is 96.48% when the signal to noise ratio is 10 dB, and the proposed method has strong robustness.

**Keywords:** fault diagnosis; rolling bearing; GAF; SERE-DenseNet

## 0 引言

滚动轴承在现代工业中有着广泛的应用,同时滚动轴

承常处在恶劣的工作环境中,容易发生故障,从而引发连锁反应造成严重的影响,为了滚动轴承的稳定运行,滚动轴承的故障诊断非常重要<sup>[1]</sup>。

收稿日期:2023-01-11

\* 基金项目:国家自然科学基金(61503257,61673279)、国家重点研发计划重点专项基金(2018YFB2003704)项目资助

滚动轴承在运行时会产生振动,而发生故障时会产生异常的振动,不同的故障位置、不同的故障点大小也会产生不同的振动信号<sup>[2]</sup>,随着信号采集和状态监测技术的提升,通过分析滚动轴承的振动信号进行故障诊断有了广泛的应用和发展,并取得了较高的准确率和效率。通过滚动轴承振动信号进行故障诊断的传统方法,如焦静等<sup>[3]</sup>提出一种改进的支持向量机,通过使用不同的核函数和函数参数,并结合梯度下降法实现自适应的核函数权值,实现了滚动轴承故障诊断。但滚动轴承的工作环境恶劣,其振动信号具有非线性和非平稳的特征,故障特征微弱难以提取,故传统故障诊断方法效果仍有提升空间。

随着计算机技术和运算能力的进步,卷积神经网络(convolutional neural network,CNN)凭借其强大的特征提取能力在数据驱动的故障诊断中迎来了蓬勃的发展。袁建虎等<sup>[4]</sup>基于 CNN 和连续小波变换进行故障诊断,通过连续小波变换获得滚动轴承的时频矩阵,并以灰度图的形式作为 CNN 的输入进行自适应特征提取和故障分类。谷玉海等<sup>[5]</sup>通过经验模态分解滚动轴承振动信号后,选取相对关系最大的本征模函数分量进行频谱分析,获得频谱图并压缩为二值化图像作为 CNN 的输入实现故障分类。张龙等<sup>[6]</sup>引入递归图编码技术,将一维的滚动轴承振动信号转换为增强信号特征的二维纹理图像,将这些图像输入到残差网络中,结合残差网络对二维图像进行自适应特征提取,最终完成故障诊断。上述方法在故障诊断上具有一定的准确率,但存在数据特征提取不充分,网络深度受限,加深网络层数会导致梯度消失或者梯度爆炸导致网络退化的问题也会导致故障诊断的效果变差,从而无法通过加深网络层数提升模型的特征提取能力<sup>[7]</sup>。

为了解决上述问题,本文提出一种基于 EMD-GAF 和改进的 SERE-DenseNet 的滚动轴承故障诊断方法。选取密集连接卷积网络(densely connected convolutional network,DenseNet)作为模型主干,DenseNet 中每层的输出都在通道上与后面层层相连,凭借着密集的连接,可以减轻模型退化的问题;在模型中加入 SERE 模块(squeeze excitation residual block),可以通过通道上的注意力机制防止模型退化;同时将 DenseNet 中的 Dense Layer 改进为三层的疏松连接的组卷积块,加深了网络层数的同时减少了模型的参数量。但是如果将一维振动信号直接输入到网络中,多次的卷积和池化操作会使信号丢失关联性从而导致特征提取不充分,故本文使用经验模态分解(empirical mode decomposition,EMD)<sup>[8]</sup>先对一维信号进行分解和重构完成一次特征提取,然后使用格拉姆角场(gramian angular field,GAF)将一维信号转换为二维图片,可以保留原始信号的时间相关性的同时充分利用深层网络的特征提取能力,将处理过的二维图片数据集作为模型的输入,最终实现故障诊断。

## 1 基于 EMD-GAF 和改进的 SERE-DenseNet 的故障诊断模型

### 1.1 数据预处理

#### 1) EMD

EMD 方法可以有效处理非线性、非平稳的数据,通过 EMD 分解可以将连续复杂的时间序列分解成若干个不同频率的固有模态函数(intrinsic mode function,IMF)和一个残差项(residual),残差表示该数据的趋势,而分解得到的若干个 IMF 分量则可以体现数据的部分特征,通过提取贡献率较大的 IMF 分量并进行重构,可以整体提取数据的重要特征而排除一些无效特征或干扰。每个 IMF 必须满足以下两个定义:(1)在整个数据集上,信号的极值数和过零数最多相差不超过一个。(2)在任意时间点上,由局部极大值和局部极小值定义的包络线的平均值为 0。

#### 2) GAF

GAF 是将直角坐标系下的时间序列转换到极坐标系下,并形成的二维的格拉姆矩阵,可以保持绝对时间相关性<sup>[9]</sup>。将时间序列  $X = \{X_1, X_2, \dots, X_n\}$  按照式(1)缩放到  $[-1, 1]$  之间,

$$\tilde{x}_i = \frac{(x_i - \max(x)) + (x_i - \min(x))}{\max(x) - \min(x)} \quad (1)$$

将缩放后的时间序列数据通过式(2)从笛卡尔坐标系转换为极坐标系,

$$\begin{cases} \phi = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \\ r = \frac{t_i}{N}, & t_i \in N, \end{cases} \quad (2)$$

最后使用三角函数生成二维矩阵,转换的方式有两种:GASF 和 GADF,经实验,GADF 的效果较稳定地优于 GASF,故本文方法选取 GADF 进行实验与分析,这里展示 GADF 的转换方式如式(3)所示。

$$GADF = \begin{pmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{pmatrix} = \sqrt{I - \tilde{x}^2}^\top \cdot \tilde{x} - \tilde{x}^\top \cdot \sqrt{I - \tilde{x}^2} \quad (3)$$

#### 3) 实验数据来源

本文采用凯斯西储大学的滚动轴承数据集进行故障诊断仿真实验,该数据集在电机转速为 1 797 rpm、负载为 0 hp 的情况下以采样频率为 12 kHz 进行数据采集,数据集有 1 种正常状态的数据和 9 种不同的故障数据,振动信号采集实验中分别在轴承的内圈、外圈和滚动体上人为通过电火花制造了 0.178、0.356、0.533 mm 的故障点,来表示不同的损毁程度<sup>[10]</sup>。

### 1.2 SERE-DenseNet 故障诊断模型

#### 1) SERE

在深度学习模型中,注意力机制可以有效提升模型的

特征提取能力,SE 模块就是一种通道上的注意力机制,其工作过程包括 Squeeze 和 Excitation 两个操作,体现各通道之间的关系,通过自动学习的方式获取不同通道的重要程度,并以这个重要程度作为权重,提高对重要特征的提取,削弱相关性差的一般特征,增强以提高整个网络的表征能力<sup>[11]</sup>。考虑到不合理的权重可能会降低深层特征的价值,继而破坏原有特征对模型的良好影响,这里使用 SE 模块的变种 SERE,它是在 SE 模块的基础上加入与 ResNet 中的跳跃连接类似的连接方式,将输出与输入相加后作为输出,示意图见图 1。残差学习用于学习同一映射的残差,可以大大增加网络的深度,克服梯度消失和爆炸的问题。这样保证了即使深层网络在走入梯度上的“洼地”时即使不会继续优化也不会产生退化。

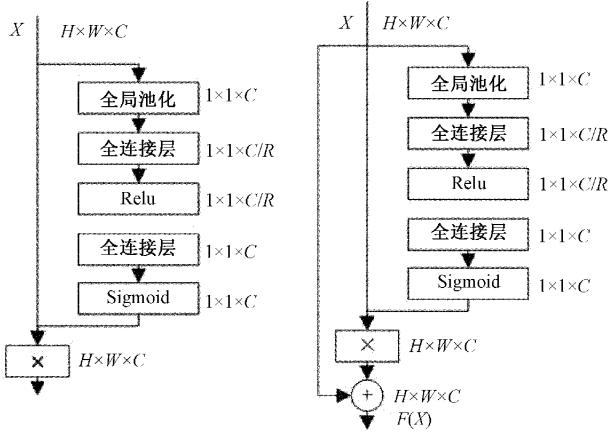


图 1 SE 模块与 SERE 模块示意图

## 2) 改进的 DenseNet

DenseNet 由密集连接块 (dense block) 和瓶颈层 (transition layer) 等组成<sup>[12]</sup>,相较于传统卷积神经网络中网络一层层单调叠加的方式不同,密集连接块中的各层之间相互紧密连接,每层的输入都是前面所有层的输出,每层的输出也都作为后续所有层的输入,并在通道上进行叠加<sup>[13-14]</sup>;瓶颈层中包括批量归一化 (batch normalization, BN)、 $1 \times 1$  的卷积层和  $2 \times 2$  平均池化层 (average pooling),用于调整特征图的尺寸与通道数,优化特征信息在网络的传播速度<sup>[15]</sup>。

虽然 DenseNet 密集的连接方式配合瓶颈层也可以控制模型的参数量,但由于网络层数较大模型参数还是较大,ResNeXt 的优秀性能证明了增加基数比加深网络层数或者增大卷积核的尺寸更有效<sup>[16]</sup>,为了减少模型的容量提升计算的速度,这里将组卷积的概念应用到 DesNet,但 ResNeXt 中卷积小组的层数在大于等于三层时组卷积才能产生效果<sup>[17]</sup>,故本文将每个 Dense Layer 中原有的两个卷积层改为 3 个卷积层并使用组卷积的操作,网络结构如图 2 所示,它可以同时加强特征的利用和增加变换的基数。

为验证模型的体量减轻了,这里与常规 DenseNet 和一

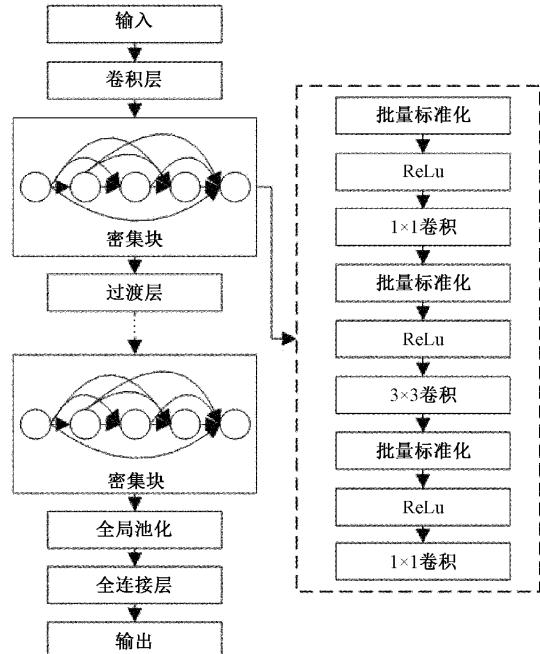


图 2 改进的 DenseNet 网络结构

些经典网络进行参数量比较,如表 1 所示,DenseNet 的参数量天然地小于其他经典网络,改进后的网络网络的层数加深,可以更好地提取深层特征的同时,网络参数不仅没有增加反而下降了,证明本文模型非常具有性价比。

表 1 不同网络模型参数量

模型	本文模型	DenseNet	ResNet	VGG
Prams/MB	5.1	6.64	40.54	122.84

## 3) 基于 EMD-GAF 和改进的 SERE-DesNet 的故障诊断模型

基于 EMD-GAF 和改进的 SERE-DesNet 的滚动轴承故障诊断流程如图 3 所示。

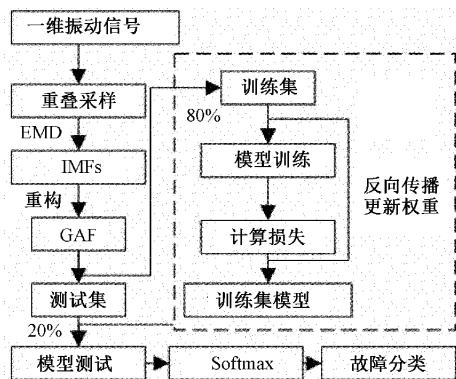


图 3 基于 EMD-GAF 和改进的 SERE-DesNet 的故障诊断模型

滚动轴承的一维时间序列先使用 EMD 方法进行分解,得到一定数量的 IMF 分量,取前 5 个分量进行重构,将

重构的数据通过 GAF 转化成  $224 \times 224$  的二维矩阵; 将得到的二维图像输入到改进的 SERE-DenseNet 模型中进行分类。

## 2 实验与结果分析

### 2.1 网络模型参数

基于 EMD-GAF 和改进的 SERE-DenseNet 的故障诊断模型参数见表 2。

表 2 网络模型参数

模型	输出尺寸	网络结构
Convolution	$112 \times 112$	$7 \times 7 \times 64$ , 步长 2
Pooling	$56 \times 56$	$3 \times 3$ 最大池化层, 步长 2
Dense block	$56 \times 56$	$\begin{pmatrix} 1 \times 1 \times 128 \\ 3 \times 3 \times 128, C=32 \\ 1 \times 1 \times 256 \end{pmatrix} \times 6$
Transition Layer	$56 \times 56$ $28 \times 28$	$1 \times 1 \times 128$
Dense block	$28 \times 28$	$\begin{pmatrix} 1 \times 1 \times 256 \\ 3 \times 3 \times 256, C=32 \\ 1 \times 1 \times 512 \end{pmatrix} \times 12$
Transition Layer	$28 \times 28$ $14 \times 14$	$1 \times 1 \times 256$
Dense block	$14 \times 14$	$\begin{pmatrix} 1 \times 1 \times 512 \\ 3 \times 3 \times 512, C=32 \\ 1 \times 1 \times 1 024 \end{pmatrix} \times 24$
Transition Layer	$14 \times 14$ $7 \times 7$	$1 \times 1 \times 512$
Dense block	$7 \times 7$	$\begin{pmatrix} 1 \times 1 \times 1 024 \\ 3 \times 3 \times 1 024, C=32 \\ 1 \times 1 \times 2 048 \end{pmatrix} \times 16$
pooling	$1 \times 1$	$7 \times 7$ 全局平均池化
Classification layer	$1 \times 1$ 10	全连接层 Softmax

大小为  $224 \times 224 \times 1$  的图片输入进模型, 经过一个卷积核尺寸为  $7 \times 7$  的卷积层和  $3 \times 3$  的最大池化层后数据输出尺寸为  $56 \times 56 \times 64$  并进入模型主干: 首先进入由 SERE blocks 和基数  $C=32$  的组卷积组成的密集连接块和瓶颈层, 并在这完成主要的特征提取和模型训练, 其中密集连接块共有 4 种, 个数分别为 6、12、24、16, 其输入输出尺寸不同, 最后一层密集连接块的输出尺寸为  $7 \times 7 \times 1 024$ , 通过一个全局池化层后使用 Softmax 函数完成故障诊断。其中, 为了防止过拟合, 在每个 Dense layers 后面加入数值为 0.1 的 Dropout 层。

### 2.2 故障诊断实验

#### 1) 数据处理

对凯斯西储大学轴承数据库中一维时间序列的十种状态分别进行分割采样, 每个样本选取连续的 2 000 个数据点, 重叠比例设为 0.1, 正常数据取 2 400 个样本, 九种故障数据各取 1 200 个样本, 共 13 200 个样本。

对凯斯西储大学的轴承数据中的正常数据和九种故障共计 10 种分别进行编号, 为了有效利用数据, 以 0.1 的重叠比例对数据进行重叠分割采样, 每个样本选取连续的 2 000 个数据点, 对采集到的样本进行 EMD 分解, 经过 EMD 分解的前几阶 IMF 分量往往包含了信号主要的能量与频率分量, 因此故障信息也主要集中在前几阶分量中, 故本文以前 5 个 IMF 分量作为主要特征成分, 将前 5 个 IMF 分量重构后使用 GAF 方法转换为极坐标后再转换为二维图像, 转换过程如图 4 所示。

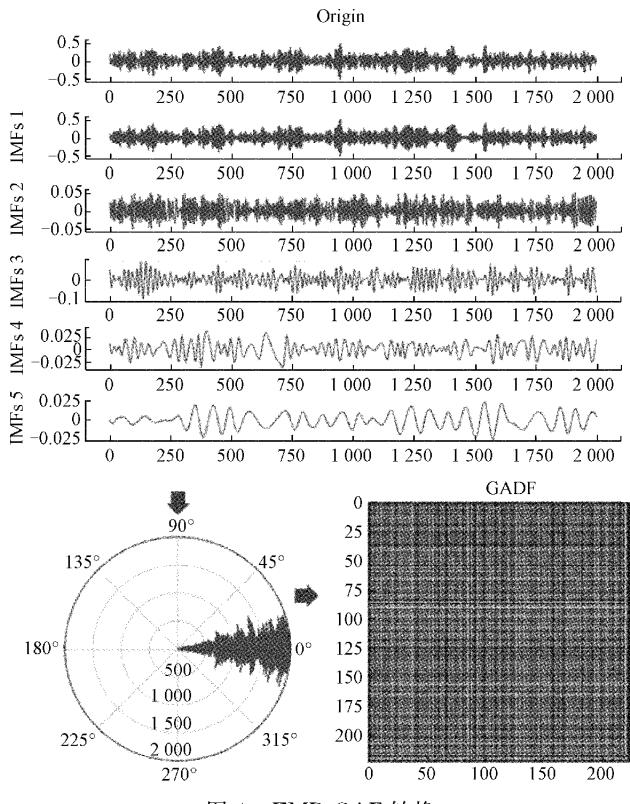


图 4 EMD-GAF 转换

图像尺寸为  $224 \times 224$ , 正常数据得到 2 400 个样本, 故障数据每种各得到 1 200 个样本, 共得到 13 200 张图片, 并将这些图片以 8 : 2 的比例随机划分为训练集和测试集, 最终数据集的组成如表 3 所示。

#### 2) 故障诊断实验

图 5 为将经过 EMD 和 GAF 处理好的数据集在改进的 SERE-DenseNet 中迭代十次的准确率曲线图, 不难看出模型的收敛速度极快, 并未因为使用了较大的学习率而导致剧烈震荡, 而是在第 5 个 epoch 之后进入稳定收敛, 而在

表 3 轴承数据集

状态	标签	训练集样本数	测试集样本数
正常	0	1 920	480
0.178 mm 滚动体故障	1	960	240
0.178 mm 内圈故障	2	960	240
0.178 mm 外圈故障	3	960	240
0.356 mm 滚动体故障	4	960	240
0.356 mm 内圈故障	5	960	240
0.356 mm 外圈故障	6	960	240
0.533 mm 滚动体故障	7	960	240
0.533 mm 内圈故障	8	960	240
0.533 mm 外圈故障	9	960	240

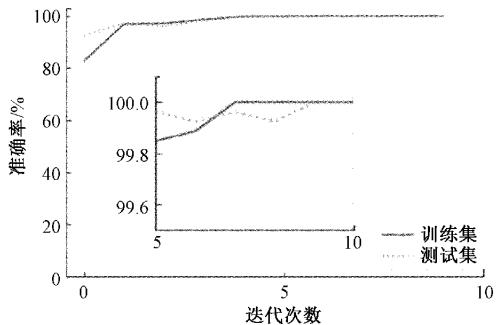


图 5 故障诊断模型准确率曲线

第 6~10 个 epoch 中, 训练集和测试集的准确率都稳定地继续收敛, 而最终测试集的准确率达到了 100%, 为了验证本文方法的稳定性, 故进行十次实验并取平均值, 最终测试集准确率也达到了 99.91%, 效果非常理想。值得关注的是, 本文方法在具有极高的训练集准确率的同时, 验证集并未出现由于过拟合而引起剧烈震荡, 而是一直保持稳定的收敛。

取 10 次实验中 loss 较高、准确率较低的一组进行分析, 分类结果如图 6 所示。可以看出, 标签为 5、6、8 的三组数据中的数据分类出现了错误, 标签为 5 一个样本被错误地分为标签 6 的故障类型, 而标签 6 的 2 个样本被错误地分为标签 5 的故障类型, 标签为 8 一个样本被错误地分为标签 1 的故障类型, 可以看出, 对于标签为 5 和 6 的故障类型即 0.356 mm 内圈故障和 0.356 mm 外圈故障容易出现错误。整体地, 整个测试集中 2 640 个样本中有 2 636 个样本被正确分类, 准确率达 99.85%。

为进一步分析实验结果, 除准确率(accuracy)外, 此处使用这些指标进行分析: 精确率(positive predicative value, PPV), 即正确预测为正确的占全部预测为正确的比例; 召回率(true positive rate, TPR), 即正确预测为正确的占全部实际为正确的比例; F-score, 即精确率和召回率的调和平均。其对应公式为:

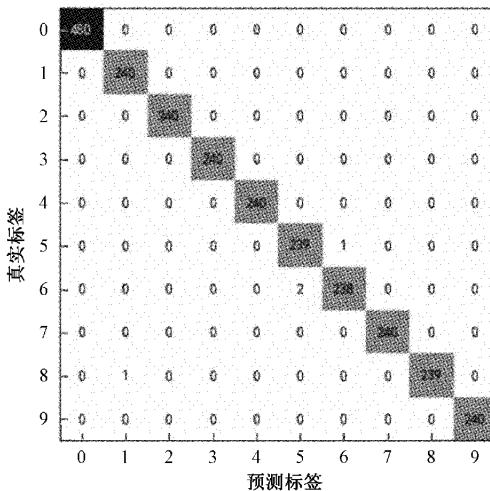


图 6 故障分类结果

$$PPV = \frac{TP}{TP + FP}$$

$$TPR = \frac{TP}{TP + FN} \quad (4)$$

$$F\text{-score} = 2 \times \frac{PPV \times TPR}{PPV + TPR}$$

其中, TP、FN、FP 和 TN 的定义见表 4。

表 4 TP、FN、FP 和 TN 的基础定义

真实值	预测值	
	Positive	Negative
Positive	True Positive(TP)	False Negative(FN)
Negative	False Positive(FP)	True Negative(TN)

使用上述指标对本文方法进行分析, 结果如表 5 所示。

表 5 故障诊断模型分类结果评价

标签	精确率/%	召回率/%	F-score/%
0	100	100	100
1	100	99.58	99.79
2	100	100	100
3	100	100	100
4	100	100	100
5	99.58	99.17	99.37
6	99.17	99.58	99.37
7	100	100	100
8	99.58	100	99.79
9	100	100	100

为了验证本文模型的性能, 同样使用 EMD+GAF 的数据处理方法, 采用 VGG<sup>[18]</sup>、GoogleNet<sup>[19]</sup>、ResNet101 与

DenseNet121 等模型进行实验比较,仍进行 10 次实验取平均值,比较结果如表 6 所示。

表 6 不同模型测试准确率 %

方法	本文方法	DenseNet121	ResNet101	GoogleNet	VGG
准确率	99.91	99.78	97.23	92.61	90.27

### 3) 鲁棒性实验

虽然 CWRU 数据集在采集振动数据时已包含了一定的背景噪声,但由于实际工况的复杂性,轴承常处在各种各样的环境中,从而导致测量所得的振动信号会包含各种各样的噪声,为了维护滚动轴承的正常运行,故障诊断方法必须具有强大的鲁棒性,故对本文方法进行鲁棒性测试,测试方法为对原始一维振动信号加入不同信噪比的高斯白噪声,随后再进行数据分割、EMD 提取分量和重构和 GAF 转换之后输入进本文模型中进行分类,实验结果如表 7 所示。

表 7 鲁棒性实验准确率

信噪比	30 dB	20 dB	16 dB	12 dB	10 dB
本文方法/%	99.27	98.9	98.1	97.35	96.48
DenseNet/%	98.91	98.44	97.49	96.59	95.35
ResNet101/%	97.35	96.59	95.9	94.77	93.79
GoogleNet/%	92.42	91.59	90.09	89.66	88.3
VGG/%	90.15	89.43	87.91	86.78	85.19

从表 7 可以看出在加入噪声后,不同的模型的准确率都有不同程度的下降,特别是 VGG 随着噪声的增大准确率下降严重,在 10 dB 的噪声下只有 85.19% 的准确率,不难看出这些经典模型的鲁棒性相对更差一些;GoogleNet 中 inception 模块的应用使其准确率和鲁棒性都优于 VGG;本文的主干网络 DenseNet121 由于网络层层紧密连接,与 EMD+GAF 结合的表现明显优于网络深度相似的 ResNet101,且与本文方法较接近,但由于缺乏 SERE 的注意力机制,导致此模型的鲁棒性较差,随着噪声的增大,与本文方法的准确率差距逐渐增大;本文方法的实验结果仍然非常理想,在信噪比为 30 dB 时,仍能准确提取故障特征并进行准确分类,准确率高达 99.27%,即使是信噪比为 10 dB 时还可以达到 96.48% 的准确率,这是因为在网络密集连接,能够更好提取特征的同时,加入 SERE 模块防止随网络深度加深而走向“洼地”而导致模型恶化,所以本文方法比同样具有深层卷积的 ResNet101 模型具有更好的效果和更强的鲁棒性。

## 3 结 论

本文提出了一种基于 EMD-GAF 和改进的 SERE-DenseNet 的故障诊断方法,该方法在数据预处理方面通过 EMD 对振动信号进行分解并重构,并采用 GAF 将重构的

信号转换成二维图像,避免了一维振动信号故障特征微弱的问题;模型方面选择密集连接的 DenseNet121 为模型主干,加入融合了 ResNet 中跳跃连接概念的 SERE 模块提升特征提取能力和避免网络层数加深导致的模型恶化,并对每个 Dense Layer 单元引入基数的概念,提升了模型深度并减少了模型参数量。

实验结果表明:本文最大准确率为 100%,10 次实验平均值为 99.91%,与其他深度学习方法相比,本文方法具有更高的准确率;在鲁棒性实验中,不同于经典模型随着噪声增强而出现准确率大幅度地下降,本文方法在信噪比为 10 dB 时准确率为 96.48%,证明本文方法可以在高噪声的环境下保持较高的准确率,具有较好的鲁棒性。但本文所提出方法仍存在不足,因为采用深层卷积网络和二维卷积导致运算量大、对设备算力要求高,在未来的工作中重心应该放在保持准确率的同时压缩模型的运算量,可以继续通过模型的轻量化或迁移学习两个方面进行探索与研究。

## 参考文献

- [1] NEUPANE D, SEOK J. Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review[J]. IEEE Access, 2020, 8: 93155-93178.
- [2] YAN X A, JIA M P. A novel optimized svm classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing[J]. Neurocomputing, 2018, 313: 47-64.
- [3] 焦静,岳建海,裴迪. 基于 MSK-SVM 的滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 109-117.
- [4] 袁建虎,韩涛,唐建,等. 基于小波时频图和 CNN 的滚动轴承智能故障诊断方法[J]. 机械设计与研究, 2017, 33(2): 93-97.
- [5] 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, 203.
- [6] 张龙,胡燕青,赵丽娟,等. 采用递归图编码技术与残差网络的滚动轴承故障诊断[J]. 西安交通大学学报, 2023, 57(2): 110-120.
- [7] SONG L Y, WANG H Q, CHEN P. Vibration-based intelligent fault diagnosis for roller bearings in low-speed rotating machinery[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67 (8): 1887-1899.
- [8] 邓勇,胡徐松. 基于 EMD 和 SPS 的容差模拟电路故障诊断[J]. 电子测量与仪器学报, 2020, 34(2): 67-72.
- [9] WANG S B, IVAN S, CAI G G, et al. Nonconvex sparse regularization and convex optimization for bearing fault diagnosis [J]. IEEE Transactions on

- Industrial Electronics, 2018, 65(9): 7332-7342.
- [10] HUANG H, NATALIE B, LIANG M. Bearing fault diagnosis under unknown time-varying rotational speed conditions via multiple time-frequency curve extraction[J]. Journal of Sound and Vibration, 2018, 414: 43-60.
- [11] SINITSIN V, IBRYAEVA O, SAKOVSKAYA V, et al. Intelligent bearing fault diagnosis method combining mixed input and hybrid CNN-MLP model [J]. Mechanical Systems and Signal Processing, 2022, 180: 109454.
- [12] ZHANG K, CHEN P, YANG M, et al. The harmogram: A periodic impulses detection method and its application in bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2022, 165: 108374.
- [13] DING X, LI Y, XIAO J, et al. Parametric doppler correction analysis for wayside acoustic bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2022, 166: 108375.
- [14] LI X, ZHANG W, DING Q. Understanding and improving deep learning-based rolling bearing fault diagnosis with attention mechanism [J]. Signal Process, 2019, 161: 136-154.
- [15] LIU Z, ZHANG L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings[J]. Measurement, 2020, 149: 107002.
- [16] 陈仁祥,朱玉清,胡小林,等.自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J].仪器仪表学报,2021,41(8):95-103.
- [17] XIONG J, LI C, WANG C D, et al. Application of convolutional neural network and data preprocessing by mutual dimensionless and similar gram matrix in fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2021, 18(2): 1061-1071.
- [18] 李传鑫,刘增力.时频分析与VGG19迁移学习的轴承故障检测[J].电子测量技术,2021,44(5):161-165.
- [19] 黄磊,马圣,曹永华.基于GAF与GoogLeNet的轴承故障诊断研究[J].机床与液压,2022,50(1):193-198.

#### 作者简介

- 赵国威,硕士研究生,主要研究方向为故障诊断。  
E-mail:935570707@qq.com
- 曾静(通信作者),副教授,博士,主要研究方向为非线性系统的状态估计、预测控制及故障诊断。  
E-mail:zengjing@syuct.edu.cn