

基于深度学习与改进极限学习机的包装机轴承故障诊断

汝欣¹, 孟金鑫¹, 李建强², 彭来湖^{1,2}

(1.浙江理工大学机械工程学院, 浙江 杭州 310018;

2.浙江理工大学龙港研究院有限公司, 浙江 温州 325000)

✉ ruxin@zstu.edu.cn; 934412020@qq.com; wzcnlj@126.com; laihup@zstu.edu.cn



摘要:针对包装机故障信号受噪声影响且样本稀少导致传统的诊断方法不能满足实际场景应用要求的问题,提出一种新的轴承故障诊断方法。首先,利用连续小波变换(Continue Wavelet Transform, CWT)将振动信号转换为二维图像。其次,将其输入深度神经网络进行训练。再次,利用极限学习机(Extreme Learning Machine, ELM)进行故障分类。最后,通过麻雀搜索算法(Sparrow Search Algorithm, SSA)对 ELM 进行优化。试验结果显示,在强噪声干扰且少样本训练的情况下,所提方法的准确率仍能够达到 98.91%,并且模型在不同的轴承数据集集中的准确率均达到 98.92%,证明所提方法具有一定的实用价值。

关键词:故障诊断;深度学习;特征提取;极限学习机

中图分类号:TP307 **文献标志码:**A

Fault Diagnosis of Packaging Machine Bearings Based on Deep Learning and Enhanced Extreme Learning Machine

RU Xin¹, MENG Jinxin¹, LI Jianqiang², PENG Laihu^{1,2}

(1.School of Mechanical Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China;

2.Research Institute of Zhejiang Sci-Tech University in Longgang, Wenzhou 325000, China)

✉ ruxin@zstu.edu.cn; 934412020@qq.com; wzcnlj@126.com; laihup@zstu.edu.cn

Abstract: Aiming at the problem of packaging machine fault signal affected by noise and sparse samples, making traditional diagnostic methods unsuitable for practical applications, a new bearing fault diagnosis method is proposed. Firstly, the vibration signals are transformed into two-dimensional images by using Continuous Wavelet Transform (CWT). Subsequently, these images are input into a deep neural network for training. Following that, Extreme Learning Machine (ELM) is used for fault classification. Finally, the ELM is optimized by the Sparrow Search Algorithm (SSA). Experimental results demonstrate that the proposed method achieves an accuracy of 98.91% even in scenarios with strong noise interference and limited training samples. Additionally, the model achieves an accuracy of 98.92% across various bearing datasets, proving the practical value of the proposed method.

Key words: fault diagnosis; deep learning; feature extraction; extreme learning machine

0 引言(Introduction)

随着生活质量的提高,人们对产品的包装要求也随之提升,进而对包装机的可靠性和稳定性提出了更高的要求。轴承的健康状态直接影响包装机设备的工作和运行状态。因此,建

立一种特征提取能力强、泛化性能优异的轴承故障诊断模型是当前的研究热点^[1]。

目前,振动分析是一种有效的轴承故障诊断方法,其主要包含故障信号的特征提取和分类^[2]。传统的特征提取方法,如

信号处理已被广泛应用,其结合深度学习可以得到较高的诊断准确率。孙佳韵等^[3]提出了经验模态分解算法与卷积神经网络相结合的轴承故障诊断方法,提高了模型对故障特征的学习能力。但是,与传统的机器学习方法相比,深度学习模型需要更多的训练参数和时间,其分类层的分类效果与机器学习算法的分类效果相比,仍有一定的差距。

针对上述问题,本文提出了一种融合深度卷积神经网络(DCNN)和麻雀搜索算法的优化后的 ELM 分类模型,将其加入包装机轴承故障诊断模型中。该模型既充分利用了深度学习优秀的特征提取能力,又结合了 ELM 高效的分类能力,并引入 SSA 对 ELM 的参数进行寻优,提升了模型在强噪声干扰下的故障诊断能力。

1 轴承故障诊断方案(Bearing fault diagnosis scheme)

振动分析应用在包装机的轴承故障诊断中,存在两个关键问题需要解决。首先,考虑到包装机的工作环境及轴承的安装位置,传感器采集的振动信号常常受到噪声的干扰。现有的一些方法必须依据先验的专业知识进行一系列复杂的计算,包括滤波、噪声抑制等,才能对轴承故障进行诊断,例如常用的包络调节法、模态分解法等,虽然它们可以捕捉许多轴承故障的特征频率,但是有些特定故障模式可能在振动信号中表现不明显,特征频率可能会受到其他频率成分的掩盖,导致故障特征难以准确提取。因此,亟须研发一种有效的方法用来在强噪声场景下准确且快速地提取出轴承故障所固有的特征。此外,鉴于包装机轴承故障信号的稀缺性,如何仅依靠少量的故障信号实现精准的故障诊断,成为另一个亟须解决的问题。

为了减少因为设备故障带来的损失,及时发现包装机的故障,本文采用了一种云边协同的包装机轴承故障诊断方案,其流程如图 1 所示。首先,边缘主机通过传感器收集包装机的轴承振动信号,将其上传至云端服务器。其次,采用人工方式依据包装机的实际情况二次确定故障标签,输入模型进行训练。最后,将训练好的模型移植到边缘主机进行包装机轴承的状态识别,并在必要时进行控制。此方案通过公开数据集训练的模型配合包装机轴承数据进行迁移训练,可在前期解决包装机轴承故障信息稀缺的问题,并且随着故障样本的增多,模型的准确率也会随之提高。

同时,本文提出了 DCNN-SSA-ELM 模型。其中,深度学习用于消除传统方法中手动提取特征的需求,降低了人工干预的成本,并且可以捕捉更加深层的故障特征,能够适应多种类型的数据^[4]。ELM 的训练速度非常快,尽管训练过程使用了随机权重,但是仍具有较强的泛化能力,相比于其他算法模型,同样降低了人工干预的成本。虽然 ELM 的泛化性较好,但是其结果通常不是最优的,这也是随机确定权重的一个缺点。通过 SSA 寻找 ELM 权重参数的最优解,可以最大限度地提升模

型的故障诊断能力。SSA 采用种群分组、种群迁移和个体采样等策略,使算法具有较强的多样性和全局搜索能力,并且具有较高的收敛速度和精度,能够在较短的时间内找到较优解。

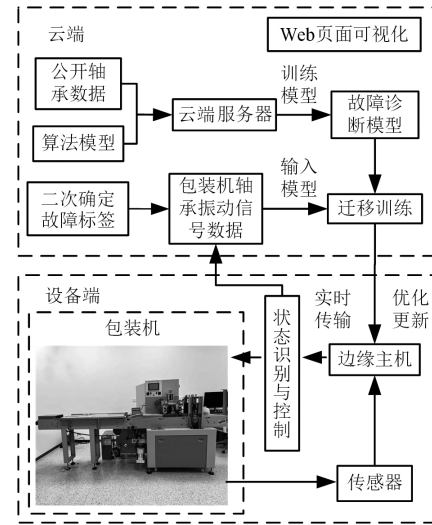


图 1 包装机轴承故障诊断方案流程

Fig. 1 Flowchart of the diagnostic scheme for packaging

machine bearing faults

2 算法介绍(Algorithm introduction)

2.1 深度卷积神经网络

卷积神经网络(CNN)^[5]是深度学习中的典型算法,具备卷积运算和深度结构。CNN 主要由输入层、卷积层、池化层、全连接层和输出层组成。模型流程涵盖卷积层、池化层等的处理,并通过分类器进行结果识别分类。在训练过程中,CNN 根据训练样本进行权重优化,运用反向传播和梯度下降法,与传统神经网络的训练方法相同。

经典的深度卷积神经网络(DCNN)包括视觉几何组(VGG)^[6]和残差网络(ResNet)^[7]等。VGG 基于 CNN 进行优化,模型在图像分类领域广泛应用,其采用深层网络结构和小卷积核、池化域,既保证了感受视野,又减少了参数量。通过交替的多个卷积层与非线性激活层,能够更好地提取深层特征。ResNet 基于 VGG 模型进行改进,引入残差单元以解决深层网络引发的退化问题,使网络能够更深入地学习特征。

2.2 极限学习机

极限学习机(ELM)^[8]是一种广义单隐层前馈神经网络,其结构简单,学习速度快,它的结构分为输入层、隐藏层和输出层,如图 2 所示。极限学习机中的输入权重 w 与偏置 b 是随机确定的,且隐藏层和输出层之间的连接权重不需要迭代调整,而是直接输出结果。因此,极限学习机的学习速度很快,而且具有良好的泛化能力。

2.3 麻雀搜索算法

麻雀搜索算法(SSA)是根据麻雀的觅食行为而提出的群




图2 极限学习机结构图

Fig. 2 Structure diagram of the extreme learning machine model

智能优化算法^[9],麻雀被分为3类:发现者、跟随者和警戒者。

在 D 维解空间内,每只麻雀的位置 X 和适应度 f 如公式

(1)和公式(2)所示:

$$X = (x_1, x_2, \dots, x_D) \quad (1)$$

$$f_i = f(x_1, x_2, \dots, x_D) \quad (2)$$

每代发现者的位置更新公式如公式(3)所示,若确定周围安全,则进行广泛搜索,若发现危险,则迅速远离。

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{a \cdot iter_{max}}\right), & R_2 < ST \\ X_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (3)$$

其中: $X_{i,j}^{t+1}$ 表示种群中第 t 代中第 i 个个体的第 j 维的位置。 $iter_{max}$ 表示最大迭代次数。 a 是 $0 \sim 1$ 的随机数。 R_2 和 ST 分别是预警值和安全值。随机变量 Q 服从正态分布。 L 表示 $1 \times d$ 的矩阵,其中每个元素都为 1。

跟随者会观察发现者的位置,其位置更新描述如公式(4)所示:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst} - X_{i,j}^t}{i^2}\right); & i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L, & \text{其他} \end{cases} \quad (4)$$

其中: X_p^{t+1} 是目前发现者所占据的最优值, X_{worst} 则表示当前全局最差值。矩阵 A 的大小和 L 一样,但其中的元素随机赋值为 1 或 -1 , A^+ 如公式(5)所示:

$$A^+ = A^T (AA^T)^{-1} \quad (5)$$

还有占一定比例的麻雀用于侦察预警,如公式(6)所示:

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left[\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon} \right], & f_i = f_g \end{cases} \quad (6)$$

其中: X_{best} 是当前的全局最优值, β 是均值为 0、方差为 1 的正态分布随机数, K 是 $-1 \sim 1$ 的一个随机数, f_i 是当前适应度值。 f_g 和 f_w 分别是当前全局最佳和当前全局最差的适应度值, ϵ 为常数。

2.4 连续小波变换

CWT^[10]是 WT 的一种,在使用 CWT 做时频分析时,可以

在时间分辨率和频率分辨率之间取得很好的平衡。因此,本文采用 CWT 将原始时域信号转换为二维时频图像,其数学表达式如公式(7)所示:

$$cwt(\alpha, \beta) = \alpha^{-\frac{1}{2}} \int x(t) \varphi^* \left(\frac{t-\beta}{\alpha} \right) dt \quad (7)$$

其中: α 和 β 分别表示比例因子和平移参数, $x(t)$ 为原始时域信号, φ 为小波函数, $*$ 为复共轭算子。

2.5 改进的 DCNN-SSA-ELM 故障诊断流程

首先,利用 CWT 将轴承的原始振动信号转换为二维时频图像。

其次,输入图像对深度卷积神经网络模型进行训练,保存训练好的模型的参数,使用 ELM 替代深度卷积神经网络模型的全连接层,对轴承故障进行分类。图 3 是 CNN-ELM 模型结构示意图,图中 CNN 为特征提取器,ELM 为分类器。




图3 CNN-ELM 模型结构示意图

Fig. 3 Schematic diagram of the CNN-ELM model structure

最后,通过引入 SSA 优化算法对 ELM 的权值 w 和偏置 b 进行寻优,使得 ELM 的分类效果达到最优且稳定。

3 试验验证 (Experimental verification)

为了验证所提方法的有效性,本小节研究了两个实例,分别使用 CWRU (Case Western Reserve University) 轴承数据集^[11]和帕德博恩大学轴承数据集^[12]。所有试验模型都是通过 Python 3.8 和 Pytorch 实现的,在 Ubuntu 18.04 上运行,使用 3090 24 GB 的 GPU。

3.1 基于 CWRU 轴承数据集的试验验证

3.1.1 数据集描述

数据由轴承在 4 种不同负载下 (0 hp, 1 hp, 2 hp, 3 hp) 运行的数据组成。采样频率为 12 kHz。该数据集中的轴承故障类别分别为内圈缺陷、滚动体缺陷和外圈缺陷,其中每种故障又有 3 种不同的直径 (7 mil, 14 mil, 21 mil)。因此,CWRU 轴承数据集的标签有 10 个类,其中包括 9 个故障类和 1 个正常类。对于不同轴承故障类的每种故障直径,在不变换数据的情况下,分别从每个负载中选取 30 720 个采样点,分为 30 个样本,即一种故障类别有 120 个样本,并将其按照 4 : 1 的比例分为训练集和测试集。CWRU 轴承数据集分类如表 1 所示。利用 CWT 将一维的轴承振动信号转换为二维时频图像,每张图的大小为 64×64 ,以此作为模型的输入。

表1 CWRU 轴承数据集分类

Tab.1 Classification results on the CWRU bearing dataset

分类 标签	不同的 负载/hp	故障 直径/mil	故障 位置	样本 数量/张
1	0/1/2/3	7	滚动体	120
2	0/1/2/3	14	滚动体	120
3	0/1/2/3	21	滚动体	120
4	0/1/2/3	7	内圈	120
5	0/1/2/3	14	内圈	120
6	0/1/2/3	21	内圈	120
7	0/1/2/3	7	外圈	120
8	0/1/2/3	14	外圈	120
9	0/1/2/3	21	外圈	120
10	0/1/2/3	—	正常	120

3.1.2 模型试验

在深度卷积神经网络模型的训练中,使用了3种不同的模型结构(CNN、ResNet18、VGG16)。为了提高模型的特征提取能力,首先对模型进行训练,其中VGG16的模型批处理大小设置为80,学习率设置为0.01,迭代20次。CNN和ResNet18批处理大小设置为40,学习率设置为0.01,迭代40次。将训练好的模型的全连接层及之后的网络层替换为ELM和SVM进行训练,其中ELM的隐藏层节点数设置为3000,SVM核函数选取RBF核函数,惩罚参数设置为1。所有试验在相同条件下重复10次,以最后的平均准确率作为评价指标。在训练完成之后,将每个DCNN模型全连接层之前提取的特征进行归一化,并利用 t 分布随机邻近插入(T-SNE)对提取的特征可视化,各个模型的聚类效果如图4所示。




图4 各个模型的聚类效果

Fig. 4 Clustering results of various models

从图4中可以看出,CNN在一些故障类型中的聚类并不明显,在此模型的基础上改进的VGG16和ResNet18则具有了明显的聚类效果。采用VGG16和ResNet18提取特征,不同故障类型相互远离,同一种类型也不分散。由此可见,利用DCNN作为特征提取器是完全可行的。3种不同的深度学习模型以及融合ELM和SVM之后的模型的故障诊断结果如表2所示。

表2 3种不同的深度学习模型以及融合ELM和SVM之后的模型的故障诊断结果

Tab.2 Fault diagnosis results for 3 different deep learning models and a model after fusing ELM and SVM

模型	分类器	最大准 准确率/%	最小准 准确率/%	平均准 准确率/%
CNN	Softmax	98.33	97.92	98.29
	ELM	99.17	97.50	98.46
	SVM	97.91	97.91	97.91
ResNet18	Softmax	99.17	98.33	98.88
	ELM	99.58	98.33	99.00
	SVM	98.75	98.75	98.75
VGG16	Softmax	99.17	98.75	99.00
	ELM	99.58	98.33	98.83
	SVM	98.75	98.75	98.75

从表2中的数据可以看出,无论选择哪种DCNN模型结构,在替换了ELM之后,与原本的Softmax分类器相比,最高准确率都得到了提升。此结果证明了将ELM作为故障分类器是具有优势的。其中,当VGG16作为ELM特征提取器后,最高准确率从原来的99.17%提升到99.58%,并且结合ELM的模型故障诊断准确率均高于替换成SVM的模型,也证明了ELM在分类问题上具有优越性。

模型的稳定性也是考量模型性能的重要指标。从表2中的数据可以看出模型结合ELM的最大准确率和最小准确率的差值比模型结合其余两个分类器的差值更大,这也证明了前文中提到的ELM输出不稳定的问题。

为了使ELM的输出稳定,需要使ELM随机确定的权值和偏差更确定,又要确保确定的参数使ELM的分类效果最优。于是,本文在原有模型中加入麻雀搜索算法,利用SSA对ELM的参数进行优化。其中,麻雀数量设为20只,发现者比例为80%,预警值为0.7,意识到危险的麻雀占20%。每次试验迭代20次,重复10次试验,试验结果如表3所示。从表3中的数据可以看出,引入SSA之后,模型的准确率得到了提升,并且模型诊断效果变得稳定,其中基于VGG16和ResNet18的模型准确率都达到了100%。

表3 各个模型加入SSA后的故障诊断准确率

Tab.3 The fault diagnosis accuracy of each model after integrating SSA

模型	最大准 准确率/%	最小准 准确率/%	平均准 准确率/%
CNN-SSA-ELM	99.58	99.58	99.58
ResNet18-SSA-ELM	100	100	100
VGG16-SSA-ELM	100	100	100

为了模拟包装机轴承实际运行时存在的各种噪声干扰,并验证强噪声环境下本文所提方法的有效性,试验设置了4种噪声等级,向原始振动信号中添加均值为0的具有不同标准差的高斯白噪声。噪声等级设置如表4所示。

表4 噪声等级设置
Tab.4 Noise level settings

噪声等级	均值	标准差
I	0	0.10
II	0	0.15
III	0	0.20
IV	0	0.25

根据之前的试验,可以得出 VGG16-SSA-ELM 的诊断综合效果最好,为了验证不同噪声等级下该模型的诊断效果,选取其他模型进行对比,其中 LeNet 的模型参数与前文 CNN 的参数相同,每个模型均取最优准确率,试验结果如表 5 所示。

表5 不同模型在不同噪声等级下的诊断准确率

模型	准确率/%					平均
	无噪声	噪声等级 I	噪声等级 II	噪声等级 III	噪声等级 IV	
VGG16-SSA-ELM	100	99.58	99.58	99.58	95.83	98.91
VGG16-ELM	99.58	98.75	98.33	98.33	92.92	97.58
VGG16	99.17	98.75	98.33	97.92	92.50	97.33
CNN	98.33	95.42	95.00	95.83	89.17	94.75
LeNet	99.17	97.50	97.08	95.41	90.83	96.00

从表 5 中的数据可以看出,随着噪声等级的增加,VGG16-SSA-ELM 诊断能力表现优秀,平均诊断准确率高于改进前的 VGG16-ELM 模型 1.33 个百分点,高于 VGG16 模型 1.58 个百分点。与其他深度神经网络及传统模型相比,也有 2.91 百分点~4.16 百分点的提升。验证了改进的 VGG16-SSA-ELM 在提升强噪声场景下的故障诊断准确率上的成效。

3.2 基于帕德博恩大学轴承数据集的试验

3.2.1 数据集介绍

为了评估本文所提方法的迁移能力,采用帕德博恩大学轴承数据集进行试验验证。帕德博恩大学轴承数据集是从 6203 轴承上采集的,采样频率为 64 kHz。本文选取了其中的正常和真实的损伤轴承振动数据,分为 3 种健康状态(正常、外圈损坏、内圈损坏)。与 CWRU 数据集处理方法相同,从数据集中的不同轴承状态中采集样本,每个样本包含 1 024 个采样点,每个故障类别共有 100 个样本,并将其按照 1:4 的比例分为训练集和测试集(表 6)。利用 CWT 将这些样本转换为二维时频图像,每张图的大小为 64×64。

表6 帕德博恩大学轴承数据集分类

分类	来源	故障位置	样本数量/张
1		正常	100
2	6203 滚动轴承	内圈	100
3		外圈	100

3.2.2 试验验证

本次试验的 DCNN 模型沿用 CWRU 数据集所训练的模型,用来提取轴承的故障特征。ELM 的模型结构不变,SSA 搜索算法的参数设置不变,试验步骤相同,各个模型的故障诊断准确率如表 7 所示。从表 7 中的数据可以看到,训练完成之后,CNN-ELM 的平均准确率达到 88.17%,ResNet18-ELM 的平均准确率达到 92.33%,VGG16-ELM 的平均准确率达到 94.67%。加入优化算法 SSA 后,模型的诊断能力得到了提升,平均准确率提高了 4.50 百分点~6.83 百分点。再次证明了 SSA 对 DCNN-ELM 模型是具有优化效果的。图 5 中显示的是 DCNN-ELM 加入 SSA 算法前后最好的诊断效果的混淆矩阵图,从图中可以明显看出,SSA 对故障分类的提升效果。通过分析试验数据可以发现,将 CWRU 数据集训练的 DCNN 模型与 ELM 结合后,在帕德博恩大学轴承数据集上也有较高的故障诊断准确率,这也证明了所提模型具有较强的迁移能力。

表7 各个模型的故障诊断准确率

Tab.7 Fault diagnosis accuracy of each model

模型	分类器	最大准确率/%	最小准确率/%	平均准确率/%
CNN	ELM	91.67	86.67	88.17
	SSA-ELM	95.00	95.00	95.00
ResNet18	ELM	95.00	90.00	92.33
	SSA-ELM	96.67	95.00	96.34
VGG16	ELM	96.67	91.67	94.67
	SSA-ELM	99.17	99.17	99.17

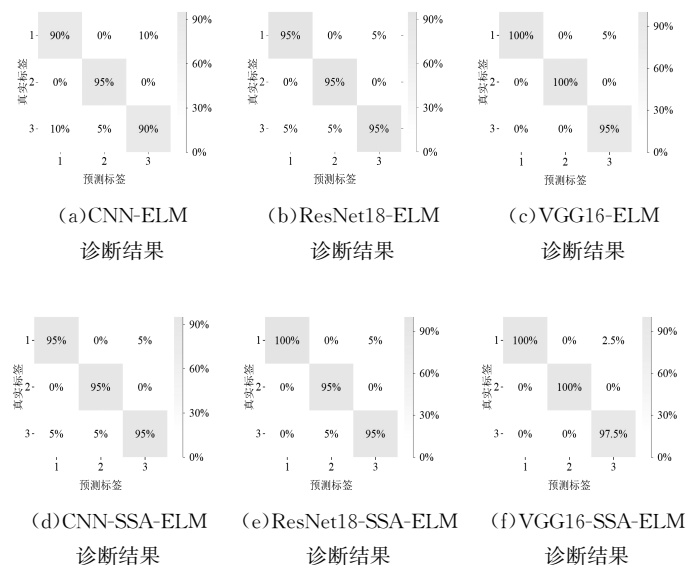


图5 各个模型在帕德博恩大学轴承数据集上的混淆矩阵

Fig. 5 Confusion matrices of each model on the Paderborn university bearing dataset

为了验证迁移模型在噪声影响下的诊断优势,对帕德博恩大学轴承数据集添加同样等级的高斯白噪声,并对 VGG16-SSA-ELM 与其改进前的模型进行对比试验。由于 CWRU 数据集训练的模型最后的全连接层输出结果是 10,若直接用于帕德博恩大学轴承数据集的故障诊断,则达不到理想的诊断效果。因此,需要将 VGG16 模型最后的全连接层输出结果改为 3,并且冻结全连接层之前的所有层,对全连接层进行重新训练,训练时 VGG16 模型的批处理数改为 20,迭代次数改为 40 次,其余参数不变。试验结果如表 8 所示。

表 8 不同噪声等级下模型的诊断准确率

Tab.8 Diagnostic accuracy of models at different noise levels

模型	准确率/%					平均
	无噪声	噪声等级 I	噪声等级 II	噪声等级 III	噪声等级 IV	
VGG16-SSA-ELM	99.17	99.17	98.33	99.17	98.75	98.92
VGG16-ELM	97.92	98.33	98.33	98.33	97.08	98.00
VGG16	96.25	97.92	97.50	96.25	97.50	97.08

从表 8 中可明显看到,尽管 VGG16-ELM 模型中的 ELM 模型在训练期间采用随机权重,然而在各种噪声水平下,其准确率均达到了 97% 以上,平均准确率也达到了 98%。这也证明了 ELM 模型在泛化方面的强大能力。而且,VGG16-ELM 模型的平均准确率比 VGG 模型的平均准确率提升了 0.92 百分点。在经过 SSA 优化后,故障诊断的准确率达到 98.92%。与 Softmax 层的训练不同,ELM 仅需计算随机生成的权重和偏置,不需要进行诸如反向传播等迭代过程,这使得 ELM 更加适用于模型迁移,有助于降低网络复杂度并缩短训练时间。值得强调的是,使用的训练数据是基于少样本原则,如果能够获得更多的故障数据,模型准确率也将相应提升。

4 结论 (Conclusion)

本文设计了一个云边协同的包装机轴承的故障诊断方案,并指出方案中轴承故障诊断存在噪声干扰以及样本稀缺的问题。针对这些问题本文提出了 DCNN-SSA-ELM 故障诊断模型,在 CWRU 数据集和帕德博恩大学轴承数据集上进行了多次对比试验,得到以下结论。

(1) 本文建立 DCNN-ELM 模型,对振动信号进行连续小波变换,将一维的轴承振动信号转换为二维时频图像并输入模型训练。在相同数据集的情况下进行试验对比,结果表明 VGG16 与 ResNet18 能够更好地提取轴承的故障信息,并且在融合了 ELM 之后,模型的最高准确率得到了进一步的提升。

(2) 本文又采用 SSA 对 ELM 进行参数寻优,在 DCNN 模型参数不变的情况下进行不同强度的噪声条件下的对比试验,结果表明 SSA-ELM 的分类性能更佳且十分稳定。将在 CWRU 数据集上训练的 DCNN 模型的参数保留,融合 SSA-ELM 后在帕德博恩大学轴承数据集进行故障诊断对比试验,结果表明 DCNN-SSA-ELM 的泛化性能优于未优化的 ELM 分类模型且其抗噪声干扰的能力更强。本文所提方法能够有效识别轴承故障,对包装机的故障维修与预防具有一定的实用价值。

参考文献 (References)

- [1] 郝涛,葛增元,王莉静. 基于参数优化的 VMD 与 DBN 的滚动轴承故障诊断[J]. 组合机床与自动化加工技术,2022(12): 57-61.
- [2] 瞿红春,周大鹏,贾柏谊,等. 基于全矢包络融合双层降噪处理的轴承故障特征提取[J]. 噪声与振动控制,2023,43(1): 135-140,184.
- [3] 孙佳韵,战卫侠,孙显彬,等. 基于卷积神经网络的端到端低速重载轴承故障诊断方法[J]. 制造业自动化,2023,45(12): 194-198.
- [4] 李彦夫,韩特. 基于深度学习的工业装备 PHM 研究综述[J]. 振动、测试与诊断,2022,42(5):835-847,1029.
- [5] 卢绪祥,刘顺顺,陈向民,等. 基于声发射及 WST-CNN 协同的滑动轴承润滑状态识别[J]. 振动与冲击,2023,42(22): 71-77,229.
- [6] 王玉静,夏林,康守强,等. 基于多源域异构模型迁移的滚动轴承故障诊断方法[J]. 振动与冲击,2023,42(24): 257-266.
- [7] 谢译文,陈裕成,柴琴琴,等. 改进残差网络的逆变器开路电路故障诊断[J]. 福州大学学报(自然科学版),2024,52(1): 45-52.
- [8] 兰朝凤,宋博文,郭小霞. 基于改进极限学习机的水轮机运转状态识别[J]. 振动与冲击,2023,42(1):132-138.
- [9] XU J, YAN H Z, DING Q, et al. Sparrow search algorithm applied to temperature control in PEM fuel cell systems[J]. International journal of hydrogen energy, 2022, 47(94): 39973-39986.
- [10] 陈代俊,陈里里,董绍江. 基于 VMD-CWT-CNN 的滚动轴承故障诊断[J]. 机械强度,2023,45(6):1280-1285.
- [11] 刘杰,李长杰,赵昕,等. 基于多特征融合与 GSA-SVM 的滚动轴承故障诊断[J]. 传感技术学报,2023,36(10): 1607-1614.
- [12] 张英杰,张彩华,陆碧良,等. 基于类别域自适应的滚动轴承故障诊断[J]. 振动与冲击,2023,42(24):117-126.
- [13] 郑惠萍,王卓,彭立强,等. 基于改进 CEEMDAN 和 t-SNE 的故障特征提取方法[J]. 机床与液压,2023,51(19): 216-222.

作者简介:

汝欣(1989-),女,博士,讲师。研究领域:智能纺织装备技术,纺织 CAD。

孟金鑫(1998-),男,硕士生。研究领域:智能制造与车间信息化技术。

李建强(1990-),男,博士生。研究领域:智能算法,智能制造与车间信息化技术。

彭来湖(1980-),男,博士,副教授。研究领域:智能制造与车间信息化技术,智能装备与嵌入式控制技术。