

DOI: 10.19783/j.cnki.pspc.200585

基于改进卷积神经网络的风电轴承故障诊断策略

常淼, 沈艳霞

(江南大学物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对风电机组滚动轴承故障特征微弱、提取困难、诊断效率低下等问题, 提出一种基于改进卷积神经网络(Convolution Neural Network, CNN)的故障诊断算法。改进CNN模型结构, 在全连接层前增加新的卷积层, 挖掘信号的深层特征以提高模型的泛化能力。对卷积层数据进行批归一化处理, 采用带有动量的随机梯度下降训练算法来加速训练速度。详细介绍了改进CNN的工作原理, 给出了采用改进CNN进行故障诊断的流程。最后利用凯斯西储大学滚动轴承数据库的数据进行验证。证明该方法不需要预先提取信号的故障特征, 可直接实现对轴承的故障特征提取以及故障识别, 诊断率高。

关键词: 卷积神经网络; 深度学习; 风电; 滚动轴承; 故障诊断; 齿轮箱

Fault diagnosis strategy of a wind power bearing based on an improved convolutional neural network

CHANG Miao, SHEN Yanxia

(Engineering Research Center of Internet of Things Technology Applications of Ministry of Education,
Jiangnan University, Wuxi 214122, China)

Abstract: The rolling bearing of a wind turbine has problems of weak fault characteristics, difficult extraction and low diagnosis efficiency. To solve these problems we propose a fault diagnosis algorithm based on an improved Convolution Neural Network (CNN). The structure of the CNN model is improved, a new convolution layer is added in front of the full connection layer, the deep features of the signal are excavated to improve the generalization ability of the model, the convolution layer data are standardized, and the stochastic gradient descent with momentum is used to speed up the training speed. The working principle of the improved CNN is introduced in detail, and the flow chart of fault diagnosis with improved CNN is given. Finally, the data of a rolling bearing database at Case Western Reserve University is used to verify the method, and proves that this method does not need to extract the fault features of the signal in advance, and can directly achieve fault feature extraction and fault identification of bearings, and the diagnosis rate is high.

This work is supported by the National Natural Science Foundation of China (No. 61573167) and the Fundamental Research Funds for the Central Universities (No. JUSRP51510).

Key words: convolution neural network; deep learning; wind power; rolling bearing; fault diagnosis; gear case

0 引言

风能作为最清洁的可再生能源之一, 越来越受到世界各国的重视。齿轮箱作为风电机组的核心设备, 其运转状态关系着整个系统的运行状况, 一旦故障将产生高额的维修费用和长时间的停机, 会导致严重的发电量损失。对风电齿轮箱故障及时、准确的判断是保证机组稳定运行、提高风场效益的关键。其中滚动轴承的故障特征微弱、提取困难, 对

齿轮箱的运作影响巨大, 所以研究风电机组滚动轴承的故障诊断方法具有重要的实际意义。

故障诊断方法可以分为基于模型^[1]和基于数据的方法, 针对滚动轴承的故障通常使用时频域诊断方法, 如使用傅里叶变换^[2]、小波分析^[3]、希尔伯特-黄变换^[4]等方法对振动信号进行预处理和特征提取, 利用机器学习等进行特征分类, 从而完成故障的识别与诊断。文献[5]使用离散小波变换对故障轴承信号进行处理。文献[6]使用小波包提取特征并用支持向量机(SVM)进行分类。文献[7]选取9个时域特征参数构建特征向量, 采用极限学习机进行分类, 并使用粒子群算法和交叉验证对其参数进行优

基金项目: 国家自然科学基金项目资助(61573167); 中央高校基本科研业务费专项资金资助(JUSRP51510)

化。文献[8]基于经验模态分解,以峭度为准则,提取故障特征量,通过其J-散度和KL-散度来判断故障类型和故障程度。这些方法均采用一定的信号处理算法对原始数据进行故障特征提取,再通过分类算法实现故障的诊断,通常需要相应的去噪手段对原始数据进行降噪处理,过程复杂,容易造成原始有效信息的缺失,而且用于分类的机器学习模型表达能力有限,极易陷入过拟合,泛化能力弱,从而导致诊断的效率降低。

随着深度学习的发展,卷积神经网络(Convolution Neural Network, CNN)得到广泛关注。CNN将卷积操作与反向传播算法相结合,完成卷积核参数自学习训练,通过局部感知域、稀疏连接和权值共享的方式减少参数矩阵规模^[9]。CNN在具有一定降噪滤波效果的同时能够保证特征提取不变性,当用于故障诊断时,与传统的“信号处理+机器学习”方法相比,特征提取和模型建立同时进行,具有优越的学习和表达能力,诊断效率较高,泛化能力强,在大数据背景的故障诊断领域^[10]尤为适用。针对传统方法鲁棒性差、抗噪性能弱等问题,文献[11]使用三个CNN提取特征向量,并将其融合为一个新向量,通过实验证明该算法提取的特征向量具有更大的区分度。考虑故障信号数据庞大、识别困难等问题,文献[12-14]使用CNN对信号进行故障特征提取,证明其在故障特征提取方面的优越性。为了提高CNN的模型收敛速度,改善泛化能力,文献[15]使用SVM分类器对CNN模型进行优化。文献[16]在故障数据输入CNN模型之前先用小波变化对其进行处理。文献[17]引入正则化卷积核并对权重损失函数进行改进。文献[18]通过修正损失函数和采用自适应学习率的方法优化CNN。目前,基于CNN建立故障诊断模型的研究已初见成效,但仍存在梯度消失、过拟合、计算量大等问题需要深入探索。

本文考虑风电机组齿轮箱滚动轴承的故障诊断,对传统的CNN模型进行改进,在全连接层前添加一个卷积层,深度挖掘故障特征,以提高模型泛化能力。激活函数采用整流线性单元(Rectified Linear Unit, ReLU),解决输出误差较难传递到更远节点的问题,避免梯度消失;在每个卷积层和激活函数之间使用批归一化层,使用具有动量的随机梯度下降(Stochastic Gradient Descent with Momentum, SGDM)算法更新参数从而加速网络训练。以凯斯西储大学的滚动轴承振动数据作为网络输入,使用该改进的CNN模型对滚动轴承进行故障诊断,验证提出方法的有效性。

1 改进的CNN模型

1.1 改进的CNN模型

改进的CNN的结构如图1所示,包括输入层、卷积层、池化层(也称下采样层)、全连接层和输出层,并在全连接层之前增加了一个卷积层。一般地,卷积层和池化层成对出现,输出层采用多分类神经网络。

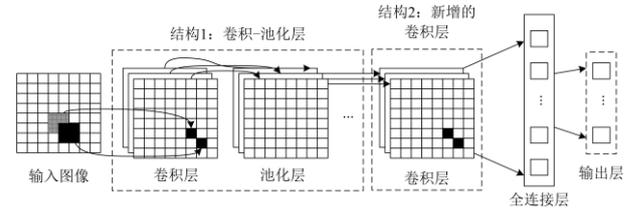


图1 改进的CNN模型

Fig. 1 Improved CNN model

1) 结构1: 卷积层和池化层

卷积层是CNN最为独特同时最为重要的结构,它实质上是特征提取层,由多个卷积核构成。卷积核是二维矩阵,对信号进行过滤和提取,输入图像通过卷积核生成特征映射。每个卷积核的参数均通过反向传播的参数优化训练得到。

假设卷积层为CNN中的第1层,则其输出为

$$Z_j^l = \sum_{i \in M_j} X_i^{l-1} * K_{ij}^l + b_j^l \quad (1)$$

式中: Z_j^l 为第 l 层中第 j 个特征映射, $j \in [1, n]$; X_i^{l-1} 为从 $l-1$ 层获取的第 i 个输入特征; M_j 表示上一层的第 $l-1$ 层中的第 j 个卷积区域; “*” 为卷积算子; K_{ij}^l 表示第 l 层在生成第 j 个生成特征映射时应用在第 $l-1$ 层第 i 个特征输入特征上的卷积核; b_j^l 为第 l 层输出第 j 个特征映射时的偏置。

为降低模型对网络初始化的敏感度并加速网络训练速度,在卷积层之后添加批归一化层,对CNN网络中的激活值、梯度传播进行归一处理。加入归一化层以后输出结果为

$$x_j^l = \frac{Z_j^l - \mu_\beta}{\sqrt{\sigma_\beta^2 + \varepsilon}} \quad (2)$$

$$Y_j^l = \gamma x_j^l + \beta \quad (3)$$

式中: x_j^l 为归一化处理之后的结果; μ_β 为上一层输出数据的均值; σ_β 为上一层输出数据的标准差, ε 为一个极小值; γ 、 β 为学习参数; Y_j^l 为第 l 层的重构结果。

将进行归一化处理以后的结果输入非线性激活函数, 在本文的研究中采用 ReLU 激活函数^[19], 即

$$y_j^l = f(Y_j^l) = \max(0, Y_j^l) \quad (4)$$

可见, 采用 ReLU 激活函数会使得部分神经元的输出值为 0, 在一定程度上有效减少了参数之间的相互依存关系。

池化层对卷积层的输出特征图进行矩形分割, 将图像区域内的相邻像素合并成单个代表值, 缩小特征图的尺寸并删除冗余信息, 从而减少特征图谱维度, 降低过拟合的风险和实现输入图像的平移不变性^[20]。池化层包括平均池化和最大池化。在本文中采用最大池化, 如式(5)所示。

$$X_{j_0}^{l+3} X_{j_0} = \max_{(j_0-1)S \leq r \leq j_0 S} \{y_j^l(r)\} \quad (5)$$

式中: S 为池化层的尺寸; $X_{j_0}^{l+3}$ 为第 $l+3$ 层中输出的第 j_0 个特征映射, $j_0 = [1, \frac{n}{S}]$; $y_j^l(r)$ 为第 l 层的第 j 个特征映射中第 r 个神经元的值, $r \in [(j_0-1)S+1, j_0 S]$ 。

2) 结构 2: 新增的卷积层

原始信号在经过若干个如结构 1 所示的卷积-池化层后, 得到压缩的特征向量。为使分类结果更加精确, 发掘信号的深层特征, 在全连接层前添加一个新的卷积层, 即图 1 中的结构 2, 可以提高 CNN 的模型泛化能力。

3) 全连接层

通过逐层的卷积、池化等操作后, 全连接层将先前层在图像中学习的所有特征组合在一起, 使用 softmax 针对每个输入返回的概率, 将输入分配到其中一个互斥类并计算损失, 以最小损失为学习目标, 更新参数。常见的损失函数有均方误差函数、交叉熵函数、负对数似然函数等^[21], 本文采用交叉熵函数, 如式(6)所示。

$$E = -\sum_{a=1}^A \sum_{b=1}^B t_{ab} \ln y_{ab} \quad (6)$$

式中: A 为样本数量; B 为类别数; t_{ab} 表示第 a 个样本是否属于第 b 个类别; y_{ab} 为属于类别 b 的样本 a 的输出, 即 softmax 的输出, 它表示网络将样本 a 归为类别 b 的概率。

1.2 改进 CNN 的训练

CNN 的训练经常采用随机梯度下降算法^[22], 在本文研究中, 对此进行改进, 网络的训练采用 SGDM 算法。每次从训练集中随机选择一个样本进

行学习, 计算梯度的指数加权平均数, 并利用该梯度更新所取样本的 K_{ij} 、 b_j , 如式(7)和式(8)所示。

$$K_{ij} = K_{ij} - \eta v_k(t) \frac{\partial E}{\partial K_{ij}} \quad (7)$$

$$b_j = b_j - \eta v_b(t) \frac{\partial E}{\partial b_j} \quad (8)$$

式中: η 为 CNN 的学习率; $v_k(t)$ 、 $v_b(t)$ 为第 t 次学习时两个参数的动量, 其更新公式为

$$v_k(t) = -\eta \frac{\partial E}{\partial K_{ij}} + v_k(t-1) * momentum \quad (9)$$

$$v_b(t) = -\eta \frac{\partial E}{\partial b_j} + v_b(t-1) * momentum \quad (10)$$

式中, $momentum$ 为动量, $momentum \in [0, 1]$ 。如果 t 时刻更新的 $v(t)$ 与上一时刻更新的 $v(t-1)$ 的方向相同, 就会加速, 反之则会减速。加入动量因子之前, 在随机下降过程中, 选取的样本对参数求导后的方向就是下降的方向, 虽然解决了非随机计算需处理所有样本、迭代过多的问题, 但是在靠近极值时收敛速度减慢, 而且单个样本可能存在大量噪声, 每次迭代不一定是向着整体最优化方向。加入动量因子后, 可以加速收敛, 提高精度, 若干次计算后可以保证下降方向的最优, 减少了收敛过程中的振荡。

2 基于改进 CNN 的轴承故障诊断流程图

将提出的改进 CNN 模型用于故障诊断。建立 CNN 模型的过程包括划分训练和测试集、使用训练集训练模型、使用测试集测试模型的泛化能力并输出分类结果。CNN 模型的训练流程图如图 2 所示, 其中结构 1 中卷积-池化层的数量由实际需要决定。在训练过程中引入 Dropout 机制, 将隐层神经元按一定比例随机置零, 可降低模型过拟合的风险^[23]。

首先由时序图得到初始特征序列, 进入卷积层进行卷积计算, 得到信号的故障特征映射, 对其进行批归一化处理得到重构结果并输入 ReLU 激活函数; 然后将重构的故障特征映射输入最大池化层进行压缩; 在经过若干个结构 1 中的卷积-池化结构后, 输入结构 2 中的新卷积层重新进行故障特征映射; 使用全连接层连接前一层的所有神经元, 通过 softmax 层得到概率序列, 以 0.5 的概率对节点进行 Dropout, 计算损失函数。若损失函数不满足终止条件, 就使用 SGDM 训练所选样本的卷积核和偏置矩阵, 更新其参数, 继续上述计算, 直至损失函数满

足终止条件。在完成训练后，将测试集输入该 CNN 模型并统计它的分类准确率，作为对该模型的评估。

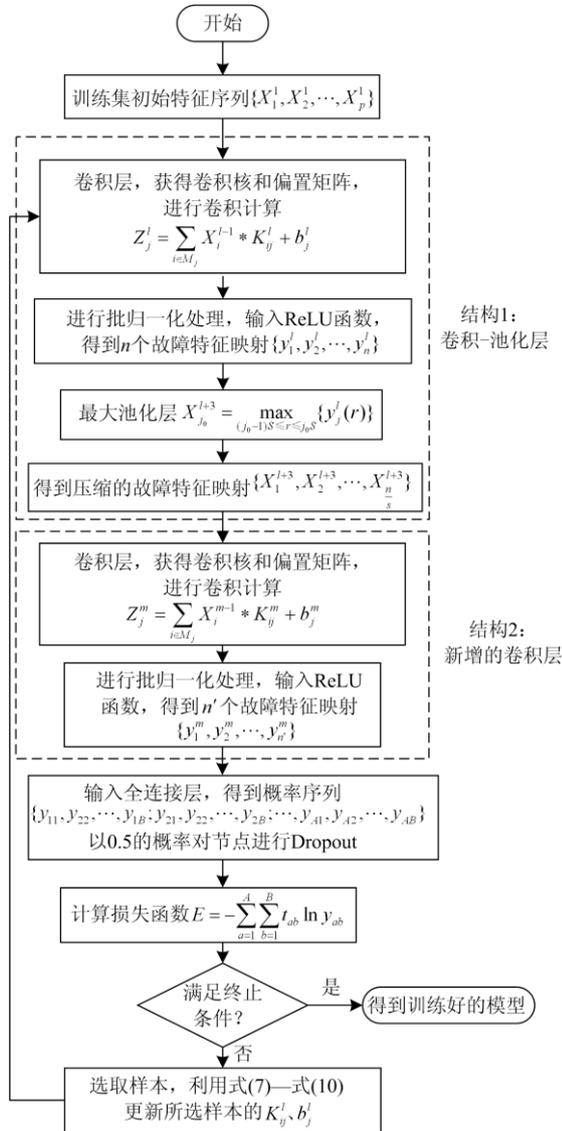


图 2 改进 CNN 模型的训练流程图

Fig. 2 Flow chart of the training process of the improved CNN

3 实验验证

3.1 实验数据集

本文使用的原始数据来自凯斯西储大学滚动轴承数据库中的部分数据。在该实验平台上，使用电火花加工技术在轴承上布置单点故障，有内圈故障、滚动体故障、外圈故障三种类型的故障，并使用 16 通道的 DAT 记录器采集振动信号加速度，采样频率为 12 kHz。首先对得到的滚动轴承时序信号进行标准化处理，然后进行随机分段，分段信号的长度为 2 000，保存为时序图，每种类型的样本数量为 200，

将数据集随机分为训练集和测试集，其中训练集数量为 150，测试集数量为 50。保存 800 个时域信号的波形图，它们对应四种标签：正常信号(normal)、内圈故障信号(Inner)、滚动体故障信号(Roll)、外圈信号(Outer)。这些时序图的像素为 64×86，通道为 3。

3.2 CNN 模型的结构与参数

用于故障诊断的 CNN 模型的结构和参数如表 1 所示。结构 1 中有两个卷积-池化层，两个卷积层分别位于网络的第 2、第 6 层，两个最大池化层分别位于第 5、第 9 层；结构 2 中新增的卷积层位于网络的第 10 层。三个卷积层中卷积核的个数分别为 8、16、32。

表 1 改进 CNN 模型的结构与参数

Table 1 Structure and parameters of the improved CNN model

层数	结构类型	参数
1	输入层	800 个波形图
2	卷积层 1	3×3, 个数 8
3	批归一化层 1	通道数 8
4	激活函数层 1	ReLU 函数
5	最大池化层 1	2×2
6	卷积层 2	3×3, 个数 16
7	批归一化层 2	通道数 16
8	激活函数层 2	ReLU 函数
9	最大池化层 2	2×2
10	卷积层 3	3×3, 个数 32
11	批归一化层 3	通道数 32
12	激活函数层 3	ReLU 函数
13	全连接层	节点数 4
14	Dropout 层	概率为 0.5
15	输出层	分类数 4

将数据集输入该 CNN 模型，将初始学习率设置为 0.01，动量设置为 0.9。

3.3 泛化性验证与特征可视化

图 3 所示为本文研究中提出的改进的 CNN 的训练进度图，它显示了损失函数和准确度，该准确度是网络对测试集预测正确的标签的比例。有 99.80% 的诊断标签与测试集的真实标签相匹配，而验证损失无限接近于 0，模型训练较快，10 s 左右即可完成训练。传统 CNN 的训练进度图如图 4 所示，测试集的诊断准确性只有 83.08%，模型的泛化能力差；在训练过程中，该模型从训练集中学习规则的能力较差，直到训练结束，模型的损失函数都未收敛。与之相比，在改进的 CNN 中，经过 1~2 轮的训练就可以建立精确的模型，诊断速度快，诊断精度高。

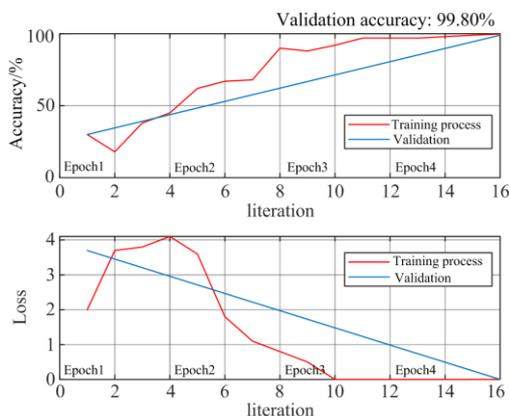


图 3 改进 CNN 模型的训练进度图

Fig. 3 Training process of the improved CNN model

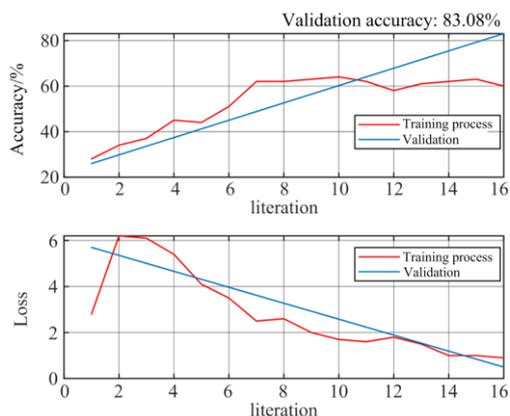


图 4 传统 CNN 模型的训练进度图

Fig. 4 Training process of the classic CNN model

为了体现本文提出的 CNN 的有效性, 利用 t-分布随机邻域嵌入 (t-distribution stochastic neighborembdding, t-SNE) 算法将故障特征可视化。使用 t-SNE 将原始数据集的高维数据映射到二维空间, 然后将其绘制为散点图, 结果如图 5 所示, 每一种颜色代表一种类型的数据。可以看到轴承振动信号的故障特征相互重叠, 难以区分。同样地, 将三个卷积层提取到的故障特征降维可视化, 如图 6 一图 8 所示, 可以看出, 故障特征的重叠率逐渐降低, 变得越来越容易区分。

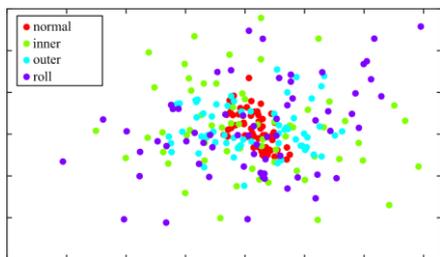


图 5 原始数据集的特征分布

Fig. 5 Feature distribution of original data set

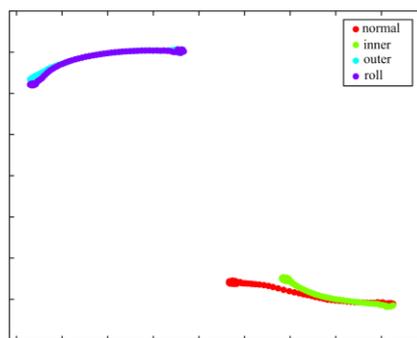


图 6 卷积层 1 输出特征的降维可视化结果

Fig. 6 Dimension reduction visualization of the output

features of convolutional layer 1

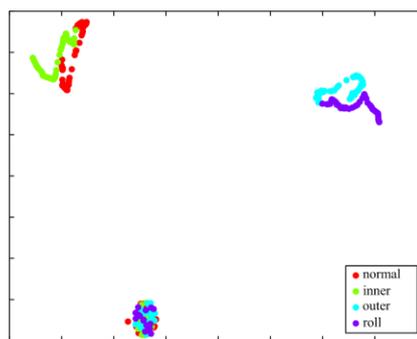


图 7 卷积层 2 输出特征的降维可视化结果

Fig. 7 Dimension reduction visualization of the output

features of convolutional layer 2

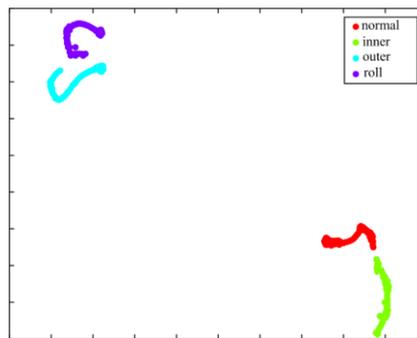


图 8 卷积层 3 输出特征的降维可视化结果

Fig. 8 Dimension reduction visualization of the output

features of convolutional layer 3

为验证模型的泛化能力, 对滚动轴承数据重新进行随机分段, 构成 50 个新的测试集。使用改进 CNN 与传统 CNN 对 50 个新测试集进行诊断, 统计它们对每种类型数据诊断的平均准确性, 结果如图 9 所示, 可以看到传统 CNN 的诊断结果较差, 改进的 CNN 模型对新测试集的诊断准确度更优, 这说明该模型很好地学习了原始滚动轴承数据的深层特征, 泛化能力强。

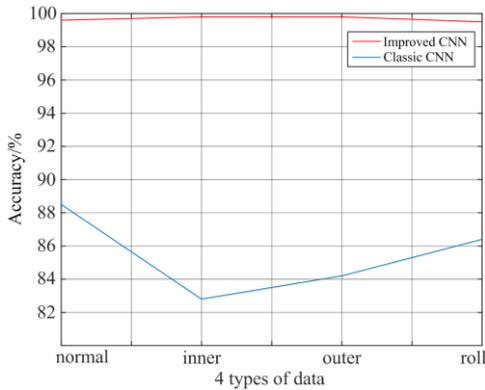


图 9 50 个新测试集的诊断结果

Fig. 9 Diagnostic accuracy of 50 new test sets

3.4 鲁棒性验证

考虑实际工况中风电轴承信号含有很强的噪声, 本文将进一步研究所提出的 CNN 模型的鲁棒性。

随机选取少量训练集样本添加高斯白噪声, 测试集所有样本都添加高斯白噪声。不同信噪比 (SNR=-3~3) 下 CNN 模型对测试集的诊断准确性如图 10 所示, 可以看到改进的 CNN 模型在具有少量噪声样本的前提下便可迅速学习到噪声干扰下轴承信号的分布特征, 诊断准确率较高, 证明该改进的 CNN 模型有较强的鲁棒性。

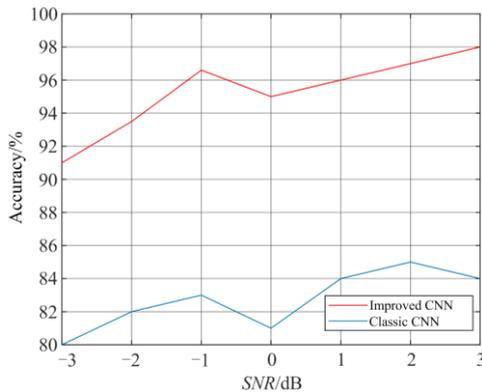


图 10 不同噪声程度测试集的诊断结果

Fig. 10 Diagnostic accuracy of different noise levels

4 结论

针对风电滚动轴承故障特征提取困难、计算量庞大、难以诊断等问题, 结合近些年来深度学习的不断发展, 本文对传统的 CNN 进行改进, 用于滚动轴承的故障诊断。与传统的时频域诊断方法相比, 无需预先处理数据和特征提取; 与传统 CNN 相比, 通过批归一化层和具有动量的梯度下降法加速其训练进度, 并在分类前新增一个卷积层, 用于提高模

型的泛化能力和诊断精确度。通过本文的研究可以看出, 改进的 CNN 具有很强的特征学习和提取的能力, 通过较少样本的学习即可得到整个原始信号的深层特征, 同时在噪声干扰的情况下有较强的鲁棒性, 它在滚动轴承故障诊断方面十分有效。未来可以进一步研究 CNN 模型的参数优化问题, 避免手工调参造成的资源浪费。

参考文献

- [1] YAO Zhiqing, ZHANG Qun, CHEN Peng, et al. Research on fault diagnosis for MMC-HVDC systems[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 71-77. DOI: 10.1186/s41601-016-0022-0.
- [2] KOCHMANN J, MANJUNATHA K, GIERDEN C, et al. A simple and flexible model order reduction method for FFT-based homogenization problems using a sparse sampling technique[J]. Computer Methods in Applied Mechanics & Engineering, 2018, 347: 622-638.
- [3] SEBASTIAN P, DSA P A. Implementation of a power quality signal classification system using wavelet based energy distribution and neural network[C] // 2015 International Conference on Power & Advanced Control Engineering (ICPACE), August 12-14, 2015, Bangalore, India: 157-161.
- [4] MUHAMMET U, MUSTAFA O, MUSTAFA D, et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network[J]. Measurement, 2014, 58: 187-196.
- [5] KUMAR A. Bearing fault diagnosis based on vibration signature analysis using discrete wavelet transform[J]. International Journal of Engineering and Technical Research, 2014, 3(8): 1258-1261.
- [6] VONG C M, WONG P K. Engine ignition signal diagnosis with wavelet packet transform and multi-class least squares support vector machines[J]. Expert Systems with Applications, 2011, 38(7): 8563-8570.
- [7] 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.
- [8] LU Jinling, SHENG Feifei, ZHAO Hongshan. Fault diagnosis method of main bearing main bearing based on limit learning machine[J]. Renewable Energy, 2016, 34(11): 1588-1594.
- [8] 郭艳平, 颜文俊, 包哲静, 等. 基于经验模态分解和散度指标的风力发电机滚动轴承故障诊断方法[J]. 电力系统保护与控制, 2012, 40(17): 83-87, 93.
- GUO Yanping, YAN Wenjun, BAO Zhejing, et al. Fault diagnosis method of wind turbine rolling bearing based

- on empirical modal decomposition and divergence index[J]. Power System Protection and Control, 2012, 40(17): 83-87, 93.
- [9] BUXTON B, GOLDSTON D, DOCTOROW C, et al. Big data: science in the petabyte era[J]. Nature, 2008, 455: 8-9.
- [10] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Research on convolutional neural network[J]. Journal of Computer Science, 2017, 40(6): 1229-1251.
- [11] 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. Classification of power quality disturbances based on feature fusion one-dimensional coiling neural networks[J]. Power System Protection and Control, 2020, 48(6): 53-60.
- [12] MA Yunfei, JIA Xisheng, BAI Huajun, et al. A new fault diagnosis method based on convolutional neural network and compressive sensing[J]. Journal of Mechanical Science and Technology, 2019, 33(11): 177-188.
- [13] 刘佳翰, 陈克绪, 马建, 等. 基于卷积神经网络和随机森林的三相电压暂降分类[J]. 电力系统保护与控制, 2019, 47(20): 112-118.
LIU Jiahan, CHEN Kexu, MA Jian, et al. Three-phase voltage sag classification based on convolutional neural networks and random forests[J]. Power System Protection and Control, 2019, 47(20): 112-118.
- [14] 王瀚晨. 基于深度学习的模拟电路故障诊断研究[D]. 北京: 北方工业大学, 2020.
WANG Hanchen. Research on fault diagnosis of analog circuits based on deep learning[D]. Beijing: North China University of Technology, 2020.
- [15] 胡晓依, 荆云建, 宋志坤, 等. 基于 CNN-SVM 的深度卷积神经网络轴承故障识别研究[J]. 振动与冲击, 2019, 38(18): 173-178.
HU Xiaoyi, JING Yunjian, SONG Zhikun, et al. Fault identification of deep convolution neural network bearing based on CNN-SVM[J]. Vibration and Shock, 2019, 38(18): 173-178.
- [16] 袁建虎. 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.
YUAN Jianhu. Intelligent fault diagnosis method of rolling bearing based on wavelet time-frequency diagram and CNN[J]. Mechanical Design and Research, 2017, 33(2): 93-97.
- [17] FENG Jia, LEI Yaguo. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization[J]. Mechanical Systems and Signal Processing, 2018, 110(9): 349-367.
- [18] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Classification and identification of cable early fault based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [19] GLOT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[J]. Journal of Machine Learning Research, 2012, 15: 315-323.
- [20] 高子翔, 张宝华, 吕晓琪, 等. 基于自适应池化的双路卷积神经网络图像分类算法[J]. 计算机工程与设计, 2019, 40(5): 1334-1338.
GAO Zixiang, ZHANG Baohua, LÜ Xiaoqi, et al. Image classification algorithm based on adaptive pool convolutional neural network based on adaptive pooling[J]. Computer Engineering and Design, 2019, 40(5): 1334-1338.
- [21] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks[J]. Computer Science, 2015(12): 1-14.
- [22] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法[J]. 计算机工程与设计, 2018, 39(2): 441-445, 462.
WANG Gongpeng, DUAN Meng, NIU Changyong. Random gradient descent algorithm based on convolution neural network[J]. Computer Engineering and Design, 2018, 39(2): 441-445, 462.
- [23] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Research Gate, 2012, 3(4): 212-223.

收稿日期: 2020-05-26; 修回日期: 2020-07-29

作者简介:

常 淼(1996—), 女, 硕士研究生, 研究方向为风电滚动轴承的故障诊断策略; E-mail: cm15518999391@163.com

沈艳霞(1973—), 女, 博士, 教授, 研究方向为电机的非线性控制。E-mail: shenyx@jiangnan.edu.cn

(编辑 周金梅)