

基于 AlexNet – Adaboost 的多工况滚动轴承故障识别方法

唐贵基, 田寅初, 田甜

(华北电力大学(保定) 机械工程系, 河北 保定 071003)

摘要: 针对实际工程中滚动轴承多工况下传统故障诊断方法识别率偏低的情况。提出了一种基于 AlexNet – Adaboost 相结合的滚动轴承故障识别方法。以滚动轴承信号的时频图作为模型输入、分类结果作为模型输出, 训练多个 AlexNet 基分类器; 在此基础上利用 Adaboost(自适应提升)算法进一步提升得到强分类器, 将多工况下滚动轴承信号的时频图输入强分类器进行测试。结果显示, 所提方法可实现对多工况下滚动轴承故障有效识别, 并且在一定程度上提高了故障分类的准确性。

关键词: 状态识别; 时频图; 滚动轴承; 卷积神经网络(CNN); 自适应提升算法

中图分类号: TH133.33

文献标志码: A

DOI:10.13465/j.cnki.jvs.2022.02.003

Multi-working condition rolling bearing fault identification method based on the AlexNet – Adaboost algorithm

TANG Guiji, TIAN Yinchu, TIAN Tian

(Department of Mechanical Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: In view of the low recognition rate of the traditional fault diagnosis method for rolling bearings under multiple working conditions in practical engineering, a rolling bearing fault identification method based on the AlexNet – Adaboost algorithm was proposed. Taking the time-frequency diagram of the rolling bearing signal as the model input and the classification result as the model output, several AlexNet – based classifiers were trained. On this basis, the Adaboost (adaptive lifting) algorithm was used to further improve the strong classifier, and the time-frequency diagram of the rolling bearing signal under multiple working conditions was input into that strong classifier for testing. The results show that the proposed method can effectively identify rolling bearing faults under multiple working conditions, and improve the fault classification accuracy to a certain extent.

Key words: fault diagnosis; time-frequency diagram; rolling bearing; convolutional neural network (CNN); Adaboost algorithm

近年来,随着深度学习在图像和语音识别等领域的成功应用^[1],相较于传统诊断方法,在提取特征、识别准确率等方面具有明显优势。卷积神经网络(convolutional neural network, CNN)目前在医学、认知科学和人工智能领域得到了广泛应用:文献[2]使用一维 CNN 自适应提取滚动轴承故障信号的故障特征;文献[3]直接将滚动轴承故障信号作为输入,使用 CNN 进行轴承多故障诊断;文献[4]通过 CNN 和振动数据的频域特征对齿轮箱进行故障诊断;文献[5]提出了权值求和和

最大尺度最大池化策略,对故障轴承进行诊断,验证了平移不变 CNN 的有效性;文献[6]将滚动轴承振动信号的频谱图作为输入通过 CNN 自适应提取故障特征;文献[7]通过短时傅里叶变换得到振动信号的时频图并将其作为 CNN 的输入,一定程度上实现了端到端的轴承故障诊断;文献[8]使用深度卷积自编码器对振动信号时频图进行去噪,然后利用 CNN 对去噪后的图像进行故障分类;文献[9]对 CNN 全连接层进行改进,使用改进 CNN 算法进行滚动轴承故障识别;文献[10]通过基于粒子群优化的细菌觅食方法改进 AlexNet,实现了滚动轴承 16 种故障状态的诊断。以上方法为滚动轴承故障诊断提供了良好借鉴。

但在实际工程应用中,用于训练的样本数据往往

基金项目: 河北省自然科学基金(E2020502031)

收稿日期: 2020-07-21 修改稿收到日期: 2020-10-26

第一作者 唐贵基 男,博士,教授,1962 年生

通信作者 田寅初 男,硕士生,1996 年生

受其样本大小、维度和总体表示形式的影响。因此,神经网络模型的训练效果经常被有限的数据集和预测问题所限制。而故障状态种类越多,所需要的训练样本数量相应就需要增加。Adaboost(自适应提升)算法可以更加充分地利用数据集,通过提高被上一个基分类器错分样本的权重来提高下一个基分类器对于错分样本的准确率,并且最终将所有的基分类器按不同的权重组合为强分类器。为了使用有限的数据集得到更好的分类效果,进一步实现多工况状态下更多故障的分类,本文综合 Adaboost 算法在集成学习领域和 AlexNet 在图像分类领域各自的优势,以轴承故障信号时频图为对象,提出了一种基于 AlexNet - Adaboost 的多工况滚动轴承故障识别方法。

1 理论基础

1.1 小波变换

传统的傅里叶变换是一种全局变换,无法将信号的时域特征和频域特征联系起来。小波变换具有良好的时频局部化特性,可以表现出振动信号的频域特征而不丢失其时域特征^[11]。小波变换通过小波母函数的平移和伸缩得到一系列小波序列,以此将信号分解为不同的频率分量,具体过程可表示为

$$\psi_{a,b} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

式中: $\psi(t)$ 为小波母函数; a 为尺度因子并假定 $a > 0$; b 为平移因子。

对于任意二次方可积函数 $f(t) \in L^2(R)$, 其连续小波变换定义为

$$WT_f(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (2)$$

1.2 AlexNet

AlexNet 由 2012 年 ImageNet 竞赛冠军获得者 Hinton 和他的学生 Krizhevsky 等^[12] 设计。AlexNet 是第二代 CNN, 在第一代 CNN 的基础上加深了网络架构, 能够提取更丰富更高维的图片特征。AlexNet 主要包含 8 层: 前 5 层是卷积层; 后 3 层是全连接层, 最后 1 层的输出经过 Softmax 函数, 产生 1 000 类标签的概率分布。详细结构如图 1 所示, 不同于第一代 CNN, AlexNet 使用两个 GPU 进行训练, 其网络结构的上下部分完全相同, 只在特定层进行信息交互以完成对图片的并行处理。AlexNet 已广泛应用于图像识别、图像检索、语音识别等领域。

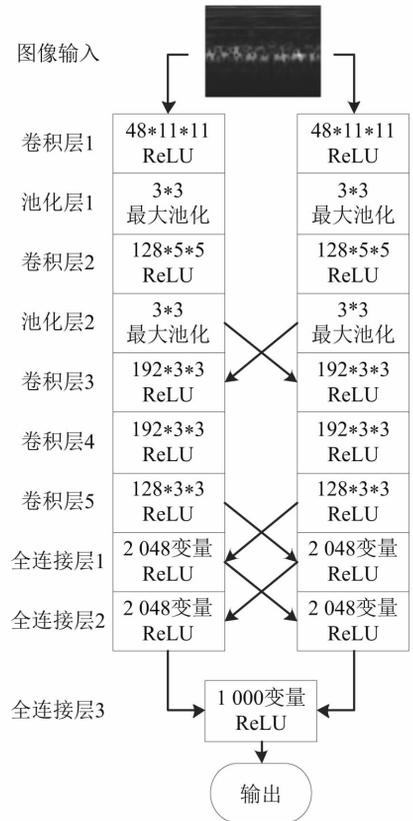


图 1 AlexNet 结构图

Fig. 1 AlexNet structure diagram

1.3 Adaboost

Adaboost 算法由 Freund 等^[13] 开发, Adaboost 会在训练数据集中产生一系列权重, 从而对训练数据进行调整以生成多个假设。在每次迭代中, 调用学习算法以最小化训练数据集上的加权误差, 并将其应用于更新训练数据集的权重。权重变化的影响是将更多的权重放在被误分类的训练数据上, 将更少的权重放在正确分类的训练数据上。因此, 随着迭代的进行, Adaboost 会逐步构造更难的学习问题。Adaboost 算法的过程如下:

步骤 1 初始化训练数据的权重 $w_i = \frac{1}{n}, i = 1, 2, \dots, N$;

步骤 2 迭代过程 $m = 1 \sim M$

(a) 使用带权重 w_i 的训练数据来训练分类器 $T_m(x)$

(b) 计算分类结果误差

$$err_m = \frac{\sum_{i=1}^n w_i \cdot \mathbb{I}[c_i \neq T_m(x)]}{\sum_{i=1}^n w_i} \quad (3)$$

(c) 计算权重系数

$$\alpha_m = \ln \frac{1 - err_m}{err_m} \quad (4)$$

(d) 更新权重

$$w_{i+1} = w_i \cdot \exp\{\alpha_m \cdot \mathbb{I}[c_i \neq T_m(x)]\},$$

$$i = 1, 2, \dots, m \quad (5)$$

(e) 归一化 w_i ;

步骤3 输出预测值

$$C(x) = \arg \max \sum_{m=1}^M \alpha_m \cdot \mathbb{I}[T_m(x) = k] \quad (6)$$

原始的 Adaboost 算法仅限于二分类问题, Zhu 等^[14]对 Adaboost 算法进行了改进, 使用多分类指数损失函数的阶段性加法建模, 改进后的 Adaboost 算法与原算法非常相似, 主要区别为权重系数计算公式

$$\alpha_m = \ln \frac{1 - err_m}{err_m} + \ln(K - 1) \quad (7)$$

式中, K 为总分类数。

2 基于 AlexNet - Adaboost 的滚动轴承故障识别

2.1 时频图的获取和预处理

本文取 1 024 个采样点为一个样本, 通过重叠采样来增加样本数量^[15]。假设原数据数列数据点个数为 M , 样本长度为 N , 采样偏移量为 ΔX , 则该数列可以产生样本个数为 Y , 其公式为

$$Y = \frac{M - N}{\Delta X} + 1 \quad (8)$$

使用 'cmor3-3' 小波, 尺寸序列长度为 256, 采样频率为 12 kHz, 分别对正常轴承、内圈故障轴承、外圈故障轴承和滚动体故障轴承的振动信号做小波变换绘制时频图, 去除时频图周边的坐标、文字、能量条部分, 将所得到的时频图尺寸调整为 227×227 。

2.2 简化 AlexNet

AlexNet 虽然拥有更强的学习能力, 但是它的网络结构也更为复杂, 且需要两个 GPU 并行运算以及上百万个训练样本, 相应的时间成本和经济成本会大大增加。相对于上千种类的图片分类问题, 数十种类的滚动轴承故障识别属于少类别的任务, 因此可以在避开百万级数据样本和多个 GPU 并行运算的要求下, 通过精简 AlexNet 的结构的同时运用它包含的部分新技术来解决滚动轴承故障识别问题^[16]。本文使用的 AlexNet 结构如图 2 所示。

2.3 基于 RMSprop 的权值参数优化

随机梯度下降 (stochastic gradient descent, SGD) 算法是目前使用最多的梯度下降优化算法之一, SGD 算法通常可以找到最优解, 但是会花费远多于自适应优化算法的时间, 且 SGD 算法非常依赖于鲁棒的初始化值以及退火策略。而自适应优化算法可以在不调参的情况下使用更短的时间得到较好的效果, 常用的自适应优化算法有 Adadelta、RMSprop 和 Adam 等, 上述 3 种算法非常相似, 在相同的情况下都能得到较好的结果^[17]。本文使用收敛速度最快的 RMSprop 算法来训练模型。

$$v_i = \beta \cdot v_i + (1 - \beta)(\nabla w_i)^2 \quad (9)$$

$$w_{i+1} = w_i - \frac{\alpha}{\sqrt{v_i} + \delta} \nabla w_i \quad (10)$$

式中: i 为迭代次数; α 为全局学习率; v_i 为累计平方梯度; β 为衰减率; ∇w_i 为梯度累计量; w_i 为被更新的权值。

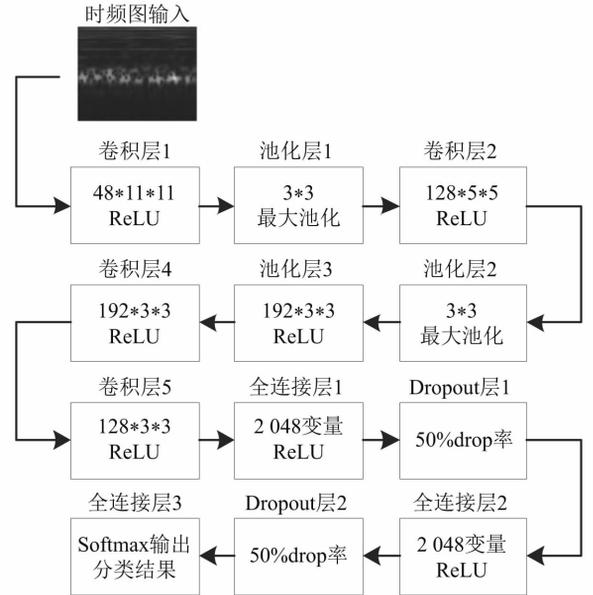


图2 简化 AlexNet 结构图

Fig. 2 Simplify AlexNet structure diagram

2.4 AlexNet - Adaboost 方法的步骤

本研究方法的流程图如图 3 所示。

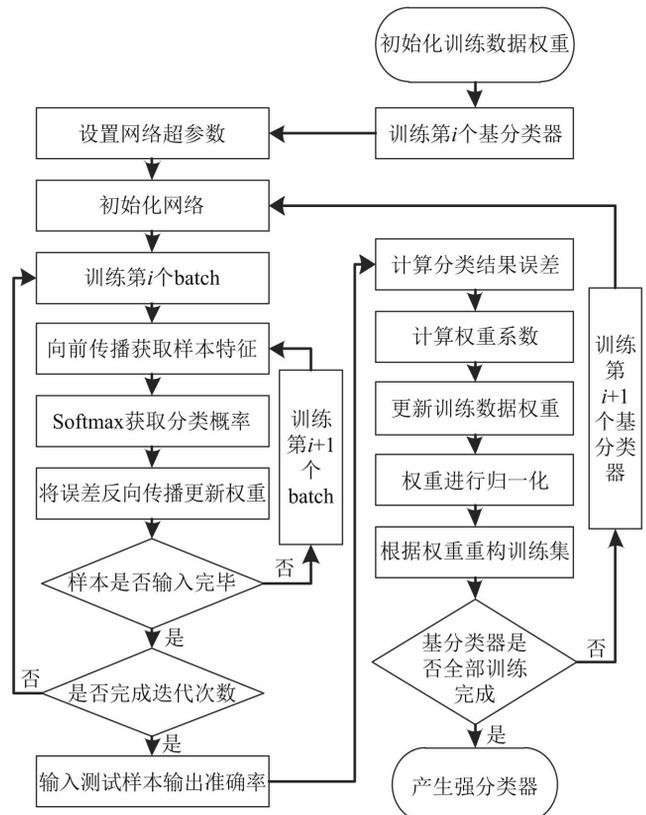


图3 AlexNet - Adaboost 算法流程图

Fig. 3 AlexNet - Adaboost algorithm flow chart

本研究方法的具体步骤如下：

- 步骤 1** 采集滚动轴承在不同工况、不同状态下的振动信号；
- 步骤 2** 通过小波变换将一维的振动信号转化为 227×227 尺寸的二维时频图；
- 步骤 3** 初始化训练数据的权重为 $w_i = \frac{1}{n}$ ；
- 步骤 4** 使用带权重的训练数据来训练第一个基分类器；
- 步骤 5** 使用测试数据集计算基分类器的分类结果误差,并计算权重系数；
- 步骤 6** 根据权重系数更新训练数据集的权重,提高误分类样本的权重,并将权重归一化；
- 步骤 7** 使用更新权重后的训练数据集训练下一个基分类器；
- 步骤 8** 重复步骤 5 ~ 步骤 7 直到所需基分类器全部训练完成；
- 步骤 9** 将所有的基分类器按权重系数组合成最终的强分类器；
- 步骤 10** 使用最终的强分类器进行多工况下的滚动轴承故障识别。

3 案例分析

分析过程的具体流程如图 4 所示。

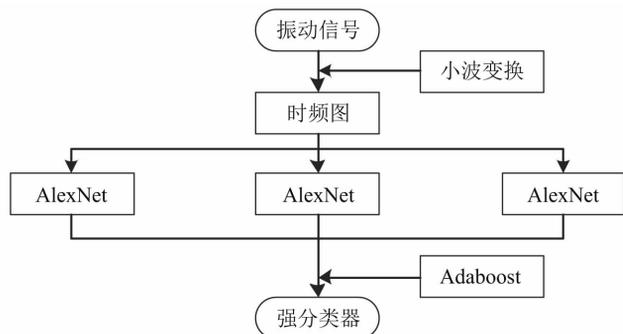


图 4 分析过程流程图

Fig. 4 Analysis process flow chart

3.1 构造数据集

本文所用振动数据为美国凯斯西储大学轴承数据库的滚动轴承振动加速度数据^[18]。试验数据包括正常、内圈故障、外圈故障和滚动体故障信号,在 4 种工况(电动机负载分别为 735.498 75 W, 1 470.997 50 W, 2 206.496 25 W)下各收集 3 种损伤直径(0.177 8 mm, 0.355 6 mm, 0.533 4 mm)数据,总共为 40 种状态如表 1 和表 2 所示。每种状态收集 450 个样本,共收集 18 000 个训练样本,分为 15 000 个训练样本和 3 000 个测试样本。

由于每种状态样本数量较少,为了增加模型的泛化能力,防止过拟合,在训练前进行数据增强,每张图

片的高度和宽度按 10% 比例随机垂直水平偏移,并随机对整张图片进行水平翻转。除数据增强外,训练时会进行样本重采样处理,每个训练阶段实际使用的样本数量为真实样本的三倍。

表 1 轴承故障状态标签

Tab. 1 Bearing fault status label

故障深度/mm	电机负载/W	滚动体	内圈	外圈
0.177 8	0	0	3	6
	735.498 75	10	13	16
	1 470.997 50	20	23	26
	2 206.496 25	30	33	36
0.355 6	0	1	4	7
	735.498 75	11	14	17
	1 470.997 50	21	24	27
	2 206.496 25	31	34	37
0.533 4	0	2	5	8
	735.498 75	12	15	18
	1 470.997 50	22	25	28
	2 206.496 25	32	35	38

表 2 轴承正常状态标签

Tab. 2 Bearing normal status label

电机负载/W	正常
0	9
735.498 75	19
1 470.997 50	29
2 206.496 25	39

3.2 故障识别结果及分析

滚动轴承的主要作用之一是承载负荷,因此当电动机负载发生变化时,不得不考虑滚动轴承故障识别方法是否仍然具有较高的识别准确率,所以要求识别方法有较好的泛化能力。对此,本文使用 AlexNet - Adaboost、CNN - Adaboost、AlexNet、CNN 和传统机器学习方法 SVM(support vector machine)分别在单工况和多工况下进行故障识别进行对比试验。对比试验使用同样的数据集分别测试使用不同方法的识别准确率。同时,为排除试验的偶然性,对每种方法分别运行 5 次的准确率取平均值得到最终结果。

SVM 的最优参数通过在单独划分出的验证数据集上进行网格搜索得到。本文方法使用的基分类器与 AlexNet 方法相同,结构见图 2;CNN - Adaboost 方法使用的基分类器和 CNN 方法相同,结构如图 5 所示。AlexNet 模型和 CNN 模型都通过 RMSprop 算法来训练,全局学习率设置为 0.000 1,衰减率设置为 0.000 001,批量尺寸设置为 32,迭代次数设置为 15。

首先,分析单工况下的滚动轴承故障识别,单工况数据集包括在电动机负载为 0 的情况下滚动轴承不同

故障部位不同损伤直径共 10 种状态。故障识别结果如图 6 所示,使用 AlexNet 或者 CNN 作为基分类器通过 Adaboost 集成得到的强分类器准确率都为 100%; AlexNet 方法和 CNN 方法准确率分别为 99.73% 和 98.13%; SVM 准确率为 99.33%。可以看出,在单工况下进行故障识别较为简单,几种方法都可以得到较好的识别效果。

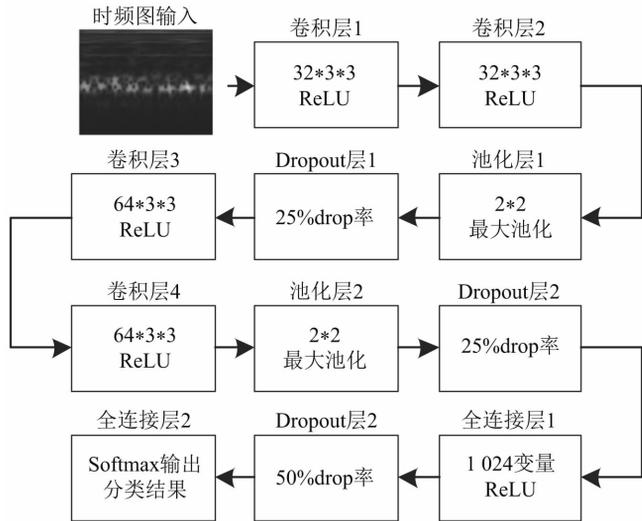


图 5 CNN 结构图

Fig. 5 CNN structure diagram

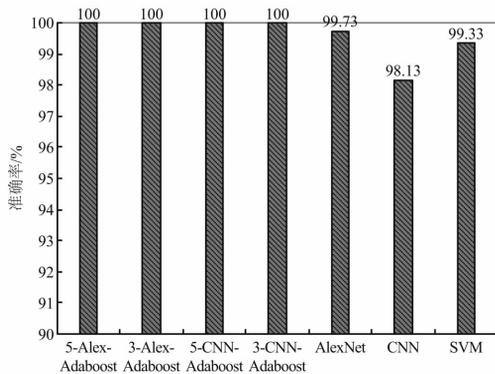


图 6 单工况下不同方法的故障识别准确率

Fig. 6 Fault recognition accuracy of different methods under single working condition

其次,分析多工况下的滚动轴承故障识别,多工况数据集包括滚动轴承在 4 种工况下滚动轴承不同故障部位不同损伤直径共 40 种状态。结果如图 7 所示,使用 AlexNet 作为基分类器时,5 个基分类器集成得到的强分类器准确率为 98.43%,3 个基分类器进行集成得到的准确率为 98.2%;使用 CNN 作为基分类器时,5 个基分类器集成得到的强分类器准确率为 95.1%,3 个基分类器进行集成得到的准确率为 93.87%; AlexNet 和 CNN 准确率分别为 90.87% 和 81.33%; SVM 方法准确率为 93.57%。可以看出,在多工况下进行故障识别,本文方法仍有高的准确率,而其他几种方法的准确率都显著降低。综述,本文方法准确率最高,且具有较

好的泛化性能。

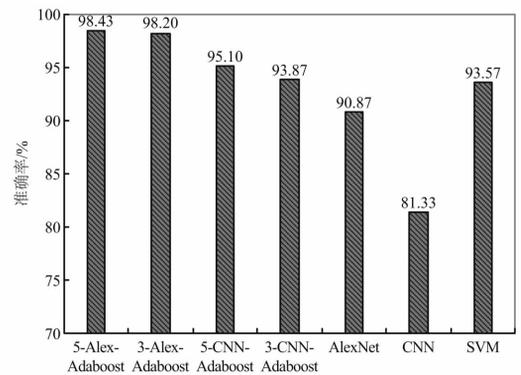


图 7 多工况下不同方法的故障识别准确率

Fig. 7 Fault recognition accuracy of different methods under multiple working conditions

4 结论

本文提出了一种基于 AlexNet - Adaboost 相结合的滚动轴承故障识别方法。构造不同数量的 AlexNet 模型作为基分类器,形成最终的 AlexNet - Adaboost 强分类器,实现了多工况条件下滚动轴承的 40 种类别的状态识别。该方法可以通过提高被前一个基分类器错误分类样本的权重并用来训练下一个基分类器,最终提高整体样本的识别准确率,充分利用有限的数据集得到更高的准确率。与 CNN - Adaboost、AlexNet、CNN 和 SVM 方法相比,所提方法应用于凯斯西储大学轴承数据集进行滚动轴承故障识别,在多工况条件下对滚动轴承不同位置、不同损伤程度的 40 种类故障识别准确率最高,且相对于其他方法有更好的泛化能力,证明了该方法的有效性。

参考文献

- [1] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436 - 444.
- [2] 曲建岭,余路,袁涛,等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算[J]. 仪器仪表学报, 2018, 39(7): 134 - 143.
QU Jianling, YU Lu, YUAN Tao, et al. Adaptive fault diagnosis algorithm for rolling bears based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134 - 143.
- [3] HOANG D T, KANG H J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image[J]. Cognitive Systems Research, 2018, 53: 42 - 50.
- [4] CHEN Z Q, LI C, SAN CHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J]. Shock and Vibration, 2015(2): 1 - 10.
- [5] 朱会杰,王新晴,芮挺,等. 基于平移不变 CNN 的机械故障诊断研究[J]. 振动与冲击, 2019, 38(5): 45 - 52.
ZHU Huijie, WANG Xinqing, RUI Ting, et al. Machinery fault diagnosis based on shift invariant CNN [J]. Journal of Vibration and Shock, 2019, 38(5): 45 - 52.

- [6] 张文凤,周俊. 基于 Dropout-CNN 的滚动轴承故障诊断研究[J]. 轻工机械, 2019,37(2): 62 - 67.
ZHANG Wenfeng, ZHOU Jun. Fault diagnosis method of rolling bearing based on Dropout-CNN [J]. Light Industry Machinery, 2019,37(2): 62 - 67.
- [7] 李恒,张氢,秦仙蓉,等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J]. 振动与冲击, 2018,37(19): 124 - 131.
LI Heng, ZHANG Qing, QIN Xianrong, et al. Fault diagnosis method for rolling bearings based on short-time Fourier transform and convolution neural network[J]. Journal of Vibration and Shock, 2018,37(19): 124 - 131.
- [8] 万齐杨,熊邦书,李新民,等. 基于 DCAE - CNN 的自动倾斜器滚动轴承故障诊断[J]. 振动与冲击, 2020,39(11): 273 - 279.
WAN Qiyang, XIONG Bangshu, LI Xinmin, et al. Fault diagnosis for rolling bearing of swashplate based on DCAE - CNN[J]. Journal of Vibration and Shock, 2020,39(11): 273 - 279.
- [9] 宫文峰,陈辉,张泽辉,等. 基于改进卷积神经网络的滚动轴承智能故障诊断研究[J]. 振动工程学报, 2020,33(2): 400 - 413.
GONG Wenfeng, CHEN Hui, ZHANG Zehui, et al. Research on intelligent fault diagnosis of rolling bearing based on improved convolutional neural network [J]. Journal of Vibration Engineering, 2020,33(2): 400 - 413.
- [10] 赵小强,张青青,陈鹏,等. 基于 PSO - BFA 和改进 AlexNet 的滚动轴承故障诊断方法[J]. 振动与冲击, 2020,39(7): 21 - 28.
ZHAO Xiaoqiang, ZHANG Qingqing, CHEN Peng, et al. Rolling bearing fault diagnosis method based on improved AlexNet and PSO - BFA [J]. Journal of Vibration and Shock, 2020,39(7): 21 - 28.
- [11] 蔡苗苗. 基于小波变换和神经网络的滚动轴承故障诊断系统[D]. 大庆:东北石油大学, 2015.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012,25(2): 1 - 9.
- [13] FREUND Y, SCHAPIRE R E. A desicion-theoretic generalization of on-line learning and an application to boosting [J]. Journal of Computer and System Sciences, 1995,55: 119 - 139.
- [14] ZHU J, ROSSET S, ZOU H, et al. Multi-class adaboost[J]. Statistics and Its Interface, 2006,2(3): 349 - 360.
- [15] 蒙志强,董绍江,潘雪娇,等. 基于改进卷积神经网络的滚动轴承故障诊断[J]. 组合机床与自动化加工技术, 2020(2): 79 - 83.
MENG Zhiqiang, DONG Shaojiang, PAN Xuejiao, et al. Fault diagnosis of rolling bearing based on improved convolutional neural network [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(2): 79 - 83.
- [16] 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.
- [17] RUDER S. An overview of gradient descent optimization algorithms[EB/OL]. (2017 - 06 - 15) [2020 - 07 - 21]. <https://arxiv.org/abs/1609.04747v2>.
- [18] Case Western Reserve University Bearing Data Center[DB]. http://cse.groups.case.edu/bearing_data_center/pages/download-data-file.