

# 基于 NLWT 系数增强的随机失活 CNN 电机运行状态检测<sup>①</sup>



龙 慧, 马家庆, 吴钦木, 何志琴, 陈昌盛, 覃 涛

(贵州大学 电气工程学院, 贵阳 550025)  
通信作者: 马家庆, E-mail: 357287962@qq.com

**摘 要:** 为了快速有效地从热像仪采集的温度数据中识别出电机的运行故障, 本文根据随机失活、非线性小波变换系数增强 (NLWTCE) 和卷积神经网络算法相结合对电机图像进行识别. 首先根据热像仪采集的数据建立电机的图像数据集, 通过非线性小波变换 (NLWT) 将数据进行图像增强, 然后构建改进的卷积神经网络 (ICNN) 模型, 将提取的特征作为最终的识别特征来进行图像识别, 最后根据与正常电机图像作比较, 识别出故障的电机图像, 实现了有效、准确的识别故障电机图像与正常电机图像. 实验结果表明, 改进的卷积神经网络模型不仅具有较高的识别准确率, 也进一步简化了提取图像特征的复杂过程. 该方法的有效性和合理性得到了验证, 并适用于工程运用中.

**关键词:** 卷积神经网络 (CNN); 随机失活; 图像增强; 故障识别; 结构相似指标

引用格式: 龙慧, 马家庆, 吴钦木, 何志琴, 陈昌盛, 覃涛. 基于 NLWT 系数增强的随机失活 CNN 电机运行状态检测. 计算机系统应用, 2023, 32(3): 345-351. <http://www.c-s-a.org.cn/1003-3254/9009.html>

## Motor Running State Detection by Dropout-CNN Based on NLWT Coefficient Enhancement

LONG Hui, MA Jia-Qing, WU Qin-Mu, HE Zhi-Qin, CHEN Chang-Sheng, QIN Tao

(The Electrical Engineering College, Guizhou University, Guiyang 550025, China)

**Abstract:** To identify the running fault of motors quickly and effectively from the temperature data collected by thermal imagers, this study combines dropout, nonlinear wavelet transform coefficient enhancement (NLWTCE), and convolutional neural network (CNN) algorithm to identify the motor image. Firstly, the image dataset of the motor is established according to the data collected by the thermal imager and the data image is enhanced by nonlinear wavelet transform (NLWT). Then an improved CNN (ICNN) model is built to identify the image with the extracted features as the final recognition features. Finally, compared with the normal motor images, the faulty motor images are effectively and accurately identified. The experimental results show that the ICNN model not only has a high recognition accuracy but also further simplifies the complex extraction of image features. The validity and reasonableness of the method are verified, and the method is suitable for engineering application.

**Key words:** convolutional neural network (CNN); dropout; image enhancement; fault identification; structural similarity index

在人工智能领域, 深度学习已经越来越受到关注<sup>[1]</sup>, 电机在运行过程中一般都会有温升, 而产生的温度过高会直接导致电机的损坏, 所以在电机的运行过

程中温度是否过高是对电机是否能正常运行是很重要的因素.

对于电机的故障识别研究, 电机信号采集方法主

<sup>①</sup> 基金项目: 国家自然科学基金 (51867006, 61861007); 贵州省科技厅项目 (黔科合支撑 [2021] 一般 442, [2022] 一般 264)

收稿时间: 2022-08-22; 修改时间: 2022-09-22; 采用时间: 2022-09-30; csa 在线出版时间: 2022-11-29

CNKI 网络首发时间: 2022-11-30

要有温度采集法<sup>[2]</sup>、声音采集法<sup>[3]</sup>、电流采集法<sup>[4]</sup>、振动采集法;常用的电机智能故障诊断方法主要有基于SVM (support vector machines) 的诊断方法<sup>[5]</sup>、基于神经网络的诊断方法<sup>[6]</sup>、基于深度学习的诊断方法<sup>[7]</sup>以及基于迁移学习的诊断方法<sup>[8]</sup>;随着计算机和深度学习技术的不断发展,神经网络中的卷积神经网络是被广泛应用的模型之一;传统的机器学习需要人工来进行分析和提取特征,导致提取出的特征具有较大的主观性和误差性,所以这种传统的方法的准确率不高以及会消耗很大的人力等缺点<sup>[9]</sup>;针对传统机器学习的不足,将卷积神经网络(convolutional neural network, CNN)应用于电机的故障识别,对于深度学习中的CNN是通过使用权重共享、局部连接等方式来自动学习数据的特征<sup>[10]</sup>,相对于传统的方法来说,CNN具有强大的特征学习能力.并且卷积神经网络在电机故障识别方面的研究越来越多.文献[11]将小波分析与卷积神经网络相结合,对电机故障进行了有效的诊断.文献[12]基于定子电流特征与振动特征永磁电机,利用残差连接的卷积神经网络较好的对电机故障进行诊断.文献[13]结合不同变换与深度学习卷积神经网络的方法,对电机系统的故障诊断提供了新的途径.CNN作为一种机器学习在机械故障识别领域得到了广泛的应用.

因此,本文提出了在电机运行温度发生变化时,通过随机失活、NLWTCE与卷积神经网络相结合,可以对电机故障进行准确且快速的识别.提出的模型只需要输入处理好的数据,不需要人工提取特征向量,这样可以减少在提取特征时的损失,还大大减少了人力,用NLWT对图像进行增强,从而提高模型的识别准确率.在构建基于CNN的电机故障诊断模型,提出了一种随机失活、非线性小波变换图像增强的改进卷积神经网络模型的识别诊断方法,不仅能有效地减少过拟合的产生,还能提高识别的准确率,对采集到的信号进行特征提取,实验结果显示该模型取得更好地识别效果.

## 1 理论基础

### 1.1 小波变换的图像增强

数据图像可以看成是一个二维信号,可以通过二维小波变换对图像进行分解和重构.在模型程序中,小波变换的图像增强可以很好地实现,首先输入原图像,对原图像的数据进行小波分解,得到低频和高频部分;对分解后的高频系数进行非线性增强,这样可以实现

图像增强的目的,将处理好的小波系数进行重构,从而得到增强后的数据图像.其函数表达式为:

$$C_{out}(i, j) = \begin{cases} G \cdot C_{in}(i, j), & C_{in}(i, j) > T \\ K \cdot C_{in}(i, j), & C_{in}(i, j) \leq T \end{cases} \quad (1)$$

其中,  $G$  是小波系数增强倍数,  $K$  ( $K < 1$ ) 是小波系数弱化倍数,  $T$  是小波系数阈值,  $C_{in}(i, j)$  是原图像的小波系数,  $C_{out}(i, j)$  是图像增强后的小波系数.

### 1.2 CNN 故障识别模型

CNN 是深度学习算法和人工神经网络的结合,如图1所示,为网络模型的结构图.卷积神经网络中,输入层是还未经过处理的原始图像,输出层是特征分类的结果,隐含层是具有复杂多层非线性结构的神经层,包括卷积层和池化层,在隐含层中这两层可以交替使用,为了能更好地提取出图像特征.




图1 网络模型的结构

#### 1.2.1 卷积层

卷积层的主要作用是利用卷积核对图像特征进行初步提取,增强原始图像的特征信息,在卷积中使用20个 $5 \times 5$ 大小的卷积核对大小为 $28 \times 28$ 的输入图像进行卷积,得到20个 $24 \times 24$ 的特征图.卷积操作的一般形式为:

$$x = f\left(\sum x * \omega_{ij} + b\right) \quad (2)$$

其中,\*为卷积运算符, $b$ 为偏差, $\omega_{ij}$ 为卷积核, $x$ 为输入特征图, $f(\cdot)$ 为激活函数.

#### 1.2.2 池化层

池化层是CNN中的隐含层,输入图像进行卷积后得到20个 $24 \times 24$ 的特征图,将得到的特征图经过池化操作后输出20个 $12 \times 12$ 的特征图.在实验中,所采用的池化操作是平均池化,使这些特征能够有更低的维度,减少计算量.池化层的一般形式为:

$$x = f(\beta \text{down}(x) + b) \quad (3)$$

其中, $\beta$ 为偏置参数, $\text{down}(\cdot)$ 为下采样函数.

#### 1.2.3 激活函数

在本文中,选用了tanh激活函数,它的取值范围在

-1~1, 输出均值是 0, tanh 函数表示为:

$$\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (4)$$

#### 1.2.4 全连接层和 Dropout 层

全连接层的特征是每一个神经元都与上一层的所有神经元相连. 将隐含层输出的 20 个  $12 \times 12$  的特征图进行全连接之后输出的特征图, 全连接层的输出为:

$$F(x) = f(\omega x + b) \quad (5)$$

其中,  $x$  为全连接层的输入,  $F(x)$  为全连接层的输出,  $\omega$  为权值系数.

为了进一步降低过拟合现象的产生, 在全连接层加入随机失活 (Dropout) 层, 在运行时以一定的概率让一些神经元随机的停止工作, 从而达到防止过拟合产生.

$$\text{Dropout}(x) = x \quad (6)$$

其中,  $x$  为随机失活的概率值,  $\text{Dropout}(x)$  为以概率  $x$  的神经元停止工作.

#### 1.2.5 输出层

输出层一般是分类器层 (Softmax 层), 其主要目的是对识别目标进行分类; Softmax 层的输入是上一层全连接层的数据, 输出的数据的每个值范围在 0~1, 输出值表示的是样本属于这一类别的概率.

在本实验中, 所构建的 CNN 模型的结构参数如表 1 所示.

表 1 电机故障识别模型结构参数

基本层类型	通道数	矩阵大小
输入层	1	$28 \times 28$
卷积层	20	$24 \times 24$
池化层	20	$12 \times 12$
Dropout 层	20	$12 \times 12$
过渡层	100	$1 \times 1$
全连接层	1	100
Softmax 分类层	1	10

电机故障识别的过程分为以下几个步骤.

- (1) 采集电机信号图.
- (2) 将采集到的电机信号图进行预处理 (裁剪、转换模式等).
- (3) 将预处理后的图像通过 NLWT 进行图像增强.
- (4) 建立卷积神经网络模型并初始化网络的参数 (根据实验需求, 确定合适的学习率、迭代次数等网络参数).
- (5) 卷积神经网络模型训练 (将处理好的图像输入到模型中, 通过运行得到网络的输出误差, 判断网络模

型是否收敛, 不收敛, 执行步骤 (6); 若收敛, 则执行步骤 (7).

(6) 进行权值修改和更新 (通过反向传播将得到的误差反向传播到各个神经网络, 以此来更新权值, 重复执行步骤 (4) 和步骤 (5), 直到网络模型达到收敛).

(7) 测试样本数据精度、损失函数等是否满足要求 (若满足要求直接输出结果; 否则回到步骤 (3) 修改网络模型参数, 直至满足要求).

(8) 网络模型输出, 判断电机运行的状态.

## 2 电机故障识别方法

### 2.1 CNN 故障识别模型

图像故障识别结果可以基于以下指标进行评价.

#### (1) 损失函数<sup>[14]</sup>

是用于评估模型预测值与真实值之间的不一致程度. 损失函数越小, 代表模型的鲁棒性越好.

其函数形式为:

$$\text{Loss} = - \sum_x p(x) \log(q(x)) \quad (7)$$

其中, 变量  $p(x)$  为真实分布的概率,  $q(x)$  为模型通过数据计算出的概率估计.

#### (2) 结构相似指标函数 (SSIM)<sup>[15]</sup>

是用于评估电机识别图片的失真程度, 也可以评估两张图片的相似程度.

$$\text{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (8)$$

其中,  $\text{SSIM}(x, y)$  是两张图像的结构相似指标函数,  $\mu$  为图像的平均像素值,  $\sigma$  为图像的标准差,  $C$  为常数为了避免函数的不稳定性.

本文的方法描述: 总体上主要是由数据采集、构建模型、电机故障识别组成; 首先采集电机数据作为数据集, 将采集到的数据集预处理之后划分为训练集和测试集, 使用 Dropout 函数、NLWTCE 与卷积神经网络相结合构建改进的网络模型, 并设置好合适的参数, 用训练集对网络模型进行训练, 将训练好的模型对测试集进行识别诊断, 实现电机的运行状态识别.

### 2.2 数据采集及预处理

该实验所使用的数据集是实验室电机运行正常图像和异常电机图像, 本文需要判断电机图片是否发生异常为研究对象; 所用数据由实验室实际测试所得, 首先需要通过热像仪设备来采集图像数据, 所采集的图像格式为 BMP. 异常电机图像的主要特征是温度过高,



使得图像在模型中数据偏大。

为了使电机图像有更好的识别效果,有利于卷积神经网络模型对图像特征进行学习,把电机原图像删掉空白和坐标部分之后变换为灰度图,为了使卷积神经网络更方便的计算和训练,将图片压缩为 28×28 的尺寸大小,如图 2 所示,然后将处理后的图像制作成数据集并用于实验中。由于在实验数据台上模拟出来的电机状态有限,本文只研究了这 3 种状态,在相同的环境下,每个不同状态下采集了 800 个数据,随机选取不同电机状态样本的 20% 作为测试数据,剩余的作为训练数据。




图 2 部分图像的预处理

实验中,如图 2 所示,为了能更好地从多方面了解电机运行时的工作特点,比较不同方向采集的电机数据图像发现,热像仪对电机运行时所采集的图像,由于在采集时温度差的不同导致图像轮廓清晰度不同,但在最后识别之后得到的都是相同的结果。

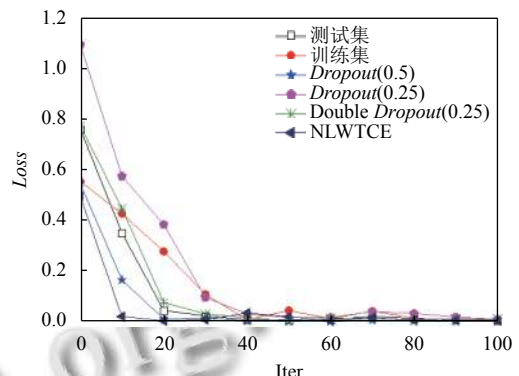
### 3 实验结果与分析

#### 3.1 实验对比分析


本文以 Matlab 为基础搭建神经网络模型,实验中所使用的数据集是根据实验室平台而构建的,首先搭建卷积神经网络模型,使用 Matlab 搭建卷积神经网络

模型,运用了梯度下降法对模型进行优化,用评价指标来对网络的识别性能进行评价。在对电机运行状态进行识别时,将随机失活函数、NLWTCE 与卷积神经网络模型结合,来实现对电机运行状态进行识别。使用 Dropout 函数来减少网络模型过拟合的产生, NLWT 提高模型的准确率,从而完成电机故障的诊断。该实验平台主要由电力电子技术及电机控制实验装置、电机、热像仪和计算机组成。在电机运行状态下,将电机分为 3 种不同的电机状态,即停止状态、正常运行和异常状态。

将预处理后的图像输入到所改进的卷积神经网络模型,实验结果显示如图 3 所示,将非线性小波变换图像增强和没有加图像增强的情况下进行了对比,可以发现,再加入 NLWT 图像增强之后的识别效果更好,经过多次迭代后其损失值和准确率都能达到很好地识别效果,验证了我们改进的 CNN 方法能够快速有效地识别,完成电机的运行状态识别。



(a) 损失值的比较



(b) 准确率的比较

图 3 数据图像在不同迭代次数时的对比

由图 3 显示,随着迭代次数的不断增加,模型在运行时其损失函数的值不断减小最后趋向于零,且准确

率不断增大最后逐渐趋向于1, 准确率是指在测试过程中网络模型的识别成功率. 将本文所提出的 NLWT 系数增强的随机失活 CNN 在不同 Dropout 概率值下进行到 100 次迭代次数电机故障识别的实验对比; 将图像数据直接输入到网络模型中, 如表 2 和图 3 所示, 电机故障识别的准确率与损失值的在不同 Dropout 下对比情况. 本文所改进的方法中, 在迭代次数较小的情况下, 故障识别的损失值和准确率都比较差, 相对来说, 在加入 NLWT 图像增强的 Dropout 概率值为 0.5 时的损失值和准确率均比 Dropout(0)、Dropout(0.25) 和 double Dropout(0.25) 时的情况还要好. 在使用 NLWT 对数据进行图像增强后, 识别精度和损失函数值相对地都有所提高并能更快的趋于稳定. 通过实验结果分析可知, 本文所提出的基于 NLWT 系数增强的随机失活 CNN 故障识别准确率和损失值上表现的更有优势. 在卷积神经网络中, 对该模型进行 100 次迭代实验, 由实验结果可知, 在迭代次数达到 40 时, 测试集在网络模型中的损失值为 1.5%, 准确率为 99.5%, 在迭代 40 次之后, 随着迭代次数的增加, 其损失值和准确率趋于稳定或不变, 网络模型在运行时所需要耗费的时间随着迭代次数的增大而增加, 为了确保网络模型的损失值小且准确率高, 也要保证运行时间要尽可能的少, 所以本文的迭代次数选取 40 次. 分析实验的方法是 NLWT 系数增强的随机失活 CNN 电机运行状态识别.

表 2 不同迭代次数在不同 Dropout 值下准确率的比较 (%)

迭代次数	Dropout(0)	Dropout(0.5)	Dropout(0.25)	Double Dropout(0.25)
1	28.522	59.51	44.011	33.567
10	54.397	63.807	53.194	59.048
20	80.826	97.66	94.288	96.244
30	90.743	99.285	97.206	96.916
40	99.336	99.413	99.192	98.236
50	95.827	99.466	99.866	99.711
60	97.72	99.494	99.357	98.429
70	93.225	98.508	99.261	98.533
80	95.17	99.782	99.608	99.416
90	96.87	99.637	99.611	98.702
100	97.811	99.905	99.718	98.726

### 3.2 WTCE 与 NLWTCE 实验结果对比分析

为了验证本方法的优越性, 将本文方法 NLWTCE 与小波变换数据增强 (WTCE) 的实验结果进行了比较, 图 4 为 WTCE 与 NLWTCE 在不同学习率下损失值的趋势.

图 5 为 WTCE 与 NLWTCE 在不同迭代次数时准

确率的趋势.

从图 4、图 5 的比较结果表明, 学习率过小、过大都会导致损失值过大且准确率降低, 但在学习率适中时, NLWTCE 的损失值相对更小以及准确率更高且稳定; WTCE 和 NLWTCE 的损失值都会随着迭代次数的增加而逐渐降低, 识别准确率随着迭代次数的增加逐渐升高最后趋于稳定, 但 NLWT 的实验结果效果更好; 可以看出 NLWTCE 的实验结果有更好的性能, 该方法在保证识别准确率的前提下, 其迭代次数比较少, 所需要的训练样本越少, 可以节省实验时间, 则该方法能更好地对数据图像进行识别. 相比基于 WTCE 的学习算法, 在相同的训练样本集下, 本文提出的 NLWTCE 的随机失活 CNN 的电机运行状态识别准确率最好, 具有更高的可行性和操作性.

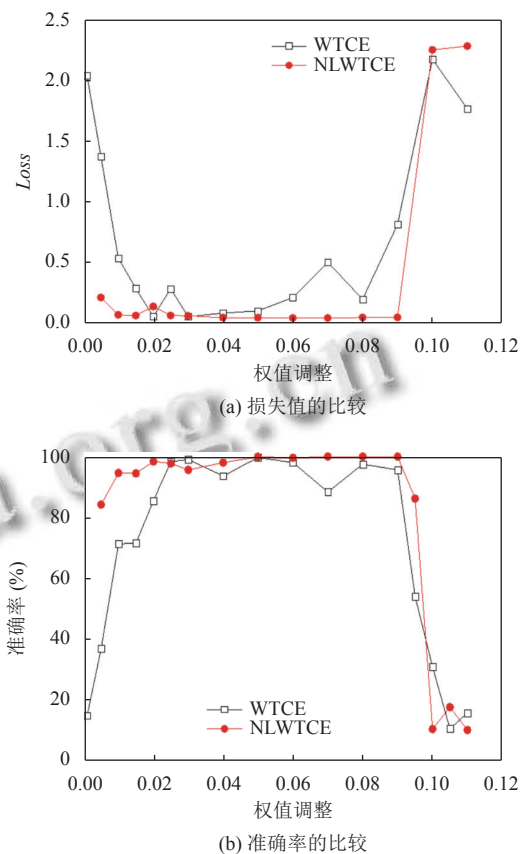


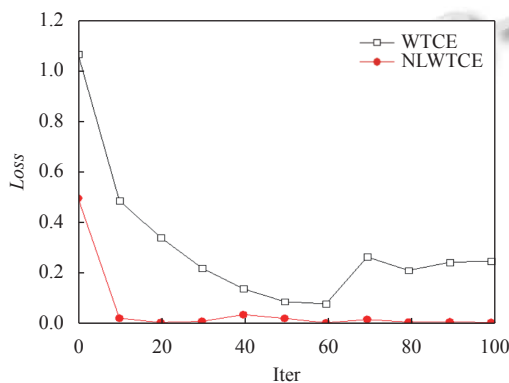
图 4 WTCE 与 NLWTCE 在不同学习率时

### 3.3 实验结果


将预处理后的数据集输入到本文改进的 CNN 模型, 运用 NLWT 对图像进行增强、Dropout 函数对模型进行优化, 其中权值调整是影响误差收敛、评价指

标的一个重要参数. 在网络模型训练中, 为了提高模型运行的效率, 选择一个合适的权值调整步进是相当重要的, 在实验中, 我们在保持其余参数相同时, 采用不同的权值调整来训练卷积神经网络模型, 实验结果如图 6 所示. 从图 6 可以看出, 权值调整步进过大或者过小网络模型的识别准确率都会减小, 训练和测试时的损失函数都会增大; 图 6(b) 可以看出, *Dropout* 概率值为 0.5 时, 其识别准确率相比效果是最好的. 在模型中, 选择一个合适的权值调整参数, 能够使网络模型更快的收敛, 减少其损失值, 还能提高模型的准确率. 在保证损失值小且准确率高, 的情况下, 本文实验选取的权值调整参数为 0.03.

限制, 无法一次将全部样本用于网络训练, 在保持其他参数不变的情况下, 本实验在对训练图的数量进行改变, 其实验结果如图 7 所示, 在训练图数量在不断地增加的同时, 其训练集和测试集的损失值不断减少, 且 *SSIM* 在不断增加, 但网络模型训练所花费的时间也在不断增加. 从实验结果可以看出, 当训练图很少时, 网络模型训练和测试的损失值相对来说比较大, 且 *SSIM* 相对较低. 当训练样本越来越大时, 模型训练和测试的损失值越来越低, *SSIM* 越来越高, 但网络模型运行一次所需要的时间却越来越多. 在实验中, 所采用的训练数为 20, 在保证损失值、准确率和 *SSIM* 的同时, 还相对降低了训练的时间.



(a) 损失值的比较

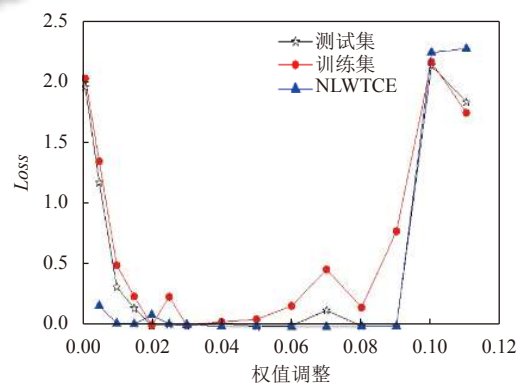


(b) 准确率的比较

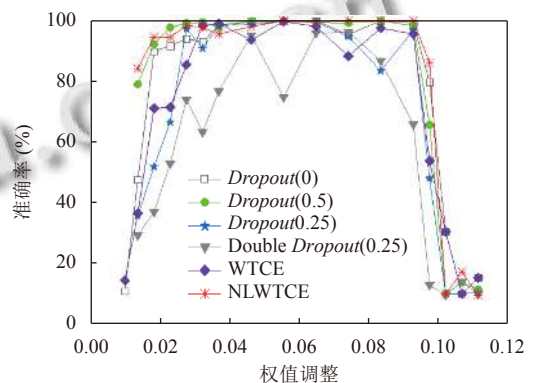
图 5 WTCE 与 NLWTCE 在不同迭代次数时

在使用 NLWT 对数据图像进行增强之后, 电机识别准确率和损失函数相对来说效果更好. 随机失活函数在模型运行时能避免产生过拟合, 而 NLWT 图像增强保证了识别的准确率; 在模型运行时随机失活函数和 NLWTCE 既能防止过拟合的产生又能保证识别准确率.

在网络模型中, 由于样本数大、电脑配置等条件



(a) 损失值的比较



(b) 准确率的比较


图 6 数据图像在不同学习率下的比较

#### 4 结语


本文利用 NLWT 图像增强、改进的卷积神经网络实现了电机运行状态的识别. 在 CNN 中, 选择合适的参数是相当重要的, 实验结果显示, 改进的卷积神经网络在迭代次数和训练样本小以及权值调整过大或过



小的情况下,对电机的运行状态识别都有一定的影响,识别的损失函数值相对来说都比较大且识别的准确率也会过低,但在选择合适的迭代次数、权值调整和训练样本数时,电机故障识别的准确率均达到97%以上,随机失活函数可以很好地避免过拟合的产生,而NLWT图像增强能很好地保证电机故障识别的精度,通过两者结合能更有效地对电机的运行状态进行识别.通过实验结果对比可知,本文所提出的方法在电机运行状态识别的准确率和损失值上均表现出了明显的优势,效果更好.



(a) 损失值的影响



(b) SSIM的影响

图7 数据图像在不同训练图数的影响

### 参考文献

- 李亚召, 云利军, 叶志霞, 等. 基于卷积神经网络的霉变烟叶图像识别方法研究. 计算机工程与科学, 2021, 43(3): 473-479. [doi: 10.3969/j.issn.1007-130X.2021.03.012]
- 刘欢, 陈力, 田建涛, 等. 红外诊断技术在电机故障诊断中的应用. 装备制造技术, 2014, (9): 255-256, 262. [doi: 10.3969/j.issn.1672-545X.2014.09.096]

- 王新杰, 董志学, 潘颖辉. 机车牵引电机声音检测与故障诊断系统应用研究. 计算机应用与软件, 2016, 33(10): 103-107, 171. [doi: 10.3969/j.issn.1000-386x.2016.10.023]
- 张明杰, 曾祥东. HXN3型机车牵引电机故障诊断技术研究. 中国新技术新产品, 2016, (2): 44-45. [doi: 10.13612/j.cnki.cntp.2016.02.034]
- 郑小霞, 周国旺, 任浩翰, 等. 基于变分模态分解和排列熵的滚动轴承故障诊断. 振动与冲击, 2017, 36(22): 22-28. [doi: 10.13465/j.cnki.jvs.2017.22.004]
- 胡耀斌, 谢静, 胡良斌. 基于神经网络与小波变换的滚动轴承故障诊断. 机械设计与研究, 2013, 29(6): 33-35. [doi: 10.13952/j.cnki.jofmdr.2013.06.011]
- Wang F, Jiang HK, Shao HD, et al. An adaptive deep convolutional neural network for rolling bearing fault diagnosis. Measurement Science and Technology, 2017, 28(9): 095005. [doi: 10.1088/1361-6501/aa6e22]
- 符羽. 基于卷积神经网络的三相异步电机故障诊断方法研究 [硕士学位论文]. 南昌: 华东交通大学, 2021. [doi: 10.27147/d.cnki.ghdju.2021.000259]
- 李志军, 陈伟根, 周淙, 等. 基于改进深度学习混合网络与小波分析的电机故障诊断方法. 三峡大学学报(自然科学版), 2021, 43(6): 94-99. [doi: 10.13393/j.cnki.issn.1672-948x.2021.06.015]
- Sun TC, Wang YL, Yang J, et al. Convolution neural networks with two pathways for image style recognition. IEEE Transactions on Image Processing, 2017, 26(9): 4102-4113. [doi: 10.1109/TIP.2017.2710631]
- 王红君, 刘冬生, 岳有军. 基于小波分析和神经网络的电机故障诊断方法研究. 电气传动, 2010, 40(3): 69-73. [doi: 10.3969/j.issn.1001-2095.2010.03.017]
- 杨柏. 基于改进卷积神经网络永磁电机故障诊断方法研究 [硕士学位论文]. 沈阳: 沈阳工程学院, 2020. [doi: 10.27845/d.cnki.gsygc.2020.000008]
- 毛向向, 王红军, 韩凤霞, 等. 基于深度卷积神经网络的机电系统故障分类识别方法. 电子测量与仪器学报, 2021, 35(2): 87-93. [doi: 10.13382/j.jemi.B2003659]
- Zhou YC, Gao ZX. Intelligent recognition of medical motion image combining convolutional neural network with Internet of Things. IEEE Access, 2019, 7: 145462-145476. [doi: 10.1109/ACCESS.2019.2945313]
- Wang Z, Bovik AC, Sheikh HR, et al. Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing, 2004, 13(4): 600-612. [doi: 10.1109/TIP.2003.819861]

(校对责编: 牛欣悦)