

# 基于 CEEMDAN-小波阈值和 3D-CNN 的 变压器铁心松动故障诊断模型\*

崔佳嘉, 马宏忠

(河海大学 能源与电气学院, 江苏 南京 211100)

**摘要:** 为了解决变压器铁心松动故障的识别与诊断, 提出基于完全自适应噪声集合经验模态分解 (CEEMDAN)-小波阈值的环境噪声去除方法, 并提出使用三维卷积神经网络 (3D-CNN) 去识别基于声纹的变压器铁心松动故障诊断方法。搭建变压器铁心松动故障试验平台, 采集铁心在不同松动程度下的噪声信号; 将采集的用于故障识别的声纹信号经过 CEEMDAN-小波阈值算法, 利用变压器本体噪声和环境噪声在峭度上的差异滤波, 得到信噪比较高的变压器声纹信号; 再将滤波后的声纹信号经过短时傅里叶变化生成时频矩阵, 并用 Mel 滤波器降维得到 Mel-语谱图, 制作成适合 3D-CNN 输入格式的数据集; 搭建好网络的各层, 利用 3D-CNN 对变压器铁心松动故障进行分类和识别。试验结果表明: 所提方法在考虑环境噪声的条件下, 变压器铁心松动故障的识别率达到 90% 以上, 可用于变压器铁心松动故障的识别和诊断。

**关键词:** 变压器; 铁心松动故障; 声纹信号; 故障诊断; 三维卷积神经网络

中图分类号: TM41 文献标志码: A 文章编号: 1673-6540(2022)10-0046-07

doi: 10.12177/emca.2022.083

## Transformer Iron Core Looseness Fault Diagnosis Model Based on CEEMDAN-Wavelet-Threshold and 3D-CNN\*

CUI Jiajia, MA Hongzhong

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

**Abstract:** In order to solve the identification and diagnosis of transformer iron core looseness fault, a method of removing environmental noise based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN)-wavelet-threshold is proposed, and a method of identifying transformer iron core looseness fault based on voiceprint using three-dimensional convolutional neural network (3D-CNN) is proposed. A transformer iron core looseness fault test platform is built to collect the noise signals of the iron core under different degrees of looseness. The voiceprint signal collected for fault identification is filtered by CEEMDAN-wavelet-threshold algorithm, and the transformer voiceprint signal with high signal-to-noise ratio is obtained by using the difference between transformer body noise and environmental noise in kurtosis. Then, the time-frequency matrix is generated by short-time Fourier transform of the filtered voiceprint signal, the Mel spectrogram is obtained by dimensionality reduction of Mel filter, and the data set suitable for the input format of 3D-CNN is made. Each layer of the network is built, and 3D-CNN is used to classify and identify the transformer iron core looseness fault. The experimental results show that the recognition rate of transformer iron core looseness fault is more than 90% under the condition of considering environmental noise, and can be used for the recognition and diagnosis of transformer iron core looseness fault.

收稿日期: 2022-06-21; 收到修改稿日期: 2022-07-20

\* 基金项目: 国家自然科学基金项目 (51577050); 江苏省电力有限公司重点科技项目 (J2021053)

作者简介: 崔佳嘉 (1998—), 女, 硕士研究生, 研究方向为电力设备状态监测与故障诊断。

马宏忠 (1962—), 男, 博士, 教授, 研究方向为电力设备状态监测与故障诊断。

**Key words:** transformer; iron core looseness fault; voiceprint signal; fault diagnosis; three-dimensional convolutional neural network (3D-CNN)

## 0 引言

变压器是电力系统中最重要电力设备之一,其运行安全影响着整个电力系统<sup>[1]</sup>。基于声纹信号的变压器故障诊断技术是目前的研究热点之一。

目前针对电力变压器的铁心松动故障的诊断方法主要集中在对振动信号的分析上,振动信号的获取是通过将振动传感器附着在器壁上而采集得到的。与变电站普遍采用巡检的方式进行故障诊断相比,基于声纹信号的诊断方法具有非接触性、测量方便及声传感器价格便宜等优势。因此,依据变压器发生铁心松动故障时发出可听声信号(20 Hz~20 kHz),提出采用声纹信号对变压器铁心松动故障进行诊断<sup>[2-5]</sup>。

目前对基于声纹信号的变压器铁心松动故障诊断的研究较少。文献[6]建立了 Mel 时频谱-二维卷积神经网络(2D-CNN)的铁心松动故障识别模型,采用的是 2D-CNN,其识别率较低。文献[7]通过改进 Mel 频率倒谱系数(MFCC),优化声音信号特征提取算法,并通过支持向量机分类算法对特征量进行识别。该文献明确提出只适用于实验室条件下,对处于室外环境含有各种噪声源的大容量变压器并不适用。除此之外,MFCC 是基于人耳对声音的感知确定的,而变压器运行发出的噪声与人声差异是巨大的,因此采用该特征量对故障识别恐有不妥<sup>[8-13]</sup>。国内外的学者对变压器的声纹信号做了很多的研究,但大多未考虑到实际变压器噪声信号的测试结果会受多种环境因素及干扰的影响<sup>[14-15]</sup>,现场采集到变压器运行时的噪声信号不能直接用于故障诊断模型中进行识别,而应将复杂环境中的其他噪声源从信号中滤除,再进行特征提取与识别。目前对于降噪的研究中,普遍采用的是小波分析和经验模态分解(EMD),但这二者具有不适应性及模态混叠等缺陷。而完全自适应噪声集合经验模态分解(CEEMDAN)能够在分解的每个阶段自适应地添加白噪声,分解过程具有完整性且几乎没有重构误差,解决了 EMD 重构不完整的问题。在利用卷积神经网络进行声信号识别时,三维卷积神经网络(3D-CNN)比 2D-CNN 更适合提取时空特征,在网络训练过程中能使用更少的样本、更简单的网络结构,却能得到更好的训练效果。

因此,结合 CEEMDAN 和小波阈值的滤波方法,及 3D-CNN 的特点,本文提出了基于 CEEMDAN-小波阈值及 3D-CNN 的变压器铁心松动故障诊断模型。

## 1 CEEMDAN 及小波阈值的基本原理

### 1.1 CEEMDAN

CEEMDAN 是在 EMD 的基础上,在原信号中加入高斯噪声并通过多次叠加求取平均值的方式抵消噪声的方法。通过自适应地添加高斯白噪声来削弱模态混叠问题,且分解过程具有完整性、几乎无重构性误差的特点。

CEEMDAN 的算法具体描述为<sup>[16]</sup>

(1) 在原始信号的基础上加入高斯白噪声分量  $\varepsilon_0 \omega_k(t)$ ,其中  $\varepsilon_{i-1}$  表示求解  $IMF_i(t)$  时的自适应系数, $K$  为在原始信号上添加白噪声的数量。对分别增加了白噪声的  $K$  个信号进行 EMD 分解,得到各个信号的一阶模态分量  $IMF_1(t)$ ,定义第  $k$  次加入噪声得到的一阶模态分量为  $imf_{k1}(t)$ 。则 CEEMDAN 分解得到的一阶模态分量为

$$IMF_1(t) = \frac{1}{K} \sum_{k=1}^K imf_{k1}(t), k = 1, 2, \dots, K \quad (1)$$

(2) 计算分解出  $IMF_1(t)$  后的第一个余量信号  $r_1(t)$ ,即为

$$r_1(t) = x(t) - IMF_1(t) \quad (2)$$

(3) 在余量信号  $r_1(t)$  的基础上加入噪声分量  $\varepsilon_1 E_1[\omega_{j(t)}]$ , $E_1(\cdot)$  表示经过 EMD 分解产生的第 1 阶模态分量算子。则 CEEMDAN 分解得到的二阶模态分量为

$$IMF_2(t) = \frac{1}{K} \sum_{k=1}^K E_1\{r_1(t) + \varepsilon_1 E_1[\omega_k(t)]\} \quad (3)$$

(4) 重复步骤(2)和步骤(3),就可以计算出第  $i$  个余量信号和第  $i+1$  阶模态分量:

$$r_i(t) = r_{i-1}(t) - IMF_i(t) \quad (4)$$

$$IMF_{i+1}(t) = \frac{1}{K} \sum_{k=1}^K E_1 \{ r_i(t) + \varepsilon_i E_i [\omega_k(t)] \} \quad (5)$$

(5) CEEMDAN 分解的终止条件是求解出的余量信号无法再进行 EMD 分解。若最终分解出  $I$  阶模态分量, 则最终的余量信号  $R(t)$  为

$$R(t) = x(t) - IMF_I(t) \quad (6)$$

### 1.2 小波阈值

在 CEEMDAN 分解后得到的 IMF 分量中, 选择适当的分量进行小波阈值去噪, 再对去噪后的信号重构能进一步降低信号中的噪声成分。其降噪的步骤为<sup>[17]</sup>

(1) 对选择的信号进行小波分解并求取小波系数;

(2) 设置阈值, 高于阈值的系数保留, 低于阈值的系数当作噪声去除;

(3) 使用步骤(2)中处理过的小波系数和近似系数对信号进行重构。

## 2 Mel-语谱图

语谱图是声音信号分析处理的重要特征频率谱图, 能够反映信号在不同时间下的频率能量分布。完整地建立声音信号在时域与频域之间的联系, 实现声音特征信息的最大化, 有助于后期声纹特征的提取与学习。

将采集到的变压器各种工况下的声纹信号, 用上述 CEEMDAN-小波阈值滤波法得到纯净的变压器运行的声音信号。利用滤波后的信号绘制声纹语谱图, 语谱图的绘制包括分帧、加窗和离散傅里叶变换过程。由于变压器噪声较人声更加平稳, 可以适当增加帧长以保证语音信号特征的完整性, 本文中取每帧  $N=1\ 250$  为  $25\text{ ms}$  (采集频率  $f_s=50\text{ kHz}$ ), 为了使帧与帧之间能平滑过渡, 取重叠率为  $50\%$ 。其次, 若是直接对分帧后的数据进行离散傅里叶变换, 会出现频谱泄漏的情况, 因此需要对每一帧先作加窗处理, 本文选择加汉明窗, 使信号两端变得平滑以减少信号的失真。

绘制的语谱图的横坐标表示分帧后的帧数(时间), 纵坐标表示频率, 其中的颜色深浅表示该时刻和频率下的大小, 该大小为功率谱密度。通过短时傅里叶变换生成的语谱图如图 1 所示。

通过上述预处理得到的语谱图可以描述变压

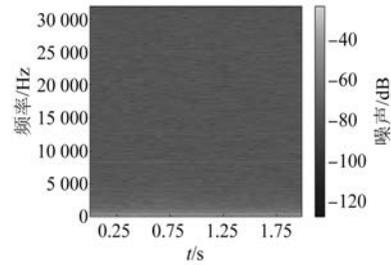


图 1 语谱图

器运行过程中时域与频域之间的关系, 虽然在时间上将维度压缩到 159 列, 但是在频率维度上却有 2 049 行, 对后续卷积神经网络的训练识别速度有很大的影响。因此必须对频率维度进行压缩, 考虑使用 Mel 滤波器对时频矩阵降维。

Mel 滤波器是根据人耳结构特征, 对线性的频段做非线性处理, 将低频部分的权重加大, 对高频部分的权重降低, 突出有效频段的作用。Mel 频率与实际频率的转化关系为<sup>[11]</sup>

$$f_{\text{Mel}}(f) = 2595 \cdot \log\left(1 + \frac{f}{700}\right) \quad (7)$$

式中:  $f_{\text{Mel}}(f)$  为 Mel 刻度下的频率;  $f$  为实际频率。

Mel 滤波器为一个由  $M$  个三角形滤波器组成的滤波器组 (取  $M=40$ ), 中心频率为  $f(m)$ 。在 Mel 频率刻度上, 滤波器之间的距离是等宽的。该滤波器组的传递函数为

$$H_m(k) = \begin{cases} 0, & k < f(m-1) \\ \frac{k-f(m-1)}{f(m)-f(m-1)}, & f(m-1) \leq k \leq f(m) \\ \frac{f(m+1)-k}{f(m+1)-f(m)}, & f(m) < k \leq f(m+1) \\ 0, & k > f(m+1) \end{cases} \quad (8)$$

其中,  $f(m)$  定义为<sup>[7]</sup>

$$f(m) = \left(\frac{N}{f_s}\right) F_{\text{Mel}}^{-1} \left[ F_{\text{Mel}}(f_l) + m \frac{F_{\text{Mel}}(f_h) - F_{\text{Mel}}(f_l)}{M+1} \right] \quad (9)$$

式中:  $f_h$  与  $f_l$  为滤波器滤波频率的上限与下限;  $f_s$  为变压器声纹采样的采样频率 ( $f_s=50\text{ kHz}$ );  $N$  为进行短时傅里叶变化时的帧长。

通过使用 Mel 滤波器对数据进行降维后, 时频矩阵从  $159 \times 2\ 048$  被压缩至  $159 \times 40$ , 大大缩减了数据的尺寸, 方便后续模型训练与识别。由

此生成的 Mel-语谱图如图 2 所示。

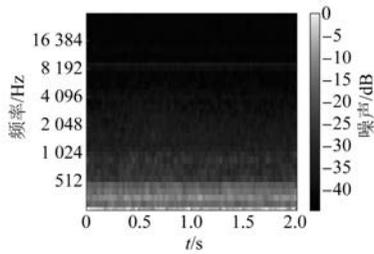


图 2 Mel-语谱图

### 3 三维卷积神经网络

#### 3.1 三维卷积神经网络的原理

传统的 2D-CNN 只能提取二维图像的特征信息,而 3D-CNN 适用于更高维度的图像数据,在处理过程中增加了时间维度的信息(连续帧),神经网络可以同时提取出时间与空间的信息。因此,与二维卷积相比,三维卷积更能捕捉到时序上的特征。3D-CNN 的卷积公式为

$$v_{ij}^{xyz} = f \left[ \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} \sum_{l=0}^{L_i-1} \bar{w}_{ijm}^{pqr} v_{(i-1)m}^{(x+p)(y+q)(z+r)(c+l)} + b_{ij} \right] \quad (10)$$

式中:  $i$  表示神经网络的层数;  $j$  表示样本的序号;  $P_i$  和  $Q_i$  表示二维卷积核的宽度和高度;  $R_i$  表示连续帧的数量(深度);  $L_i$  表示 RGB 图片的 3 个通道;  $m$  为上一层网络的连接特征数;  $f$  为神经元的激活函数;  $v_{ij}^{xyz}$  表示神经元在  $(x, y, z, c)$  处的值;  $\bar{w}_{ijm}^{pqr}$  表示第  $m$  个特征在  $(p, q, r, l)$  的神经元的传递权重;  $b_{ij}$  为第  $i$  层神经网络第  $j$  个样本的偏移量。

#### 3.2 三维卷积神经网络的输入

Mel-语谱图生成的图像的尺寸为  $41 \times 40 \times 3$ , 其中 41 表示时间分量, 40 表示 Mel 标度下的频率分量, 3 表示生成图片的 RGB 3 个通道, 而单张图片只可以作为二维卷积神经网络的输入。由于三维卷积神经网络在二维卷积的基础上增加了时间的维度, 因此在数据集的制作上不同于二维卷积。将采集的 2 s 原始数据分为 4 帧数据, 用上述方法生成 4 张 Mel 语谱图, 并将这 4 张图片堆叠成立体数据如图 3 所示, 其数据尺寸为  $4 \times 41 \times 40 \times 3$ , 4 表示数据深度, 41 表示时间

分量, 40 表示 Mel 标度下的频率分量, 3 表示生成图片的 RGB 3 个通道。将 2 s 的数据样本分成 4 段信号, 每段信号 0.5 s; 按照前文所提方法, 将每段 0.5 s 信号按每帧  $N=1\ 250$  为 25 ms 的长度分帧, 每段信号生成的 Mel 语谱图的尺寸为  $41 \times 40 \times 3$ ; 将 4 段信号分别生成的 Mel 语谱图堆叠后, 数据尺寸为  $41 \times 40 \times 3$ 。

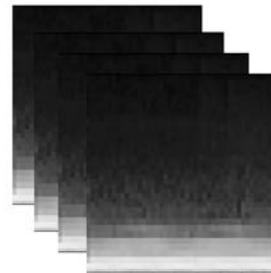


图 3 3D-CNN 输入格式示意图

#### 3.3 三维卷积神经网络的网络结构

本文使用的 3D-CNN 是由 2 层卷积层、2 层池化层及 2 层全连接层组成, 均采用 SAME 补零方式。其中, 卷积层后接有激活层, 激活层选择的是线性整流函数(ReLU)。dropout 是一种非常有效的提高泛化能力、降低过拟合的方法, 因此选择在每一个全连接层后设置 dropout 层, 速率均设置为 0.5。由于本文作 4 分类问题, 将最后一层设置为 4 节点, 用 softmax 函数激活作分类。网络的详细结构如表 1 所示。

表 1 3D-CNN 网络结构

层别	Kernel-size	输出
Conv1	32@ (5, 5, 5, 3)	(60, 4, 40, 41, 32)
maxpool	(1, 4, 4, 1)	(60, 1, 10, 11, 32)
Conv2	64@ (5, 1, 5, 32)	(60, 1, 10, 11, 64)
maxpool	(1, 4, 4, 1)	(60, 1, 3, 3, 64)
flat	-	(60, 576)
dense	(576, 1024)	(60, 1024)
dropout	-	(60, 1024)
dense	(1024, 4)	(60, 4)

### 4 基于 CEEMDAN-小波阈值去噪

对于大容量变压器而言, 由于其位置处于室外, 在声纹信号采集过程中, 不可避免地会受到环境中各种噪声的干扰, 比如鸟鸣、汽笛声、特

殊天气的雷电声,这些噪声会直接影响后续变压器声纹故障诊断的准确性。峭度是信号时域特征中反应随机变量的分布特征,可以用来描述信号概率密度函数的陡峭程度。变压器本体噪声是较为平稳的信号,其峭度值较小,概率密度分布一般呈现高斯分布或亚高斯分布,而其他的噪声是冲击性信号,其峭度值很大,概率分布呈现超高斯分布。利用这一特性能有效地将采集的变压器声纹信号中其他噪声源的含量去除,提高信噪比。

采集一段变压器运行时纯净的信号(不含噪声),其时域和频域信号如图4所示。将其进行CEEMDAN分解后,得到20个本征模态函数(IMF),再计算出各个IMF分量的峭度值,发现各个分量的峭度值在2.6左右。

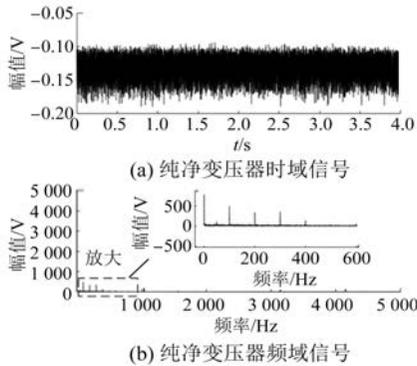


图4 变压器纯净声信号时/频域分布图

再将一段雷声的噪音用加性噪声的处理方法线性叠加在原始信号中。变压器运行时带噪声信号的时域和频域波形如图5所示。

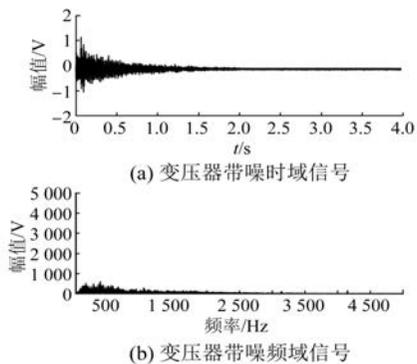


图5 变压器带噪声信号的时/频域分布图

再将带噪声信号进行CEEMDAN分解,共分解出19阶IMF和1个余量,计算各分量的峭度值如

表2所示。

表2 各阶分量的峭度值

模态分量	峭度值	模态分量	峭度值
IMF1	2.71	IMF11	2.77
IMF2	3.06	IMF12	2.52
IMF3	2.88	IMF13	3.65
IMF4	2.68	IMF14	3.13
IMF5	2.03	IMF15	4.08
IMF6	2.01	IMF16	2.80
IMF7	2.02	IMF17	2.86
IMF8	2.47	IMF18	3.34
IMF9	3.21	IMF19	1.76
IMF10	3.03	IMF20	1.83

选择带噪声信号分解的分量中峭度值偏离3较大的分量IMF13、IMF15和IMF18进行小波阈值去噪。最后将经过小波阈值去噪后的分量及未处理的分量一同进行信号的重构,得到去噪后的信号的时域和频域分布,如图6所示。去噪的信号与原始信号在幅值上相差的数量级为 $10^{-6}$ ,信噪比从-15.01升至136.13,去噪效果非常好。

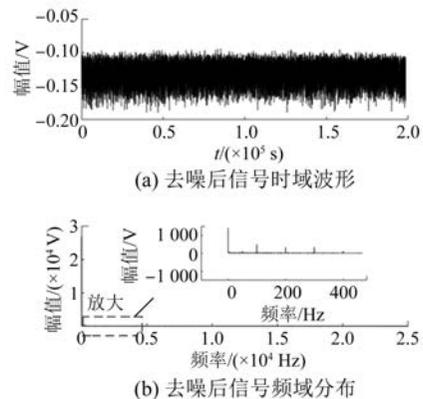


图6 去噪后的声信号的时/频域分布图

## 5 试验分析

### 5.1 数据采集

为了验证3D-CNN对变压器铁心松动故障识别效果,搭建了变压器铁心松动故障试验平台,采集铁心在不同松动程度下的噪声信号。

试验对象为一台S13-M-200/10变压器,根据GB/T 1094.10—2003对该变压器噪声测量的标准和要求,采用电容式麦克风作为声传感器对变

压器铁心不同松动情况下的噪声进行测量,采样频率为 50 kHz,频率响应为 20 Hz~20 kHz。试验在变压器厂厂房中进行,厂房空间较为空旷,几乎不存在声波反射的情况,试验环境如图 7 所示。



图 7 试验环境图

在设置铁心不同松紧程度时,将变压器油抽出后吊芯,铁心的压紧程度是通过改变螺栓的预紧力来确定的,先使用扭力扳手确定被测试的变压器的额定预紧力  $F_N$ ,再分别改变螺栓预紧力使扭力扳手的值分别达到  $F_N$ (未松动)、 $0.6 F_N$ (松动 40%)、 $0.2 F_N$ (松动 80%)、 $0$ (松动 100%)。模拟过程如图 8 所示。在低压侧加 400 V 电压,变压器空载运行,分别采集变压器铁心未松动、松动 40%、松动 80%、松动 100% 时的若干个声纹信号。



图 8 模拟铁心松动故障

分别采集铁心在未松动情况下的样本 82 个,松动 40% 时的样本 129 个,松动 80% 时的样本 129 个,松动 100% 时的样本 140 个。其中,将 80% 的数据作为训练样本,剩余 20% 作为测试样本,验证模型的有效性。

## 5.2 模型的训练参数

设置 3D-CNN 训练的 epoch = 100,批处理量 batch\_size = 60,优化器选择的是 Adam 算法,学习率设置为 0.001,损失函数选择的是传统的交叉熵函数。

## 5.3 模型评价指标

将采集到的数据经过 CEEMDAN 和小波阈

值滤波后,将每一段音频生成 Mel-语谱图,且按照上述方法将每一段语音最终制作成三维的数据块送入模型中训练。用准确率 acc 和损失值 loss 来评判模型的优劣。损失值 loss 表示预测值与实际值的差距,准确率 acc 表示正确分类的数量与总样本之间的比值。损失值越小,准确率越高,说明该模型越适用于变压器铁心松动的故障识别。

## 5.4 三维卷积神经网络训练结果

图 9 所示为 3D-CNN 模型训练过程中准确率 acc 随 epoch 变化的曲线图。从图 9 中可以看出,当 epoch 未达到 60 时,准确率的浮动较大,但是当 epoch 达到 60 次后,准确率稳定在 0.983 333~1,因此模型在训练达到 60 次以后,模型趋于稳定。

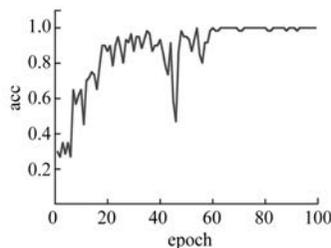


图 9 准确率 acc 随 epoch 变化曲线图

图 10 所示为 3D-CNN 模型训练过程中损失值 loss 随 epoch 变化的曲线图。从图 10 中可以看出 loss 值随着 epoch 的增加整体上呈现出下降的趋势。当 epoch 达到 63 以后,loss 值稳定在 1 以下;当 epoch 达到 85 以后,loss 值稳定在 0.4 以下并趋于稳定。因此,判断该模型已经收敛并完成训练。

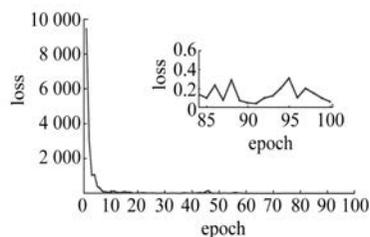


图 10 损失值 loss 随 epoch 变化曲线图

在训练好的模型上对测试集测试,测试结果显示准确率为 0.933 333,综合训练集上的准确率 acc 和损失值 loss 的结果及测试集上的准确率,确

定该 3D-CNN 适用于变压器铁心松动故障的诊断。

## 6 结 语

本文构建了基于 CEEMDAN-小波阈值的环境噪声去除方法和基于声纹的 3D-CNN 的变压器铁心松动故障诊断方法。所提方法考虑到大容量变压器所处的复杂环境噪声的影响,并搭建 3D-CNN 网络对铁心松动故障进行诊断,具体优势体现在:

(1) 能去除信号中含有的复杂环境中其他噪声成分,使得所提出的方法不局限于试验室环境,更适用于实际变电站环境;

(2) 提取声信号中连续帧之间的信息,利用 3D-CNN 网络对变压器铁心松动故障识别,使用最简单的 3D-CNN 结构,就可以达到 90% 以上的识别率。

### 【参 考 文 献】

- [ 1 ] 刘奕呈,李玉梅,张涛,等. 基于 CEEMDAN-CNN 的钻头磨损状态监测研究[J/OL]. 石油机械,2022-03-08. <http://kns.cnki.net/kcms/detail/42.1246.TE.20220304.1103.002.html>.
- [ 2 ] 刘云鹏,罗世豪,王博闻,等. 基于 Mel 时频谱-卷积神经网络的变压器铁芯夹件松动故障声纹模式识别[J]. 华北电力大学学报(自然科学版),2020,47(6): 52.
- [ 3 ] 杨光辉,杨光黎,黎宏锐. 声信号特征融合的变压器故障判断方法[J]. 北京理工大学学报,2022,42(3): 233.
- [ 4 ] 宫成明,厉伟. 基于经验模态分解法的变压器局部放电去噪方法研究[J]. 电气开关,2021,59(6): 68.
- [ 5 ] WANG Q, WANG S, SHI R, et al. A Power transformer fault diagnosis method based on random vector functional-link neural network [ J ]. Mathematical Problems in Engineering,2021(9): 1.
- [ 6 ] 张重远,罗世豪,岳浩天,等. 基于 Mel 时频谱-卷积神经网络的变压器铁芯声纹模式识别方法[J]. 高电压技术,2020,46(2): 413.
- [ 7 ] 王丰华,王邵菁,陈颂,等. 基于改进 MFCC 和 VQ 的变压器声纹识别模型[J]. 中国电机工程学报,2017,37(5): 1535.
- [ 8 ] ZHANG L, ZENG X. Research on transformer fault diagnosis based on genetic algorithm optimized neural network[J]. Journal of Physics: Conference Series, 2021,1848: 012004.
- [ 9 ] 朱文江,余银辉,陈明浩,等. 环境噪声对基于振动特征变压器故障诊断的干扰影响[J]. 变压器,2021,58(11): 35.
- [ 10 ] 司文荣,傅晨钊,徐鹏,等. 基于声学成像及图像处理的变压器铁心松动检测研究[J]. 高压电器,2021,57(11): 180.
- [ 11 ] 刘云鹏,王博闻,周旭东,等. 基于等效源法的变压器瞬态声场重构与声学监测测点位置定量评价方法[J]. 中国电机工程学报,2022,42(7): 2765.
- [ 12 ] 吴国鑫,詹花茂,李敏. 声纹的变压器放电与机械故障诊断研究[J]. 应用声学,2021,40(4): 602.
- [ 13 ] 闫荣格,董正予,焦佩林,等. 基于振动分析的变压器铁心故障诊断[J]. 电工电能新技术,2021,40(1): 55.
- [ 14 ] 侯东,段炼,曹春诚,等. 35 kV 油浸式配电变压器噪声与振动测试[J]. 应用声学,2020,39(6): 964.
- [ 15 ] 刘云鹏,王博闻,岳浩天,等. 基于 50 Hz 倍频倒谱系数与门控循环单元的变压器偏磁声纹识别[J]. 中国电机工程学报,2020,40(14): 4681.
- [ 16 ] 李明,徐壮壮. 基于 CEEMDAN 与 SVD 的滚动轴承故障信号降噪研究[J]. 机械工程师,2022(1): 63.
- [ 17 ] 高淑萍,徐振曦,宋国兵,等. 基于小波阈值去噪和 CEEMD 的混合三端直流输电线路故障测距[J]. 电力系统保护与控制,2022,50(3): 29.