

DOI:10.19651/j.cnki.emt.2106561

# 基于混合特征 MGCC 的干式变压器故障诊断<sup>\*</sup>

狄晓栋 李震梅 李宗哲 王卓 王赛 吴昊

(山东理工大学电气与电子工程学院 淄博 255049)

**摘要:** 针对变压器故障诊断方法中单一参数表征不够全面的问题,提出了一种基于混合特征 MGCC 的干式变压器故障诊断模型。首先,将预处理后的干式变压器噪声信号分别通过 Mel 滤波器和 Gammatone 滤波器得到抗噪性能一般的 MFCC 和鲁棒性更强的 GFCC 特征参数;然后,将两者参数进行线性叠加并利用 Fisher 比舍弃贡献率低的分量,得到混合参数 MGCC;最后送入 LSTM 分类模型进行模式识别。计算结果表明,所提出的混合特征 MGCC 故障诊断率高达 96.11%,相比于单一的声信号倒谱特征参数具有更好的准确性和抗噪性。

**关键词:** 干式变压器; 噪声信号; 故障诊断; Mel 频率倒谱系数; Gammatone 滤波器

中图分类号: TM412 文献标识码: A 国家标准学科分类代码: 470.4017

## Fault diagnosis of dry-type transformer based on combination of MGCC feature parameters

Di Xiaodong Li Zhenmei Li Zongzhe Wang Zhuo Wang Sai Wu Hao

(School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China)

**Abstract:** Aiming at the problem that the single parameter representation in the transformer fault diagnosis method is not comprehensive enough, a dry-type transformer fault diagnosis model based on the mixed characteristics of MGCC is proposed. First, the preprocessed dry-type transformer noise signal passes through the Mel filter and the Gammatone filter to obtain the MFCC with general anti-noise performance and the more robust GFCC characteristic parameters. Then, the two parameters are linearly superimposed and the Fisher is used to compare with discarding the components with lower contribution rate, the mixed parameter MGCC is obtained. Finally, it is sent to the LSTM classification model for pattern recognition. Calculation results show that the fault diagnosis rate of the proposed mixed feature MGCC is as high as 96.11%, which has better accuracy and noise immunity than a single cepstrum feature parameter of the acoustic signal.

**Keywords:** dry-type transformer; noise signal; fault diagnosis; MFCC; Gammatone filter

## 0 引言

电力变压器在电力系统中承担着电压变换、电能传输以及无功补偿等重要任务,正确诊断变压器机械状态对于维护电网安全可靠的运行具有重要意义<sup>[1]</sup>。随着人工智能技术的发展,利用声纹识别对变压器进行监测成为这一研究的热门话题<sup>[2-4]</sup>。目前最为成熟的特征参数有线性预测倒谱系数(LPCC)、梅尔频率倒谱系数(MFCC)以及 Gammatone 滤波器倒谱系数(GFCC)等<sup>[5-7]</sup>。Davis 等<sup>[8]</sup>表示 LPCC 虽然可以较好地描述噪声信号的共振峰特性,但是 LPCC 对辅音描述能力弱,模式识别的准确性和鲁棒性略差;刘云鹏等<sup>[9]</sup>在 MFCC 的基础上提出了一种卷积神经

网络的声纹识别模型,通过对变压器铁芯不同松动模式下的噪声信号进行训练,有效诊断了铁芯夹件松动故障,但是 MFCC 计算过程中的能量泄露问题并未得到解决,而且在复杂噪声环境中的识别性能更差;耿琪深等<sup>[10]</sup>通过提取 Gammatone 滤波器特征参数并送入随机森林模型中进行分类,有效识别了变压器正常、绕组松动、铁芯松动等状态,虽明显改善了 MFCC 信号分解过程中能量泄露问题,但是 Gammatone 滤波器特征维数太多且计算量大,各维分量之间存在冗余。

针对上述问题,本文将抗噪性能一般的 MFCC 和鲁棒性更强的 GFCC 进行线性叠加并利用 Fisher 比降维,形成一种新的混合参数 MGCC,最后采用长短时记忆网络(LSTM)

收稿日期:2021-04-30

\*基金项目:山东省自然科学基金(ZR2019QEE018)项目资助

的分类模型对干式变压器不同机械状态的振动噪声进行模式识别。以一台 10 kV 干式变压器为研究对象,通过模拟干式变压器正常、绕组松动、铁芯松动、过载等不同工况振动噪声并对其进行提取分类。实验表明,利用 LSTM 分类模型对降维后的混合特征参数进行故障诊断具有更好的准确性和抗噪性。

## 1 混合特征参数的提取

MFCC 和 GFCC 是根据人耳复杂的特征结构而提取出的特征参数,因此更符合人耳听觉模型的感知机制,可以挖掘更多声信号中的潜在信息,在电气设备故障诊断中广泛运用。

### 1.1 MFCC 特征提取

由于人耳对不同频率声音信号的敏感程度不同,且成非线性关系,因此将频谱按人耳敏感程度分为多个 Mel 滤波器组,它与频率的关系可表示为<sup>[11]</sup>:

$$Mel(f) = 2.595 \lg(1 + f/700) \quad (1)$$

其中,  $f$  为频率,单位为 Hz;  $l_{Mel}(f)$  为梅尔频率。图 1 所示为 Mel 滤波器的频响曲线,由于干式变压器不同工况的振动噪声频谱大多集中在 2 000 Hz 以内,为了保证 Mel 滤波器组能提取更多完整有用的特征信号,将中心频率的覆盖范围设置为 0~8 000 Hz。

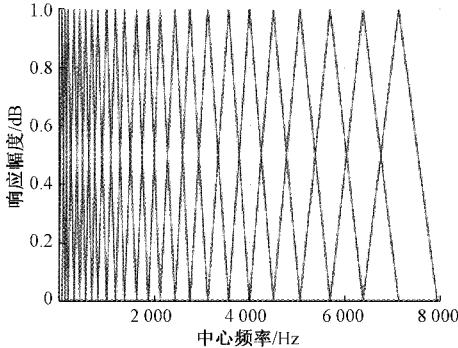


图 1 Mel 滤波器组频响特性曲线

干式变压器梅尔倒谱系数的提取过程如图 2 所示。

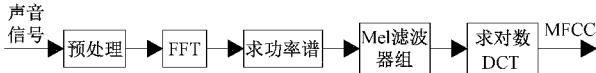


图 2 MFCC 特征参数提取过程

将干式变压器振动噪声经过预加重、分帧、加窗等预处理,再将时域分帧信号  $x(n)$  通过快速傅里叶变换得到线性频谱  $X(k)$ ,转换公式为:

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N}, 0 \leq n, k \leq N-1 \quad (2)$$

将上述线性频谱  $X(k)$  通过  $m$  维的梅尔滤波器,取  $m=24$ 。然后由式(3)求得 Mel 频谱的对数能量。

$$s(m) = \ln \left( \sum_{k=0}^{N-1} |X_a(k)|^2 H_m(k) \right) \quad (3)$$

将上述对数能量谱经过离散余弦变换(DCT)得到 MFCC 系数  $C(n)$ 。

$$C(n) = \sum_{m=0}^{N-1} s(m) \cos \left( \frac{\pi n(m-0.5)}{M} \right), n = 1, 2, \dots, L \quad (4)$$

### 1.2 GFCC 特征提取

Gammatone 滤波器能够很好地模拟人耳基底膜尖锐的滤波特性。其第  $j$  滤波器的表达式为<sup>[12]</sup>:

$$G_j(t) = A t^{a-1} e^{-2\pi b_j t} \cos(2\pi f_j t + \varphi_j), t \geq 0, 1 \leq j \leq N \quad (5)$$

其中,  $A$ 、 $f$  是分别是 Gammatone 滤波器的增益和重心频率;  $\varphi$  是相位;  $a$  是滤波器的阶数;  $N$  为滤波器的个数;  $b_j$  是衰减因子,它与第  $j$  滤波器的带宽有关,其公式为:

$$b_j = 1.019 ERB(f_j) \quad (6)$$

$$ERB(f_j) = 24.7 \left( \frac{4.37 f_j}{1000} + 1 \right) \quad (7)$$

式中:  $ERB(f_j)$  为等效矩形带宽,各滤波器的中心频率在 ERB 尺度上做均等划分,然后映射到线性尺度上。图 3 所示为 5 的整数倍通道的频率响应示意图,它的波峰与 MFCC 相比较为平缓,能够很好地改善梅尔滤波器能量泄露问题。

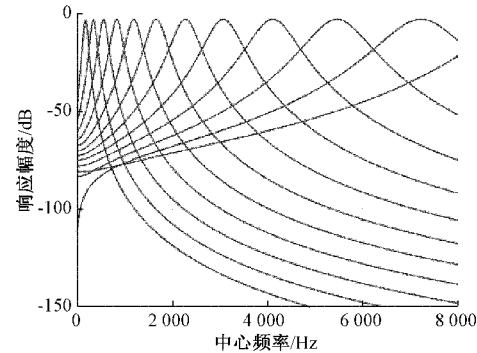


图 3 Gammatone 滤波器组频响特性

### 1.3 Fisher 比降维

由于干式变压器噪声各维系数对分类识别的贡献度不同,有些参数可能包含更多的冗余信息,导致计算复杂度增大,甚至会影响识别性能。因此引入了 Fisher 比。Fisher 比定义为<sup>[13]</sup>:

$$r_{Fisher} = \frac{\sigma_{between}}{\sigma_{within}} \quad (8)$$

其中,  $\sigma_{between}$  为类间离散矩阵,表示不同特征分量之间的均值方差;  $\sigma_{within}$  为类内离散度矩阵,表示同一特征分量不同样本之间的均值方差;  $r_{Fisher}$  即为求得的 Fisher 值,  $r_{Fisher}$  越大代表该维分量对识别性能的贡献度越大。

$$\sigma_{between} = \sum_{i=1}^M (m_k^{(i)} - m_k)^2 \quad (9)$$

$$\sigma_{within} = \sum_{i=1}^M \left[ \frac{1}{n_i} \sum_{c \in n_i} (c_k^{(i)} - m_k^{(i)})^2 \right] \quad (10)$$

其中,  $M$  代表样本总数;  $m_k^{(i)}$  表示第  $i$  类的第  $k$  维分量的均值;  $m_k$  表示所有类别的第  $k$  维分量的均值;  $n_i$  表示第  $i$  类的样本数;  $c_k^{(i)}$  表示第  $i$  类的第  $k$  维特征参数。

图 4 所示为前 12 维 MFCC 系数和前 30 维的 GFCC 系数的 Fisher 比值。由图中可得出, MFCC 系数中第 1、4、5、6、9、12 维特征向量贡献度较大; GFCC 系数中第 9、10、11、12、13、14 维特征向量贡献度较大。因此将贡献度较大的前 6 维 MFCC 和 GFCC 的维数分量进行组合, 得到 12 维的混合特征 MGCC 并将其作为干式变压器机械状态识别模型的特征参数。

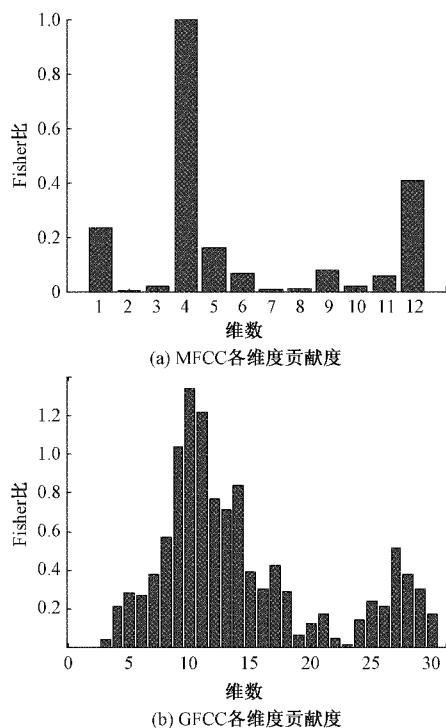


图 4 MFCC 以及 GFCC 各维度贡献度

## 2 长短时记忆神经网络

干式变压器振动噪声与语音信号类似, 是按照时间序列进行特征提取的, 而长短时记忆网络(LSTM)作为一种特殊的循环神经网络(RNN), 不仅避免了 RNN 的长期依赖问题, 而且在处理时间序列上有明显的优势。如图 5 所示, LSTM 在结构上基于门控电路设计, 与传统的 RNN 相比, 增加了输入门、输出门、遗忘门 3 种结构, 这 3 部分控制着长短时信息的流向, 有效地进行信息地筛选与更新<sup>[14 15]</sup>。

遗忘门通过 sigmoid 层控制着信息的保留与更新, 当 sigmoid 值接近 1 时说明大部分数据得到保留, 当 sigmoid 值接近 0 时大部分数据被抛弃。输入门通过 sigmoid 层决定更新多少信息并将前一时刻的状态传递到下一时刻, 而输出门将当前状态与之前的状态进行组合, 通过 sigmoid 层决定了该时刻的输出是多少。

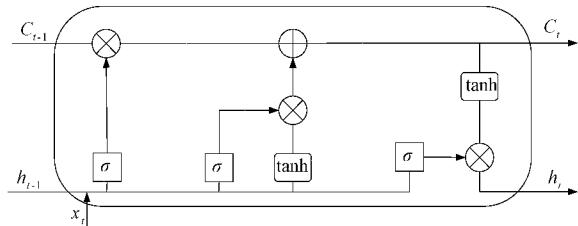


图 5 LSTM 结构

将干式变压器的混合特征 MGCC 参数作为输入, 利用 LSTM 网络提取时间序列信息的优势, 最终完成对干式变压器不同工况的识别分类。

## 3 实验测试

### 3.1 实验描述

以实验室型号为 SCB10-800/10 的一台 10 kV 干式变压器为研究对象, 基于循环电流法分别对干式变压器在正常、绕组松动、铁芯松动、过载等 4 种工况下的声音信号进行模拟测试。

依据 GB/T 1094.101-2008 电力变压器第 10.1 部分声级测定的标准, 如图 6 所示, 将 4 个麦克风传感器布置在距离变压器大概 1 m 的轮廓线上, 相邻传感器之间的距离不超过 1 m, 高度位于变压器整体 1/2 处。实验采用型号为 AWA14423 的电容传声器和型号为 AHAI14620 前置放大器, 敏感度约为 50 mV/Pa, 同时设置变压器振动噪声的采样频率为 51 200 Hz。

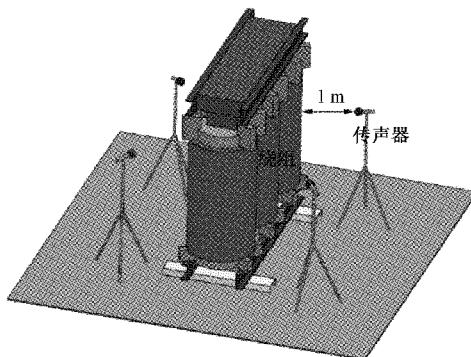


图 6 传声器测点位置图

### 3.2 噪声信号特征提取

本次实验针对变压器 4 种不同工况分别抽取 150 个样本进行训练与测试, 将前 70% 的样本用来训练 LSTM 模型, 后 30% 的样本用来验证模型的准确度。即总的训练集个数为  $105 \times 4 = 420$ , 测试集的个数为  $45 \times 4 = 180$ 。设置振动噪声的帧长为 512, 帧移为 256。图 7~10 分别给出了 MGCC 4 种工况下的特征向量图, 利用 Fisher 比降维后的混合特征维数和帧数分别为 12 和 19, 其前 6 维 MFCC 系数的能量大于后 6 维的 GFCC 系数的能量, 且 MFCC 能量大都集中在 20 dB 左右, 而 GFCC 能量大都集中在 -20~

40 dB之间。为了保证每一维度特征在数值上有可比性,因此在训练分类模型时需对整个样本集进行归一化处理。

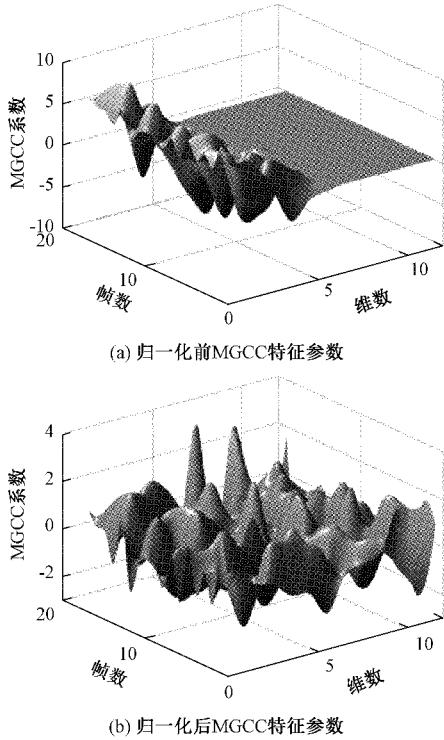


图7 正常工况 MGCC 特征参数

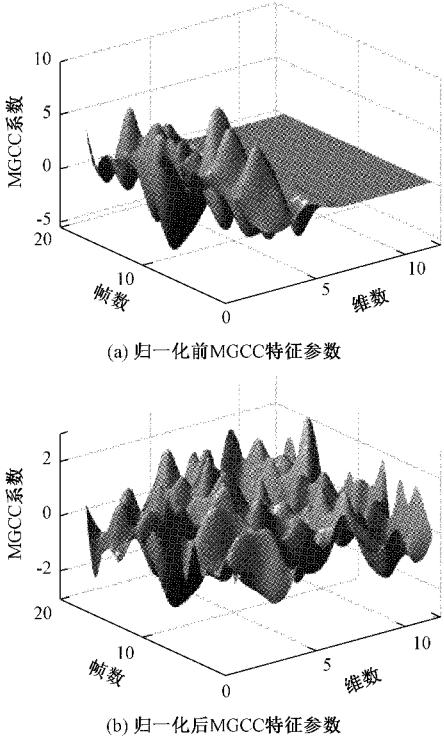


图8 绕组工况 MGCC 特征参数

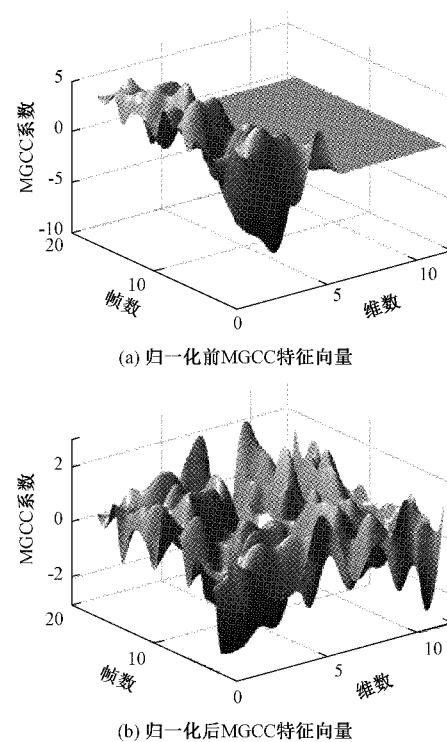


图9 铁芯工况 MGCC 特征向量

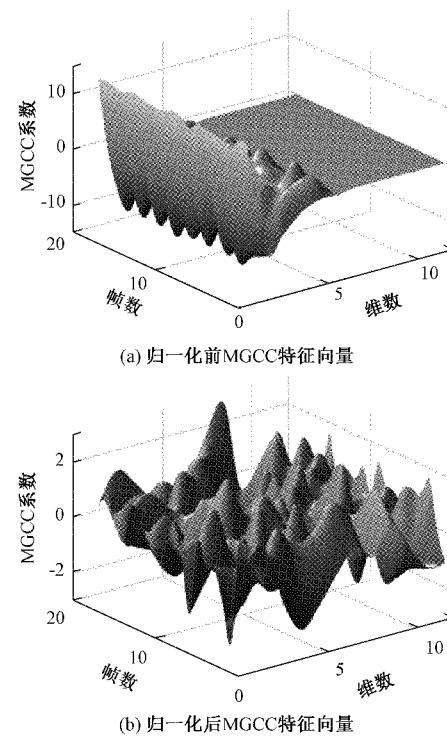


图10 过载工况 MGCC 特征向量

为了不影响样本在特征点处的变化规律,本文选取最大值最小值归一化的方法,计算公式为:

$$x_i^* = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (11)$$

其中,  $\max(x_i)$  和  $\min(x_i)$  分别为第  $i$  个样本数据的最大值和最小值;  $x_i^*$  为第  $i$  个样本数据归一化之后的结果。

### 3.3 长短时记忆网络参数优化

在对 LSTM 分类模型的设置中,采用 LSTM 单层网络结构,后面连接全连接层和 softmax 层,全连接层参数设为 4,即变压器故障诊断类型有 4 种,softmax 层将故障诊断结果以概率形式输出。由表 1 可知,当隐含神经元个数为 26 时,损失函数不再下降,则取神经元个数为 26。

表 1 不同神经元对识别结果的影响 %

神经元	10	15	20	25	26
准确率	88.89	90.56	94.44	95.56	96.11

另外为了加速学习,使用动量的随机梯度下降 sgdm 优化算法,学习率设为 0.001,图 11 所示为不同迭代次数对应的网络误差,由图 11 可知,网络误差随着迭代次数的增加而降低,当迭代次数到达 168 时,趋势近于平缓,训练过程达到收敛。

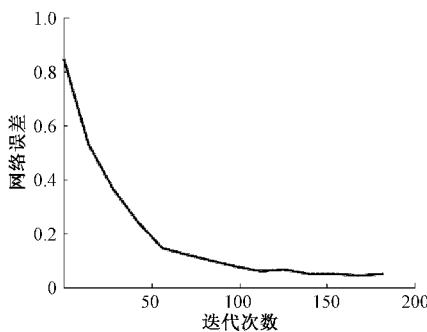


图 11 LSTM 神经网络训练过程

### 3.4 干式变压器状态识别

图 12 为 LSTM 分类模型对干式变压器 4 种工况进行训练之后得到的混淆矩阵图,数字 1、2、3、4 分别代表了干式变压器正常、绕组松动、铁芯松动、过载等机械状态,每一列之和代表了该工况真实的样本数量,每一行之和代表了被预测为该工况的样本数量,第 1 行则说明了有 42 个属于正常工况的样本被正确诊断,而有 3 个铁芯松动样本被误诊为正常工况。由图 12 可以看出,干式变压器 4 种工况的整体准确度达到了 96.1%,180 例测试样本中误诊的样本个数一共为 7 个,其中有 4 例铁芯松动样本被误诊为其他机械状态,而所有的绕组松动样本以及过载样本被完全识别。

为了进一步验证 MGCC 的抗噪性,在原始信号中添加不同信噪比的高斯白噪声,并与传统的 MFCC 和 GFCC 做对比,由图 13 可得,在高信噪比下 MFCC 特征参数识别率高于 GFCC;随着信噪比的减小,MFCC 的识别率下降较快,抗噪性较差,GFCC 的识别率下降较慢,抗噪性较好。而混合参数 MGCC 的准确度及抗噪性均高于 MFCC 和 GFCC。

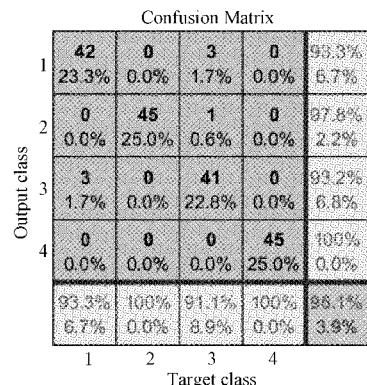


图 12 4 种工况下分类模型的混淆矩阵图

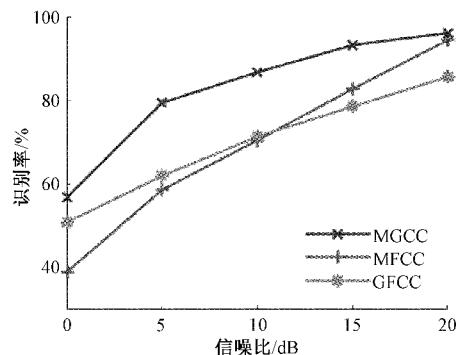


图 13 不同信噪比下的识别率

此外,为了说明 LSTM 分类模型对不同工况下的干式变压器模式识别具有明显的优势,分别应用 LSTM 模型、卷积神经网络模型以及自编码器模型对振动噪声进行了测试,得到了 3 种模型的干式变压器故障诊断识别率。由表 2 可知,3 种模型的准确率虽都达到了 85% 以上,但是 LSTM 模型的诊断率稍高于其他两个,由此证明了采用 LSTM 神经网络结果更为理想。

表 2 不同分类模型对识别结果的影响 %

	LSTM	CNN	自编码器
正常工况	93.3	88.9	75.0
绕组工况	100	88.9	95.3
铁芯工况	91.1	91.1	77.5
过载工况	100	100	100
总体准确率	96.11	92.22	86.70

## 4 结 论

本文提出了一种基于混合特征 MGCC 的变压器故障诊断模型,并对一台 10 kV 干式变压器不同机械状态进行识别。结果表明:1) 干式变压器正常、绕组松动、铁芯松动以及过载等 4 种工况的识别准确度普遍超过了 90%,充分验证了该诊断模型的有效性。2) 对比传统的 MFCC 和

GFCC 特征参数可知, MGCC 参数在加入不同信噪比的白噪声后仍具有良好的准确性和抗噪性。3) LSTM 模型可以提取出变压器噪声时间序列上的状态信息, 它结合 MGCC 特征参数对变压器机械状态的平均识别率达到 96.11%, 相比于传统的卷积神经网络和自编码器具有显著优势。

### 参考文献

- [1] 殷作洋, 吴肖峰, 仲伟坤, 等. 基于随机森林的变压器故障识别与实例分析[J]. 电子测量技术, 2020, 43(23): 63-67.
- [2] 朱叶叶, 汲胜昌, 张凡, 等. 电力变压器振动产生机理及影响因素研究[J]. 西安交通大学学报, 2015, 49(6): 115-125.
- [3] 舒畅, 金潇, 李自品. 基于 CEEMDAN 的配电变压器放电故障噪声诊断方法[J]. 高电压技术, 2018, 44(8): 2603-2611.
- [4] 于长厅, 黎大健, 汲胜昌, 等. 基于振动噪声及 BP 神经网络的变压器故障诊断方法研究[J]. 高压电器, 2020, 56(6): 256-261.
- [5] 孙国强, 樊新海, 石文雷. 基于 MFCC 和支持向量机的装甲车辆识别研究[J]. 国外电子测量技术, 2017, 36(10): 31-35.
- [6] 李虹, 徐小力, 吴国新, 等. 基于 MFCC 的语音情感特征提取研究[J]. 电子测量与仪器学报, 2017, 31(3): 448-453.
- [7] 刘云鹏, 王博闻, 岳浩天, 等. 基于 50Hz 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): 4681-4694, 4746.
- [8] DAVIS S, MERMELSTEIN P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences[J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1980, 28(4): 357-366.
- [9] 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): 52-60, 67.
- [10] 耿琪深, 王丰华, 金霄. 基于 Gammatone 滤波器倒谱系数与鲸鱼算法优化随机森林的干式变压器机械故障声音诊断[J]. 电力自动化设备, 2020, 40(8): 191-196, 224.
- [11] 徐明月, 李喆, 孙汉文, 等. 基于改进梅尔倒谱系数的 GIS 机械故障诊断方法[J]. 高压电器, 2020, 56(9): 122-128.
- [12] 周萍, 沈昊, 郑凯鹏. 基于 MFCC 与 GFCC 混合特征参数的说话人识别[J]. 应用科学学报, 2019, 37(1): 24-32.
- [13] 王玉, 申铉京, 陈海鹏. 基于改进的 Fisher 准则的多示例学习视频人脸识别算法[J]. 自动化学报, 2018, 44(12): 2179-2187.
- [14] 丁洋, 何明, 刘博, 等. 基于 TL-LSTM 的轴承故障声发射信号识别研究[J]. 仪器仪表学报, 2019, 40(5): 51-59.
- [15] 吴晓欣, 何怡刚, 段嘉珺, 等. 考虑复杂时序关联特性的 Bi-LSTM 变压器 DGA 故障诊断方法[J]. 电力自动化设备, 2020, 40(8): 184-193.

### 作者简介

**狄晓栋**, 硕士研究生, 主要研究方向为电气设备故障诊断。

E-mail: 18730217338@163.com

**李震梅**, 教授, 主要研究方向为电工电子学与测控技术。

E-mail: 2665151843@qq.com