基于多特征提取分析的变压器声纹故障识别技术研究

侯文彪[1],徐　宁[2]

(1.中国电建集团华东勘测设计研究院有限公司,浙江 杭州 310000;2.中国电建新能源集团股份有限公司华东分公司,浙江 杭州 310000)

摘　要:变压器是变电站高电压远距离输电系统中的重要设备,也是电力设备故障识别与诊断的重点。文中从声纹分析角度探讨变压器故障识别系统,介绍系统组成,重点分析变压器噪声分离模块、声纹特征提取模块以及基于LSTM的声纹识别模块。与传统的人工听声定障法相比,基于人工智能技术的电力设备声纹的故障诊断方法为电力设备的故障诊断提出了一种新思路、新方向,且与传统的以电气测试为代表的断电检测相比,因其具有不断电、实时性的优越性能,极大地提高了故障检测的便利性与时效性,为电力系统的安全运行提供了强力支撑,确保变压器的安全可靠运行。实验结果表明,文中所提出方法不仅大幅度提升了变压器故障识别的准确率与鲁棒性,还因其非断电、实时性的效能,大大提高了电力系统故障检测的安全性、可靠性与工作效率。

关键词:变压器声纹故障识别;噪声分离;特性提取;LSTM神经网络

中图分类号:TM 41　　**文献标志码**:B　　**文章编号**:1006-348X(2025)01-0070-05

0　引言

变压器是电力系统中高电压远距离输电系统中的关键设备,负责电能传输与分配、不同电压等级的转换以及电压稳定的维持等重要功能,同时也是变电站内主要噪声源之一。变压器的铁芯和绕组等机械结构在运行过程中的振动会产生声信号,这些声信号包含的信息与变压器的工作运行状态高度相关,而其异常声音现象通常与变压器的故障密切相关。因此,近年来,变压器故障的声纹识别因其非接触、不断电的检测方式,具有故障信号易于获取、不影响电力变压器正常工作、信号采集便捷等显著优势,成为学者研究关注的焦点[1]。开展变压器声纹检测与故障诊断对保障其安全运行具有重要意义。

电力设备的声学状态监测往往存在大量的干扰信号,无法快速、高效地得到纯净的设备声信号,监测变压器声信号时也易受周围环境噪声、电晕放电、鸟鸣声等干扰噪声的影响,干扰声音与目标变压器声信号叠加后经过折射、反射等过程,导致采集到的信号信噪比很低。在高噪声环境中,声纹识别的准确率会大幅下降,使得声学状态监测系统频繁出现误判。因此,提升声纹监测系统的抗噪性能至关重要,关键在于结合干扰声音的特征,采用相应的噪声分离方法,以提高声纹识别系统的准确性和鲁棒性。

1　基于声纹的故障识别系统

1.1　系统组成

基于声纹的变压器故障识别系统主要由变压器噪声分离模块、声纹特征提取模块以及基于LSTM的声纹识别模块组成。主要流程图如图1所示。

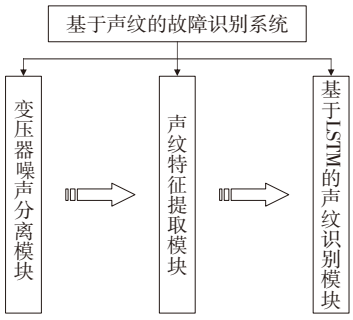

图1　基于声纹的故障识别系统

1.2　各模块功能介绍

1)变压器噪声分离模块:其主要作用是降低环

收稿日期:2024-10-15

作者简介:侯文彪(1990),男,大学本科,工程师,专业方向为电气工程及其自动化。

境噪声对于目标变压器的干扰，以提高故障识别的准确率。常用方法有：主成分分析法、独立成分分析法、稀疏分量分析法等。

2）声纹特征提取模块：将变压器声信号中蕴含着的丰富的信息编码为计算机识别的矩阵形式，是实现故障识别的基础与关键。现有的声信号特征向量主要为线性倒谱系数（linear prediction cepstrum coefficient，LPCC）、巴克频谱系数（bark-frequency cepstral coefficents，BFCC）、梅尔频率倒谱系数（mel frequency cepstrum coefficient，MFCC）等，其中MFCC是目前最常用、最普遍的用于声纹识别的特征向量，具有识别率高、鲁棒性强、适用性强等优点[2]。然而，MFCC特征参数是根据人耳对声音的感知特性设计的，而变压器噪声的机理与人声有很大差异。直接将MFCC应用于变压器噪声识别的效果有限，需要进一步研究以优化其应用效果[3-4]。此外，还可以考虑多维度的变压器声纹特征量的提取，比如奇偶次谐波比、高频能量比重、频谱复杂度以及小波包能量等。

3）基于LSTM的声纹识别模块：在分析音频数据时，必须遵循其时序性，进行有效处理。相比于传统的机器学习算法，如贝叶斯网络、矢量量化模型和高斯混合模型等，RNN（循环神经网络）因其能够捕获时间维度信息的特性，可以更好地建模序列数据的时间依赖性，因此在语音识别领域发挥了重要作用。RNN对于样本数据的特征学习的能力较强，具有高级特征学习的能力。

LSTM（长短期循环神经网络）被认为是RNN的变体，通常用于解决时间序列问题。LSTM通过精心设计的门控结构，克服了简单循环网络的缺陷，对序列建模效果优秀，是广泛使用的序列模型。

2　声纹特征提取模块及其声纹特征分析

2.1　声纹特征提取模块——Mel时频谱特征提取

变压器声音来源主要包括四个方面：磁致伸缩、绕组漏磁、铁心漏磁、外部组部件（如冷却风扇）的振动。根据声音来源的位置不同，可以将变压器发出的声音分为两类：一是由变压器本体振动产生的声音，另一是由安装在变压器本体上的冷却器、端子箱和储油柜等组件振动而产生的声音。

时频谱图主要用于展示信号在不同时间点上的频率能量分布。处理声音时频谱图时，通过应用Mel滤波技术，可以将其转换为Mel时频谱，这种方法有助于对声音特征进行降维处理，并提取出变压器故障声音的关键特征。

其意义主要有两方面：一方面，Mel时频谱具有降低干扰频段权重的作用，且能够将人耳对频率感知能力进行线性化处理；另一方面，Mel时频谱不仅能够对声纹特征做出保留，同时可以缩小样本尺寸[5]，提高识别速率，使模型训练更高效。而MFCC相较于梅尔时频谱，其以更少的数据维度描述了时频谱的信息，MFCC特征向量维度一般为39，而Mel特征向量一般为80，且MFCC的特征向量之间相关性更低，具有更好的区分度，并且能够提取出基频及共振峰的信息。然而，与梅尔时频谱图相比，它仍然存在以下缺点：计算复杂度较高，对于加性噪声的适应能力不足，需要进一步改进和创新。

1）变压器本体噪声声音特征

图2展示了变压器在正常运行状态下产生的时域波形振幅随时间变化的图谱。通过对图2数据的分析可知，在2.53 s时出现峰值，可判断此时的能量强度最大，能量波动较大，可判断此时发生了较为明显的机械摩擦，初步可断定为发生故障。但该方法因不能够直观反映出各时域中不明显的能量异常现象与杂音发生的具体位置，因此，需要借助更为精准的检测方法进行深入的故障分析。

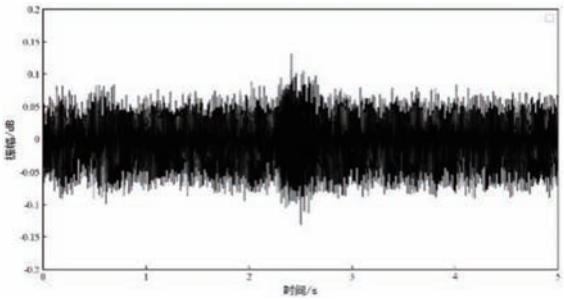

图2　变压器本体声音时域曲线

运用傅里叶变换后得到的频域谱线图如图3所示。

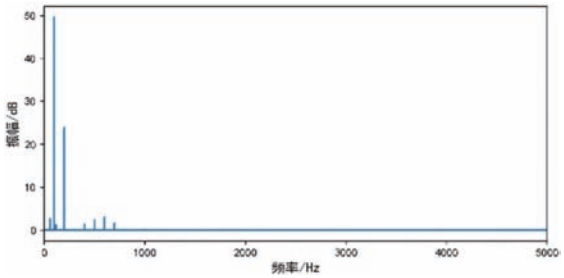

图3　变压器本体声音频域谱线

预加重后得到的频谱图如图4所示。

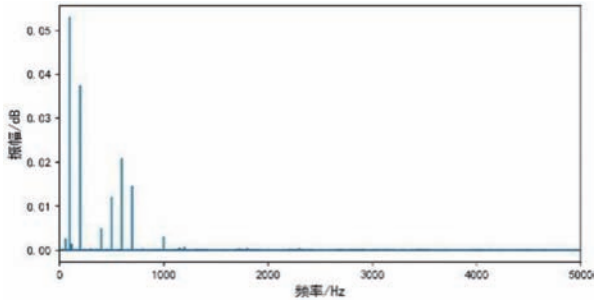

图4　预加重后的频域谱线

对音频信号进行Mel滤波，并将其转化为MFCC倒谱，如图5所示。

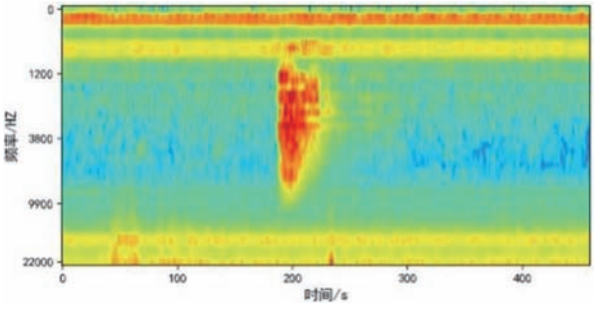

图5　正常音频MFCC倒谱图

2）变压器故障声音特征

选取变压器发生短路冲击故障时的音频信号为例，其时域图、频域图、预加重后频域图、时频谱图分别如图6—8所示。

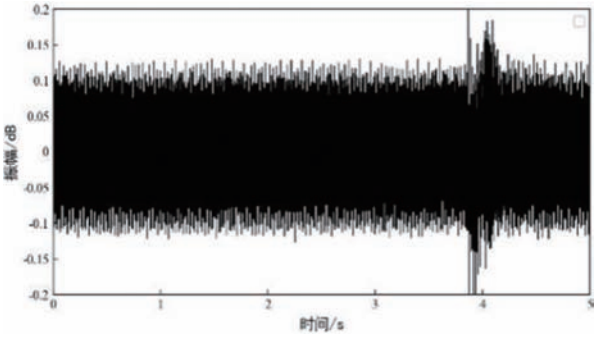

图6　故障音频时域图

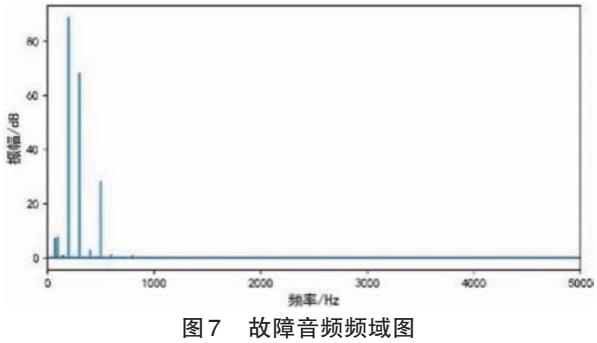

图7　故障音频频域图

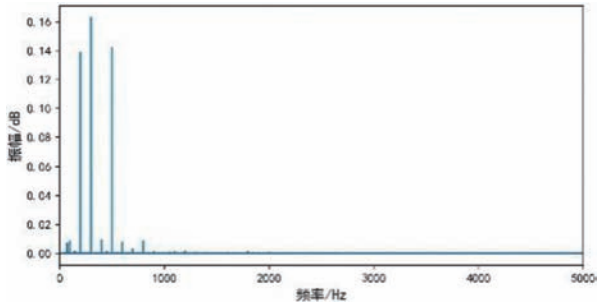

图8　预加重后故障音频频域图

由图9易知，在3.5~4 s之间峰值显著增加，即发生了较为明显的短路冲击故障。

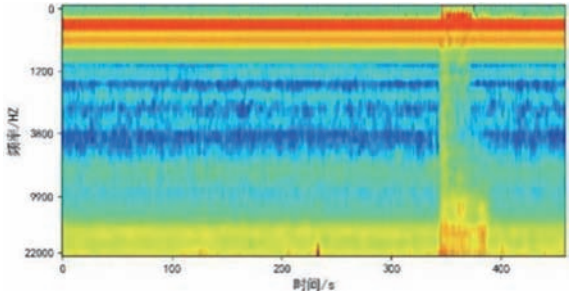

图9　故障音频MFCC倒谱图

3　变压器声纹去噪技术

变电站内存在大量的干扰信号，对变电站内声音进行采集与对比分析，发现非稳定、瞬时性干扰信号占绝大部分，这类干扰信号的特征是持续时间短促、能量分布集中，频带较窄，随机性强，且不同干扰声音之间的特性差异极大；而变压器本体信号为持续性稳定信号，频率分布较为规律性，因此，考虑使用盲源分离方法把变压器本体的故障信号与干扰信号进行分离。

欠定盲源分离是一种在无源信号以及混叠系数等先验知识的情况下，当观测信道数少于源信号个数时，仅通过观测信号恢复源信号的技术。因其性能的优越与技术的先进，近年来成为国内外众多学者的研究热点之一。FastICA算法作为一种解决盲源分离问题常见的算法，在非欠定工况下有着良好的分离精度，但在实际工况中，噪声源的种类一般具有随机性且较为复杂（可多达数十种），噪声传感器的数量往往为欠定情况[6-7]。FastICA算法通常无法直接处理这种“病态”的欠定盲源分离场景。因此，如何对变压器含噪声信号进行升维处理，以

使得在变压器声纹的盲源分离中满足FastICA算法的混合过程可逆性约束和分离信号唯一性约束条件等，成为了解决变压器声纹欠定盲源分离的关键问题[8]。

针对上述问题，结合经验模态分解算法的基础，提出一种基于集合经验模态分解（ensemble empirical mode decomposition，EEMD）改进的FastICA算法，本方法目的在于有效解决信道估计问题和欠定问题，将声纹信号由欠定状态升维为非欠定状态，进而利用FastICA算法以实现变压器本体信号与干扰信号的欠定盲源分离。

EMD算法因其出色的时频分辨率和能够处理含噪声信号的能力，在电力设备噪声抑制和信号分离领域得到了广泛应用。

然而，传统的EMD算法存在显著缺陷：它极度依赖信号的极值点分布，容易导致模态混叠、时频尺度的局部丢失和端点效应等问题，这些限制了对源信号特征的准确恢复。尤其是在处理变压器声信号时，由于其频率分布的不连续性和易受到噪声信号影响的特点，传统EMD算法常难以有效分离出源信号和噪声信号，导致提取的信号包络既保留了源信号的特征，也不可避免地保留了噪声信号的部分特征，造成不同频率特征的信号相互混叠，增加了干扰的复杂性。

EEMD算法作为对EMD算法的一种改进，通过在EMD分解之前对待分离信号进行多次加入等幅值、频率均匀分布的高斯白噪声，以改变输入原始信号的极值点特性，使得含噪信号中不同尺度的信号分布在与之相匹配的参考尺度之上，并且由于高斯白噪声具有零均值的特性，可在对多次本征IMF分量取平均后，将噪声相互抵消，从而抑制模态混叠现象[9]。

变压器运行产生的声音主要由铁芯振动、油箱、冷却装置噪声、紧固件动作、螺丝松动 等混合而成，在这些声音传播过程中，难免会与两侧防火墙发生折射、反射等[10]，而高噪声环境会对故障检测产生较大影响。以输入的110 kV变压器正常运行音频为例，图10为原始音频，图11为基于EEMD改进ICA算法重构后的有效声纹信号，可以看出，实现了“去噪、盲源分离”的目的。

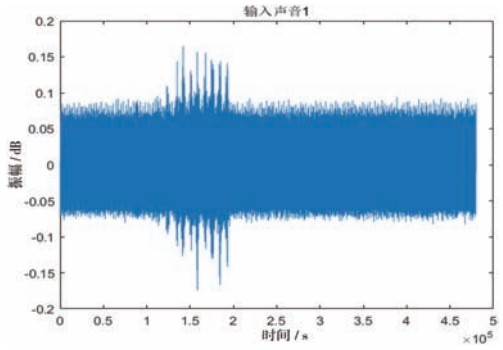

图10　输入音频信号

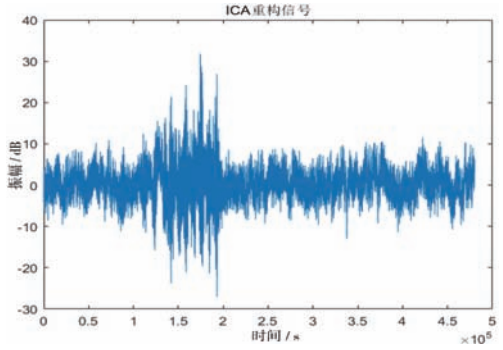

图11　ICA重构信号

4　基于LSTM的声纹识别系统

人工神经网络是一种高度非线性的计算模型，由大量相互连接的节点构成，每个节点代表一个特定的激活函数，通过权值连接来模拟复杂的逻辑运算。这种网络结构类似于人脑神经元之间的连接，用于执行复杂的信息处理任务。在人工感知领域，人工神经网络通过数理统计方法提出与感知决策相关的问题解决方案，其局部结构空间比传统逻辑推理更具优势[5]。

近年来，随着电力系统行业对智能化、可视化和专业化的要求，依托电网大数据和专业处理硬件及软件，深度学习等智能算法在电网中得到了广泛的应用，展现出了独特的优越性和不可替代的作用[10]。针对复杂数据类型的研究，传统的浅层神经网络在学习复杂数据方面受到限制，难以获得理想的效果[11]。深度神经网络则是在人工神经网络基础上发展而来[12]，递归神经网络（RNN）是一种深度学习架构，专注于从输入数据中提炼复杂特征，尤其适合处理序列数据。它能捕捉输入数据中的时间相关性。然而，处理长时间序列时，RNN的效果可能不佳。为了解决这个问题，长短期记忆网络（LSTM）应运而生。LSTM是一种改进的RNN变体，采用独特的门控机制，能够更好地捕捉和存储长时间跨度的信息。因此，

LSTM在处理时间序列数据、如文本和语音时，表现得尤为出色，能够有效应对序列中的长期依赖关系。

鉴于长短期记忆神经网络（LSTM）在处理时间序列数据方面的显著优势，提出了一种创新的变压器故障声纹识别方法，利用LSTM神经网络的强大特性，通过LSTM网络精确捕捉和分析变压器故障声纹中的时间依赖特征，成功地实现了对故障声纹的高精度识别，从而大幅提升了变压器故障诊断的准确性和效率。首先，对变压器运行时采集到的音频信号进行去噪处理。经过去噪处理后，将获得的多个语音片段转换成相应的语谱图，采用MFCC频谱降维技术提取声音特征，并对其进行标准化处理，以便输入到模型中。在模型训练阶段，利用LSTM神经网络进行深度学习和特征优化。最终，根据LSTM神经网络模型输出的结果，对变压器故障进行全面分析和判断。

将LSTM神经网络模型进行40次迭代，模型损失曲线如图12所示。

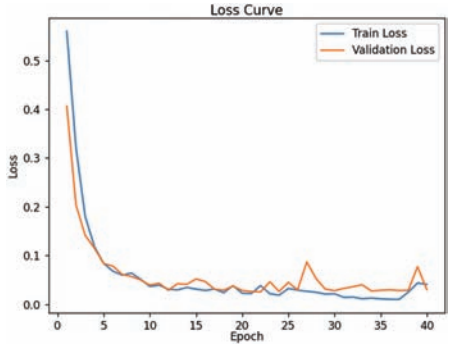

图12　模型损失曲线

图12中，横轴为训练轮次，纵轴为损失值。根据所示的训练损失train loss和验证损失validation loss曲线分析，最初阶段它们均呈现持续下降的趋势（表明学习率适中且梯度下降有效），随后逐渐趋于平稳（即收敛）。这表明当前模型在所用数据集上具备良好的拟合能力和出色的预测效果，各项评估指标也显示出较为优秀的表现。 模型迭代40次时，故障识别的准确率高达98.651%，精确率达到98.667%，召回率为98.651%，F1值为98.654%，可见本模型的识别效果优良。

5　结语

文中对基于声纹的变压器故障识别系统进行了深入的研究，分别阐述了变压器噪声分离模块、声纹特征提取模块以及基于LSTM的声纹识别模块等的工作机理与性能分析。将采集到的变压器声纹信号进行噪声分离后转换为MFCC倒频谱图，并进行降维处理；搭建了基于LSTM神经网络的变压器故障的声纹模式识别模型，采用LSTM神经网络对MFCC倒谱图的MFCC特征向量进行训练与识别，以电力系统故障运行数据为基础，通过数字化与智能化手段实现对变压器故障的识别与监测。实验结果表明，文中所提出方法不仅大幅度提升了变压器故障识别的准确率与鲁棒性，还因其非断电、实时性的效能，大大提高了电力系统故障检测的安全性、可靠性与工作效率，为建设智能电网提供了数字化的技术支撑。

参考文献：

[1] 崔佳嘉，马宏忠．基于改进MFCC和3D-CNN的变压器铁心松动故障声纹识别模型[J]．电机与控制学报，2022，26（12）：51-57.

[2] 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）：1535-1543.

[3] 李敏．高噪声环境下变压器故障声纹识别方法研究[D]．北京：华北电力大学，2022.

[4] 符劲松．基于可听声的变压器内部火花放电故障诊断研究[D]．武汉：华中科技大学，2013.

[5] 曹力潭，魏华兵，黄智，等．基于LSTM神经网络的电抗器故障声纹识别方法[J]．浙江电力，2023，42（4）：114-120.

[6] 李宁，田冬梅，单大鹏，等．城市变电站噪声分析及降噪措施探讨[J]．高压电器，2015，51（1）：139-144.

[7] 王川川，汪亚，朱宁，等．基于构建虚拟多通道的欠定盲源分离方法研究[J]．兵工自动化，2023，42（4）：60-65.

[8] 律方成，潘亦睿，郭佳熠，等．基于欠定盲源分离理论与深度学习的声音样本集获取与分类方法[J]．华北电力大学学报（自然科学版），2020，47（4）：1-9.

[9] 韩烨宸，贺兴，艾芊．基于GRU-EEMD算法的非侵入式配电网功率欠定盲源分离[J]．电力系统自动化，2023，47（14）：64-71.

[10] 王果，雷武，闵永智，等．改进EEMD算法在高压并联电抗器声信号去噪中的应用[J]．电力系统保护与控制，2023，51（24）：164-174.

[11] 潘亦睿．盲源分离和深度学习相结合的并联电抗器噪声分离识别技术研究[D]．北京：华北电力大学，2021.

[12] 吴懿范．基于盲源分离与深度神经网络的1 000 MW火电机组低频振动故障诊断研究[D]．杭州：浙江大学，2023.