

DOI: 10.19650/j.cnki.cjsi.J2514179

# 融合宽带超声与深度学习的变压器油微水 非侵入式检测方法\*

章兆宇<sup>1</sup>, 孔洒洒<sup>1</sup>, 朱 凯<sup>2</sup>, 姚 远<sup>2</sup>, 梁 晟<sup>2</sup>

(1. 湖北工业大学太阳能高效利用及储能运行控制湖北省重点实验室 武汉 430068;

2. 国网上海市电力公司青浦供电公司 上海 201700)

**摘 要:**针对传统变压器油中微量水分含量检测方法存在的破坏性取样、抗干扰能力弱等瓶颈问题,提出了一种基于宽带超声时频分析与深度学习融合的非侵入式高精度检测技术。该方法结合宽带多频超声扫描与深度神经网络建模,实现了油中微量水分复杂声学特征的动态解析与定量预测。研究采集 240 组变压器油样,利用精密微水检测仪标定其真实含水量构建数据集(训练集 220 组、测试集 20 组)。对每组油样施加 6 种中心频率的宽带超声激励,采集回波信号并采用连续小波变换(CWT)进行时频分析,提取形成 128×1 000 维的高/低频联合特征矩阵作为模型输入,对应油样真实含水量作为输出。核心创新在于构建了卷积神经网络-长短期记忆网络(CNN-LSTM)混合深度学习模型:利用 CNN 高效提取 CWT 时频谱图蕴含的空间模式特征,同时利用 LSTM 捕捉超声信号在多频率维度上的时序动态关联,从而建立从复杂声学特征到水分含量的强非线性映射。多模型对比实验表明,该 CNN-LSTM 模型预测性能显著优越,平均绝对误差(MAE)低至 1.33 mg/kg,平均绝对百分比误差(MAPE)为 7.167%,且决定系数( $R^2$ )高达 0.958。该研究为变压器油中微量水分的在线、无损、高精度监测提供了具有重要工程应用价值的新方案。

**关键词:**变压器油;微水检测;宽带超声;时频分析;深度学习

**中图分类号:** TH70 **文献标识码:** A **国家标准学科分类代码:** 470.4017

## Integrated broadband ultrasound and deep learning technique for non-invasive trace moisture detection in transformer oil

Qin Zhaoyu<sup>1</sup>, Kong Sasa<sup>1</sup>, Zhu Kai<sup>2</sup>, Yao Yuan<sup>2</sup>, Liang Sheng<sup>2</sup>

(1. Hubei Collaborative Innovation Center for High-efficiency Utilization of Solar Energy, Hubei University of Technology, Wuhan 430068, China; 2. State Grid Shanghai Municipal Electric Power Company QingPu Power Supply Company, Shanghai 201700, China)

**Abstract:** To address the critical limitations of conventional methods for detecting trace moisture content in transformer oil—such as destructive sampling and poor anti-interference capability—this study proposes a non-invasive, high-precision detection technique based on the integration of broadband ultrasonic time-frequency analysis and deep learning. The approach combines broadband multi-frequency ultrasonic scanning with deep neural network modeling to dynamically characterize and quantitatively predict complex acoustic signatures associated with trace moisture in oil. A dataset comprising 240 transformer oil samples was established, with ground-truth moisture content calibrated using a precision trace moisture detector (220 samples for training, 20 for testing). Each sample was subjected to broadband ultrasonic excitation at six distinct center frequencies. Echo signals were processed via Continuous Wavelet Transform (CWT) for time-frequency analysis, extracting a 128×1 000-dimensional joint high/low-frequency feature matrix as model input, with actual moisture content as output. The core innovation lies in constructing a hybrid Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM) deep learning model: The CNN branch efficiently extracts spatial patterns from the CWT time-frequency spectrograms, while the LSTM branch captures temporal dynamics and cross-frequency dependencies within ultrasonic features. This synergy establishes a robust nonlinear mapping between complex acoustic characteristics and moisture content. Comparative experiments with multiple models demonstrate the superior performance of the CNN-LSTM framework, achieving an exceptionally low mean absolute error (MAE) of

收稿日期: 2025-06-20 Received Date: 2025-06-20

\* 基金项目: 国家重点研发计划课题(2022YFB2404104)项目资助

1.33 mg/kg, a mean absolute percentage error (MAPE) of 7.167%, and a high coefficient of determination ( $R^2$ ) of 0.958. This research provides a novel, industrially viable solution for online, non-destructive, and high-accuracy monitoring of trace moisture in transformer oil.

**Keywords:** transformer oil; trace micro-water detection; broadband ultrasonic; time-frequency analysis; deep learning

## 0 引言

变压器作为电网核心设备,其可靠性对电网安全至关重要。国际大电网会议数据显示,绝缘劣化导致变压器故障的比例高达43%,其中油中微水含量超标是主要原因<sup>[1]</sup>。这一问题在兆伏安级的高频变压器中尤为严峻:其高功率密度与复杂结构导致热应力集中、水分更易侵入和积聚,显著加剧绝缘劣化风险。因此,精确检测变压器油中微水含量对于及时发现绝缘隐患、保障设备长期稳定运行具有不可替代的关键意义。

变压器油中微水检测可大致分为两大类:离线检测和在线检测。传统的离线检测以库伦卡尔费休滴定法(ASTM D6304)为代表<sup>[2]</sup>,虽具有较高测量精度,但需破坏性取样且时效性差。针对此局限性,研究者们开发了多种在线检测技术。文献[3]提出的光纤传感器微水监测法响应快、抗干扰强,但在制造复杂度和环境适应性方面存在挑战。文献[4]中的交叉电容法应用广泛,但存在响应迟滞和油液成分依赖问题;介电响应法<sup>[5]</sup>在温度波动条件下稳定性不足,且缺乏足够样本支持其通用性;文献[6]根据现有研究方法提出的红外光谱融合技术,虽整合了多种检测优势,但易受变压器油中其他杂质干扰;而文献[7]基于聚亚酰胺薄膜传感技术在高精度检测方面表现突出,但其复杂工艺限制了大规模应用;动态测量法<sup>[8]</sup>提供了新思路,但目前仍处于实验室阶段。值得注意的是,现有方法普遍存在特征提取维度单一、动态建模能力不足的缺陷,难以捕捉变压器油老化过程中微水与声学参数的复杂非线性关系。

近年来,超声检测技术因非侵入特性受到关注。已有研究表明,油液中的微量水分会显著影响超声波的关键声学参数,尤其是声速与声衰减,这些声学参数与含水量之间呈现出高度的非线性相关性<sup>[9-10]</sup>。但传统单频超声检测存在两大瓶颈:1)特征维度不足导致不同含水量样本的声学特征重叠度高达32%<sup>[11-12]</sup>;2)时频耦合效应造成物理模型参数辨识困难。因此,当前研究的核心问题是多模态声学参数与微水含量的映射关系具有强非线性和时变特性<sup>[13]</sup>,传统物理建模方法难以建立普适性解析模型。深度学习为解决上述问题提供了新路径。文献[14]基于神经网络预测变压器油击穿电压,取得较好的测量结果。文献[15]提出小波变换结合卷积神经网络(convolutional neural network, CNN)模型构建空气

质量预测。然而这些单一网络架构存在明显局限:CNN难以捕捉声学特征的时序演化规律,长短期记忆网络(long short-term memory, LSTM)对高维时频图的空间特征提取效率低下。

基于上述研究背景与技术挑战,本研究提出了一种融合宽带超声技术与CNN-LSTM混合深度架构。该方法通过非侵入式宽带超声扫描油样获取6个特征频段的声学频谱,并利用CWT时频分析,提取回波信号的高频和低频以及声纹在油液中传播的细微特征128维 $\times$ 1 000维,作为CNN-LSTM的输入,输出为实验室检测法831库伦水分测定仪测出的实际值。研究采用贝叶斯优化算法确定网络架构的关键超参数,包括卷积层深度、LSTM单元数量及学习率等核心参数,从而建立适应变压器油微水检测的CNN-LSTM耦合模型,并通过多工况下宽带超声数据验证该模型的预测精度。

## 1 宽带超声检测系统

超声波在油液中传播时,其声学特性会受到油中微水含量的影响,表现为声衰减现象,且随着水分含量的变化,波幅呈现出相应的减小或增大趋势。除此之外,温度会影响油中微水含量的微小起伏,为避免此种情况控制温度在室温 $24^{\circ}\text{C} \pm 1^{\circ}\text{C}$ 下进行实验<sup>[16]</sup>。如图1所示,宽带超声检测系统主要由超声控制单元和上位机分析单元协同工作。

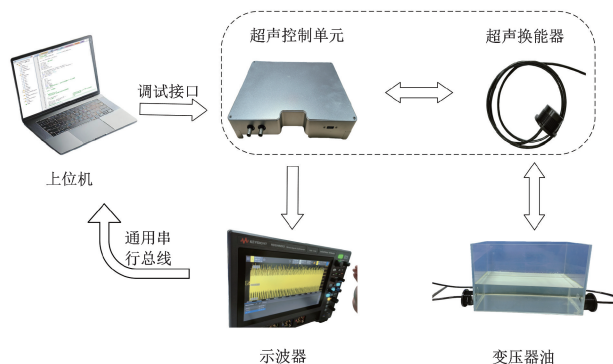


图1 宽带超声检测系统连接

Fig. 1 The connection diagram of the broadband ultrasonic testing system

图2中超声控制单元可编程多频脉冲发生器驱动宽带换能器发射超声波,同步采用100 MS/s高速采集

系统捕获回波信号。超声发射器在油液左侧,超声接收器在油液右侧,使用端对端模式进行收集宽带超声回波数据。穿透变压器油的超声回波原始信号通过示波器显示并通过数据采集在上位机分频率保存,并运

用上位机分析单元运用连续小波变换提取时频域特征,通过 CNN-LSTM 混合深度学习模型解析 6 组频段的声速、衰减和非线性参数,最终建立变压器油中微水含量预测模型。

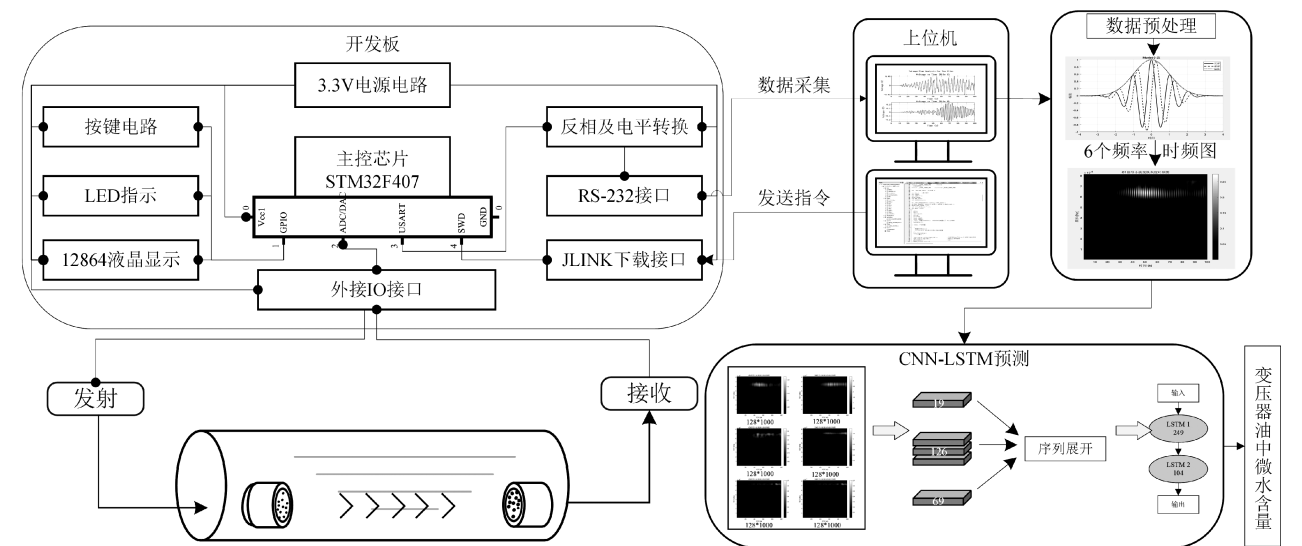


图2 宽带超声检测设计原理  
Fig. 2 Design principle diagram of broadband ultrasonic testing

变压器油的声速、密度和衰减特性直接影响超声波传播,频率过高会导致声衰减加剧,信号难以穿透,频率过低则可能无法有效分辨微水引起的微弱变化。通过多次试验确定较低频率 100~400 kHz 具有较强的穿透能力,适合深层检测,500~800 kHz 则提供更高的分辨率,能够捕捉细微水分变化。因此,实验选用 200、300、400、500、600 和 700 kHz 阶梯频率在室温条件下进行 3 次抽样扫描,并取平均回波信号。

2 宽带超声信号预处理

本研究采集运行年限 1~10 不等的 240 组 10 和 110 kV 的变压器油样本作为实验数据,使用 831 库伦水分测定仪检测每组油样实际含水量作为基准值,其含水量分布在 5~50 mg/kg。具体样本分布如表 1 所示。

表 1 变压器油样本分布		
Table 1 Sample distribution of transformer oil		
电压等级/kV	运行年限/年	样本数/个
10	1~5	80
	5~10	40
110	1~5	70
	5~10	50

通过对宽带超声回波信号的分析发现,该信号通常呈

现非平稳特性并伴随显著的噪声干扰。小波变换能够在时域和频域同时提供信息,通过多尺度分析有效捕捉信号的局部特征,从而降低噪声干扰并提升信号的分辨能力<sup>[17]</sup>。

计算每个不同频率的油样本的连续小波变换 (continuous wavelet transform, CWT) 的公式如式(1)所示。

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

式中: $a$  为尺度参数; $b$  为平移参数,即时间步长; $t$  为时间; $f(t)$  为输入数据; $\psi(t)$  为母小波函数;由于 Morlet 小波多数适用于振荡信号的时间频率分析,并且具有复数形式,可以同时获取信号的振幅、相位和频率信息,所以  $\psi(t)$  选用 Morlet 小波。Morlet 小波的数学表达式如式(2)所示。

$$\psi(t)=\pi^{-1/4}e^{-t^2/2}e^{i\omega_0t}\tag{2}$$

式中: $\omega_0$  为小波的中心频率。

由于高频信号对应小尺度范围,低频信号对应大尺度范围,其中低频区(0.1~0.4 MHz)设置 48 个尺度解析油液整体阻抗变化,高频区(0.5~0.7 MHz)配置 80 个尺度捕捉微水关联的局部散射特征,因此尺度参数  $a$  设置为 128。

根据奈奎斯特采样定理,采样频率需至少为信号最高频率的 2 倍<sup>[18-20]</sup>。为了更好捕捉回波中细微信息,设定采样频率为原始频率的 6 倍,则采样频率范围在 1.2~4.2 MHz,则各频率 1 s 内采样点在 1 200 000~4 200 000。针对高频采样带来的数据量过大问题,采用多级降采样

与特征压缩实现数据量优化。对 4.2 MHz 信号按整数倍逐步降低采样率,并在每级降采样前引入抗混叠低通滤波器,有效抑制高频混叠干扰。在此基础上采用滑动窗口均值法对降采样后信号进行特征压缩,通过设定窗口长度将原始数据分割为 1 000 个窗口,提取各窗口内均值特征作为代表性时域信息。如图 3 所示,当特征量压缩至 1 000 点时,重构信号与原始信号的均方误差(mean squared error, MSE)为  $1.5 \times 10^{-8}$ ,验证了该参数下超声回波关键声学特征的有效保留。基于上述,将小波变换时频分析的平移参数  $b$  设置为 1 000,使时频窗口与降采样特征维度匹配,有效提升后续 CNN-LSTM 模型计算率。

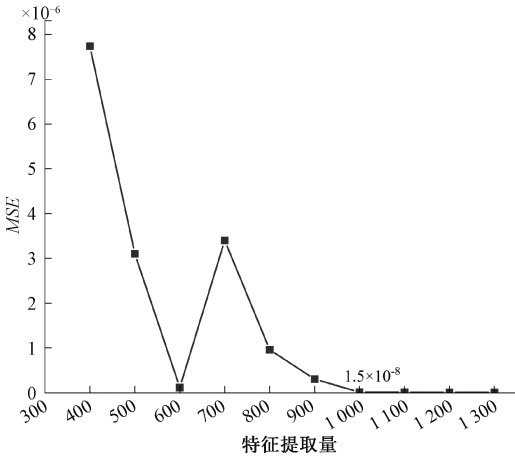


图3 降采样下各特征量对应 MSE

Fig. 3 MSE for each feature quantity under down-sampling

图 4 展示了经小波变换后,超声回波在不同含水量和频率下的幅值变化特征。

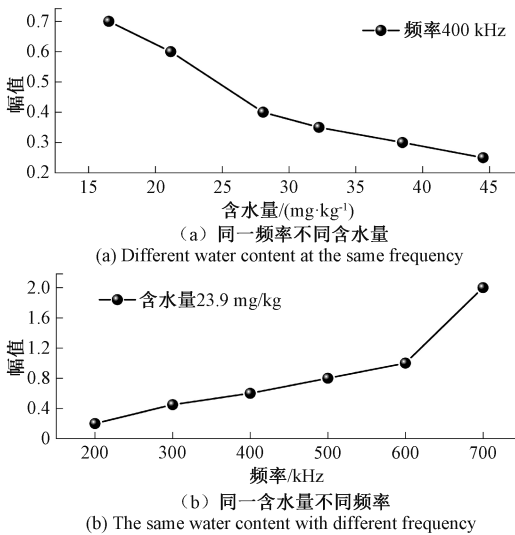


图4 小波变换时频图幅值变化趋势

Fig. 4 Wavelet transform time-frequency diagram amplitude variation trend

研究发现,图 4(a)在单一频率下,回波信号的能量与介质中的微水含量呈负相关,即微水含量越高,幅值下降的幅度越大,反映了超声波在传播过程中受到水滴的吸收与散射作用。图 4(b)在高频区域(500~700 kHz),即使含水量保持不变,超声回波的幅值仍表现出剧烈上升,这与该频率下超声波与水滴的相互作用机制发生变化有关,从而导致回波信号的幅度减弱。

### 3 算法设计

#### 3.1 卷积神经网络

卷积神经网络(CNN)作为深度学习核心架构之一,其多层结构包含数据输入层、卷积层、激活层、池化层及全连接<sup>[21-23]</sup>。本文所构建的 CNN 旨在有效学习时频图中的空间特征,捕捉由衰减、散射和波形失真引起的特定“纹理”或“形状”。该网络的整体架构如图 5 所示,网络首先接收 6 通道、维度为  $128 \times 1\,000$  的超声数据作为输入。核心部分由 3 个级联的二维卷积块构成,用以逐层跨尺度地提取时空特征,从初始特征逐步深入到高级和深层特征。卷积层后设置池化层,对提取到的特征图进行降维,以减少计算复杂度并保留关键信息。

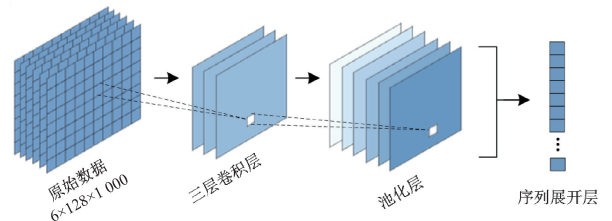


图5 CNN 卷积网络架构

Fig. 5 CNN convolutional network architecture

1) 卷积层负责核心的特征提取,其二维卷积层操作通过滑动卷积核在输入张量上进行运算,计算公式如式(3)所示。

$$Y(i, j, k) = \sigma \cdot \left( \sum_{m=1}^C \sum_{p=1}^{F_h} \sum_{q=1}^{F_w} X(i+p, j+q, m) \cdot W(p, q, m, k) + b(k) \right) \quad (3)$$

式中:  $Y$  为输出张量,即卷积结果,  $i, j, k$  分别对应空间维度和通道数;  $\sigma$  为激活函数;  $X(i+p, j+q, m)$  为输入特征图在位置  $(i+p, j+q)$  和通道  $m$  上的值;  $W(p, q, m, k)$  为权重矩阵,表示从输入通道  $m$  到输出通道  $k$  的连接权重,对于每个位置  $(p, q)$  都有一个对应的权重值;  $F_h, F_w, C$  分别为卷积核高、宽、通道数;  $b$  为偏置项,按输出通道定义。

2) 激活层函数选择 ReLU 函数,在卷积运算之后引入非线性变换,使网络能够学习更复杂的模式。其优势

在于计算简单、缓解梯度消失问题。其函数公式如式(4)所示。

$$\text{ReLU}(x) = \max(0, x) \quad (4)$$

3) 池化层用于对特征图进行降维,将维度压缩减少计算复杂度的同时保留核心特征。池化计算公式如式(5)所示。

$$Y(i, j, k) = \frac{1}{F_h F_w} \sum_{p=1}^{F_h} \sum_{q=1}^{F_w} X(i+p, j+q, k) \quad (5)$$

式中:  $F_h$  和  $F_w$  为池化核的高度和宽度,本文中为  $2 \times 2$ 。

最后,序列展开层将高位特征转换为序列形式,形成适合输入到后续 LSTM 的数据格式。

### 3.2 长短期记忆网络

由于宽带超声数据具有强时间依赖性,引入 LSTM 更好地捕捉时间序列特征。LSTM 是一种特殊的循环神经网络(recurrent neural network, RNN),专用于时序数据建模,通过遗忘门、输入门、输出门和细胞状态的门控机制实现长程依赖捕获<sup>[24-25]</sup>。采用两层 LSTM 结构,隐藏单元数为 CNN 的输出,即通过细胞状态  $h_t$  和隐藏状态  $c_t$  来捕获信号中长期和短期的依赖关系。

如图 6 所示,利用 LSTM 的门控机制处理 CNN 提取出的特征序列,捕捉其中长期的时间依赖关系。使用两层 LSTM,允许网络学习不同层次的时间抽象。第 2 层在第 1 层的基础上进一步处理时序信息。

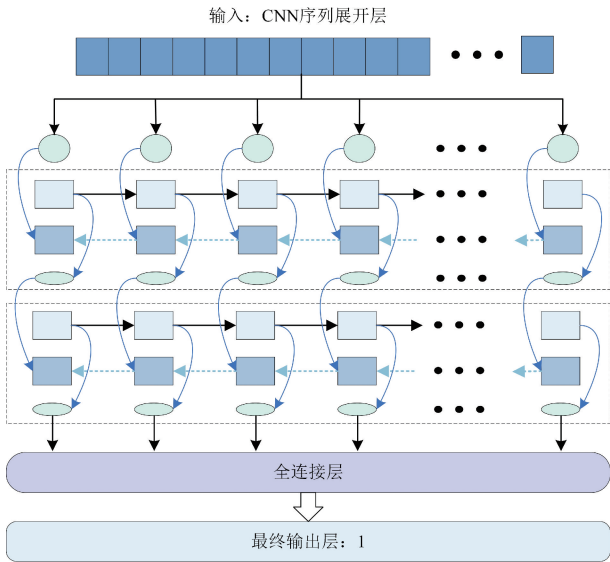


图 6 LSTM 架构

Fig. 6 LSTM convolutional network architecture

LSTM 单元的  $h_t$  输出可以用式(6)~(11)表示,即:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (9)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (10)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (11)$$

式中:  $f_t$  为遗忘门的输出,范围在  $0 \sim 1$ ;  $i_t$  为输入门的输出;  $\tilde{c}_t$  为候选记忆单元;  $c_t$  表示当前时刻的记忆单元状态;  $h_t$  为当前时间步的隐藏状态,即网络最终输出;  $W_f, W_i, W_c, W_o$  分别为遗忘门、输入门、候选记忆和输出门的权重矩阵;  $b_f, b_i, b_c, b_o$  为各门的偏置项;  $\sigma$  为激活函数 sigmoid,用于将输出映射到  $[0, 1]$ 。

通过全连接层将 LSTM 的输出  $h_t$  映射到回归任务的目标维度。全连接层的计算如式(12)所示。

$$Y = XW + b \quad (12)$$

式中:  $Y$  为模型预测结果;  $X$  为第 2 层 LSTM 的输出隐藏状态;  $W$  为权重矩阵,是一个可训练的参数,用于将 LSTM 输出映射到目标输出维度;  $b$  为偏置。

### 3.3 CNN-LSTM 变压器油中微水预测模型

本文以 240 组不同含水量变压器油样本为核心数据源,并将 240 组样本按含水量梯度均衡划分为 5 个子集(每折 48 组),在每轮迭代中以四折数据实施动态标准化训练,并保留 1 折作为验证集,确保各频率数据完整性。

模型具体算法流程如图 7 所示,从原始数据 ( $6 \times 128 \times 1\,000$ ) 出发,进行归一化或标准化处理,消除量纲差异,提升模型收敛效率。采用 CNN-LSTM 联合架构,其中 CNN 负责提取时频图的空间特征(如高频纹理、能量分布),LSTM 网络捕捉不同频率间的时序动态关联。并通过损失函数监控和反向传播调整网络参数,配合五折交叉验证评估模型每折预测性能。

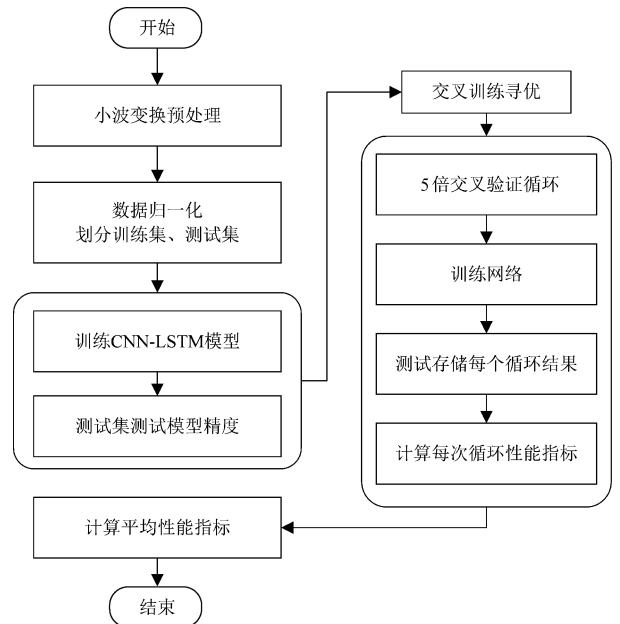


图 7 变压器油中微水预测模型流程

Fig. 7 Flowchart of the micro-water prediction model in transformer oil

此外,为提升 CNN-LSTM 模型的预测精度并克服手动调参的局限,研究采用贝叶斯优化法进行超参数寻优,并利用采集函数智能选择评估点,以较少迭代次数高效地探索并收敛至最优超参数组合。选取的关键超参数涵盖网络结构(卷积层滤波器数量、LSTM 单元量)、训练过程(小批量大小、最大训练轮数、学习率)及正则化(Dropout 率)等方面,如表 2 所示。

表 2 CNN-LSTM 模型主要超参数设置  
Table 2 Main hyperparameter settings of the CNN-LSTM model

名称	超参数优化范围	最优超参数
小批量大小	[ 4, 32 ]	12. 00
最大训练轮数	[ 100, 500 ]	397. 00
学习率	[ $10^{-5}$ , $10^{-1}$ ]	0. 02
第 1 层卷积层滤波器	[ 16, 64 ]	19. 00
第 2 层卷积层滤波器	[ 32, 128 ]	126. 00
第 3 层卷积层滤波器	[ 64, 256 ]	69. 00
第 1 层 LSTM 单元量	[ 64, 256 ]	249. 00
第 1 层 LSTM 单元量	[ 32, 128 ]	104. 00
Dropout 率	[ 0. 1, 0. 5 ]	0. 11

超参数范围的设定依据为:考虑到输入数据为 6 个不同频率的超声回波信号,其可能包含复杂的时空特征和噪声,范围选择旨在平衡模型容量、训练效率与泛化能力。学习率范围[  $10^{-5}$ ,  $10^{-1}$  ]覆盖从保守到激进的更新策略;卷积滤波器和 LSTM 单元数量范围允许模型适应不同层次的特征提取和时间依赖建模需求;小批量大小和训练轮数范围则考虑了稳定收敛与防止过拟合的需求;Dropout 率范围[ 0. 1, 0. 5 ]提供了不同强度的正则化选项。

图 8 展示了贝叶斯优化过程中的目标函数计算值的收敛曲线。

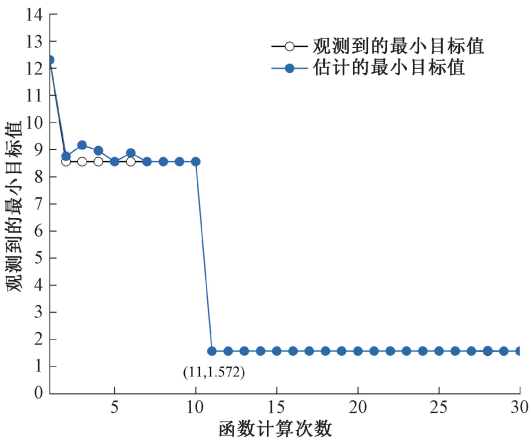


图 8 函数计算次数-最小目标值

图 8 中横坐标代表优化算法的迭代次数,共进行了 30 次迭代评估,纵坐标则表示每次迭代所评估的超参数组合对应的目标函数计算值。在优化初期(前 10~15 次迭代),目标函数计算值波动相对较大,这表明贝叶斯优化算法正在广泛探索超参数空间的不同区域,尝试不同的参数组合以快速了解函数景观。随着迭代次数的增加(15 次迭代之后),目标函数计算值的波动逐渐减小,并趋向于收敛到一个较优的稳定水平值 1.572。表明贝叶斯优化过程已基本收敛,找到当前搜索空间和迭代次数下的一组性能表现最佳的超参数组合。

通过贝叶斯优化,确定了一组适用于处理该特定超声回波数据的最佳超参数配置,如表 3 所示。采用此配置训练的模型,在均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)和拟合系数( $R^2$ )上表现出最优性能,验证了贝叶斯优化方法在针对性地提升本研究中 CNN-LSTM 模型处理宽带超声信号性能方面的实用价值。

表 3 贝叶斯函数计算性能  
Table 3 Computational performance of Bayesian function

名称	数值
函数计算总次数	30. 00
总历时/s	1 769. 60
总目标函数计算时间/s	1 763. 80
RMSE	1. 29
MAE	1. 01
$R^2$	0. 96

4 实验与分析

4.1 消融实验

为验证本文中所提出的 CNN-LSTM 模型的精确性和优越性,设计了消融实验,将该模型与 CNN、LSTM、CNN 结合门控循环单元(gated recurrent unit, GRU)及 CNN 结合支持向量机(support vector machine, SVM)等对比模型进行性能评估<sup>[26]</sup>。

为确保实验的公平性与可比性,各模型的超参数设置遵循了特定原则。在单一结构模型方面, CNN 与 LSTM 模型的超参数配置与 CNN-LSTM 混合模型保持一致,以消除参数差异对模型性能评估的干扰。对于混合结构模型, CNN-SVM 采用了径向基函数(radial basic function, RBF)作为 SVM 的核函数以有效处理非线性特征映射,其核带宽参数设为 0. 1,这一中等大小的参数设置旨在平衡模型的表达能力与泛化性能,避免过度拟合训练数据。CNN-GRU 模型中, GRU 组件采用了双层堆

Fig. 8 Function calculation times-minimum target value

叠结构以增强对长序列时间依赖关系的建模能力,同时在 GRU 层间引入和 CNN-LSTM 相同的 11.267% 的随机丢弃 (Dropout) 机制,有效抑制了模型过拟合倾向,提升了泛化性能。各对比模型具体超参数如表 4 所示。

表 4 各模型主要超参数

名称	参数
全局参数	损失函数:MSE
	优化器:Adam
	学习率:0.02
	训练周期数:350.00
	输入特征维度:3.00
	正则化系数:0.20
	批量处理参数:8.00
CNN 层	卷积核大小:[3,3]
	激活函数:ReLU
	卷积层:3.00
	过滤器数量:128.00
LSTM 层	LSTM 层数:2.00
	双向特性:True
	梯度阈值:1.00
SVM 层	核函数:RBF
	不敏感损失参数:0.10
	核函数尺度:0.10
GRU 层	GRU 层数:2.00
	隐藏单元数:100/50
	Dropout 概率:0.11

图 9 展示了 CNN-LSTM 模型在宽带超声检测变压器油微水含量任务中的五折交叉验证性能指标。

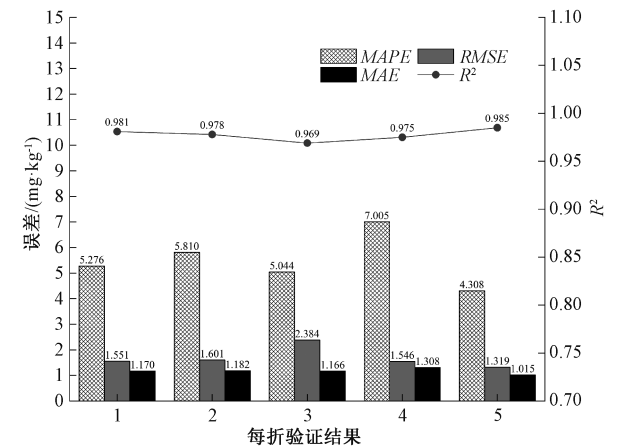


图 9 CNN-LSTM 五折交叉验证性能指标

Fig. 9 CNN-LSTM five-fold cross-validation performance index

从图 9 中可以看出,CNN-LSTM 模型在不同折次中表现出高度一致的预测性能,表明模型具有良好的稳健性和可靠性。具体而言,平均绝对百分比误差 (mean absolute percentage error, MAPE) 的值分别为 5.276%、5.81%、5.044%、7.005% 和 4.308%,波动范围约为 2%;RMSE 的值分别为 1.551、1.601、2.384、1.546 和 1.319,绝大部分折次的值保持在 1.5~1.6;MAE 的值分别为 1.17、1.182、1.166、1.308 和 1.105,也表现出较小的方差。尤其值得注意的是, $R^2$  值在所有折次中均稳定保持在约 0.95 以上,表明该模型能够解释超过 95% 的数据变异性,具备极高的预测精度。

此外,根据五折交叉验证总体平均性能确定 CNN-LSTM 模型最终各项性能指标。图 10 所示指标对比表明,CNN-LSTM 模型在宽带超声数据预测任务中展现出显著的优越性,其 RMSE 和 MAE 分别为 2.03 和 1.33,较最优单模型分别降低约 32.6% 和 29.8%,其误差控制能力显著优于其他对比模型。同时,模型的  $R^2$  达到 0.958,较传统单模型提升 0.1 个量级,逼近理论最优值 1。MAPE 指标 7.17% 较其他模型平均降低近 5 个百分点,验证了其在实际工程应用中的可靠性。

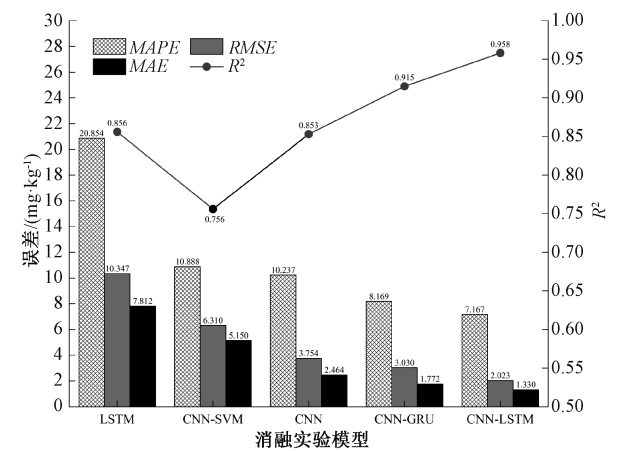


图 10 消融实验模型性能指标

Fig. 10 Comparison of performance metrics for each model

图 11 表示各模型在预测性能上存在显著差异。单一 CNN 模型与 LSTM 模型预测差值波动明显,前者虽然在空间特征提取方面表现优异,但缺乏对时序数据的建模能力,后者能处理时序依赖但对高维频域特征解析不足。

CNN-SVM 模型受限于其对宽带超声数据空间动态性能的表达能力,导致预测误差波动较大。CNN-GRU 模型在一定程度上解决了上述问题,但在处理本研究中的长序列数据(6×128×1 000)时,由于 GRU 的记忆能力相对较弱,仍然存在个别样本预测误差较大的情况。图 12 所示表明,CNN-LSTM 模型的预测误差最为集中,绝大部

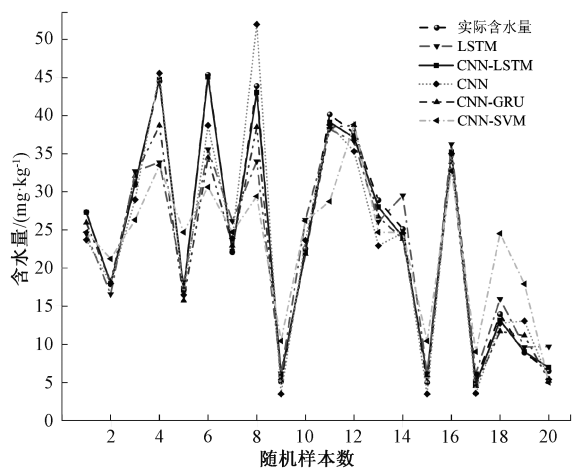


图 11 各模型微水含量预测值与真实值对比

Fig. 11 Comparison of predicted micro-water content values and real values for each model

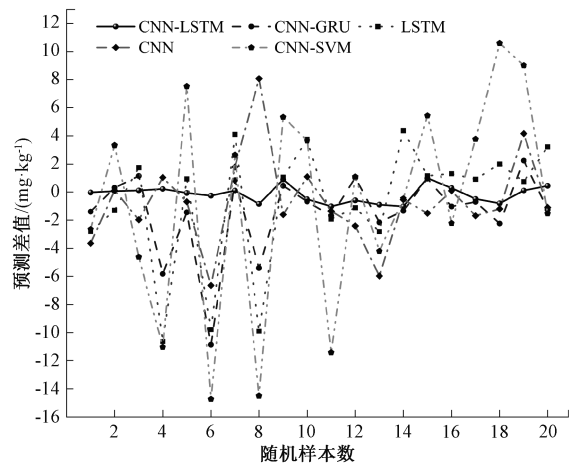


图 12 各模型微水含量的预测差值

Fig. 12 Prediction difference of micro-water content for each model

分误差分布在 $\pm 1\text{ mg/kg}$ 范围,均值为 $0.789\text{ mg/kg}$ ,明显优于其他对比模型,并且满足国标 GB/T 7600—2014 检测标准 $2\text{ mg/kg}$ 以下<sup>[27]</sup>。

4.2 对比实验

本节选取多种具有代表性的模型作为对比基线,旨在全面评估 CNN-LSTM 模型在变压器油中微水预测任务上的性能。

首先,采用基于鲸鱼优化算法的埃尔曼神经网络 (whale optimization algorithm-optimized Elman neural network, WOA-Elman) 作为同类型模型进行比较。其次,选取经典的机器学习模型随机森林 (random forest, RF) 和 SVM 进行不同类型模型的对比分析。对以上对比模型均利用贝叶斯函数对其关键超参数进行了优化,以确

保公平性,并在完全相同的数据集上进行了性能评估与时间消耗分析。

表 5 中详细记录了各对比模型在训练及预测阶段的时间消耗。

表 5 各对比模型时间成本

时间明细/s	WOA-Elman	RF	SVM	CNN-LSTM
总执行时间	683.22	10 084.18	486.96	465.95
数据加载时间	3.00	2.18	6.13	2.55
重塑时间	0.43		0.50	4.46
数据分割时间	0.43	2.13	0.14	0.02
模型训练、参数优化时间	678.46	10 077.50	479.73	455.26
测试集预测时间	0.90	4.48	0.44	1.76

其中,重塑时间指输入数据为适应特定模型输入格式而进行的结构调整耗时,数据分割时间则为将整个数据集物理地划分为独立训练集与测试集子集所花费的时间。结合图 13 所示的模型性能指标对比可以看出,RF 模型在各项性能指标上的表现仅次于 CNN-LSTM,然而其总执行时间最长约 3 h,显著限制了其实际应用的可行性。WOA-Elman 模型的总执行时间虽相对较短,但其性能指标普遍较差,特别地,其  $R^2$  值在所有模型中最低为 0.84,表明模型的可解释性较差。SVM 与 CNN-LSTM 的总执行时间相近,均约为 8 min,但在图 13 所示的性能评估中,CNN-LSTM 在所有关键性能指标上均表现更优。这表明,CNN-LSTM 模型在保持相对高效的执行时间 (约 8 min) 的同时,能够取得最优越的预测性能。

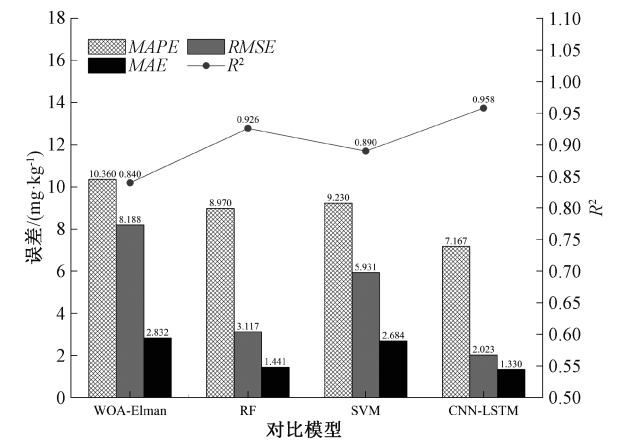


图 13 对比模型性能指标

Fig. 13 Compare model performance indicators

4.3 复杂工况下模型泛化性分析

为验证 CNN-LSTM 模型在模拟变压器运行噪声条件下的鲁棒性,本研究通过向宽带超声回波信号引入高斯白噪声,模拟实际运行中的振动干扰。实验设置了不同的信噪比( signal noise ratio, SNR) 水平,分别为 5、10、15 和 20 dB,代表极端、高、中等和低噪声条件。利用训练完成的 CNN-LSTM 模型,对不同 SNR 条件下的变压器油样超声检测信号进行预测,并与 831 库仑微水测定仪的真实值对比,评估模型性能。表 6 中结果显示,在中等噪声(SNR 为 10~15 dB) 下,模型预测性能接近原始无噪声信号;在极端噪声(5 dB) 下, RMSE 和 MAE 增幅约 30%, 仍属可控范围,而 MAPE 和  $R^2$  增幅低于 10%, 表明模型表现稳定;在低噪声(20 dB) 下,性能最接近原始预测。上述表明 CNN-LSTM 模型具备在现场噪声环境下的应用潜力。

表 6 不同信噪比下模型性能指标

Table 6 Model performance indicators under different signal-to-noise ratios				
信噪比	RMSE	MAE	MAPE/%	$R^2$
原始	2. 023	1. 330	7. 167	0. 958
5 dB	2. 940	1. 880	7. 840	0. 946
10 dB	2. 160	1. 790	7. 810	0. 953
15 dB	2. 170	1. 850	7. 250	0. 953
20 dB	2. 110	1. 710	6. 940	0. 954

为全面评估模型在实际变温工况下的泛化能力,采集了不同温度(10℃、20℃、30℃、40℃、50℃和60℃) 下的独立测试数据集(每个温度点 20 个样本)。所选温度范围依据在实际应用中宽带超声换能器推荐安装变压器油箱底部,在国家标准 GB/T 1094. 2—2013《电力变压器第 2 部分:温升》<sup>[28]</sup>, 变压器运行时顶部油温通常受限于约 85℃。由于热分层效应和油循环特性,底部油温略低于顶部,温差受负载和冷却方式影响,通常介于 10℃~20℃ 甚至更大,致使底部温度稳定在 60℃ 左右。

具体测试结果如表 7 和图 14 所示,结果表明:

- 1) 模型在 10℃~60℃ 范围保持了较高的预测精度( $R^2>0. 916$ )。
- 2) 随着温度偏离训练温度(24℃),性能指标呈现可接受的波动(例如,60℃ 时 MAPE 较 24℃ 基准增加约 16. 3%,  $R^2$  下降约 4. 4%, MAE 的增幅最大达 22%, 但仍属可控范围)。
- 以上充分表明所提模型在 60℃ 以内依然具备强大的解释能力,并且有力验证了所提模型在目标应用场景中,尤其是在变压器底部油温变化范围内的广泛适用性。

表 7 不同温度下 CNN-LSTM 预测性能指标

Table 7 CNN-LSTM predictive performance index at different temperatures				
温度/℃	MAPE/%	MAE/(mg·kg <sup>-1</sup> )	$R^2$	样本训练数量
24	7. 016	1. 330	0. 958	20
10	7. 542	1. 594	0. 928	20
20	7. 266	1. 487	0. 942	20
30	7. 540	1. 590	0. 945	20
40	7. 438	1. 597	0. 924	20
50	7. 819	1. 604	0. 920	20
60	8. 159	1. 611	0. 916	20

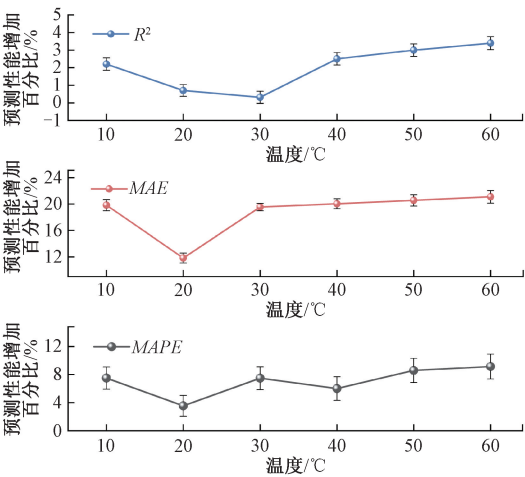


图 14 不同温度下模型性能指标增加百分比

Fig. 14 The percentage increase of model performance index at different temperatures

5 结 论

针对变压器油中微量水分含量的高精度无损检测需求,提出了一种融合宽带超声时频分析技术与深度学习算法的检测方法。通过理论建模、信号处理与算法优化,成功实现了油中微量水分含量的非侵入式、高精度预测。主要结论为:

- 1) 首创了宽带超声时频-深度学习融合框架:首次将宽带多频超声扫描技术与深度学习模型相结合,构建了一种全新的变压器油微量水分检测范式。通过在 6 个频率下激励油样,并利用连续小波变换对回波信号进行时频域分解,提取了 128×1 000 维高/低频联合特征。这些特征能够有效表征水分信息,并为深度学习模型提供了丰富的输入数据。
- 2) 提出了高性能 CNN-LSTM 混合预测模型:设计并

验证了CNN-LSTM混合架构的核心优势。该模型通过CNN分支自适应提取时频谱图的深层空间模式特征,并通过LSTM分支有效建模多频点超声特征的时序演化规律与动态关联性,两者的协同作用显著提升了模型对复杂声学与水分含量之间映射关系的建模能力。实验验证其预测精度达到行业领先水平( $MAE = 1.33 \text{ mg/kg}$ ,  $MAPE = 7.167\%$ ,  $R^2 = 0.958$ ),性能显著优于对比的单一及传统模型。

3) 提供了具有重要工程价值的解决方案:研究成果成功实现了变压器油中微量水分含量的非侵入式、高精度定量检测,解决了传统方法的破坏性取样与抗干扰性差等关键痛点。所提出的技术方案原理清晰、方法可靠、精度优异,为电力设备绝缘油状态的在线智能监测与诊断提供了切实可行的全新技术途径,具有广阔的工程应用前景和推广价值。

## 参考文献

- [1] 赵希才,陈建国. 2021年国际大电网会议继电保护与自动化技术动态[J]. 供用电, 2021, 38(12): 42-48.  
ZHAO X C, CHEN J G. A review of cigre 2021 on study committee of protection and automation[J]. Distribution & Utilization, 2021, 38(12): 42-48.
- [2] 张震,马殿伟,李慧君,等. 卡尔费休微量水分测定方法的研究[J]. 精细与专用化学品, 2025, 33(1): 10-12,16.  
ZHANG ZH, MA D W, LI H J, et al. Research of Karl Fischer method for determining trace water content[J]. Fine and Specialty Chemicals, 2025, 33(1): 10-12,16.
- [3] 江军,吴雪瑞,赵晓林,等. 基于光纤S锥的电力变压器油中微水传感研究[J]. 中国电机工程学报, 2022, 42(1): 425-434.  
JIANG J, WU X R, ZHAO X L, et al. Research on moisture sensing in power transformer oil based on S-shape optical fiber[J]. Proceedings of the Chinese Society of Electrical Engineering, 2022, 42(1): 425-434.
- [4] 宋云翔,潘明,张文泽. 基于交叉电容原理的变压器油中微水在线监测系统[J]. 变压器, 2022, 59(12): 59-64.  
SONG Y X, PAN M, ZHANG W Z. On-line monitoring system for water content in transformer oil based on principle of cross capacitance[J]. Transformer, 2022, 59(12): 59-64.
- [5] 张明泽,刘骥,齐朋帅,等. 基于介电响应技术的变压器油纸绝缘含水率数值评估方法[J]. 电工技术学报, 2018, 33(18): 4397-4407.
- ZHANG M Z, LIU J, QI P SH, et al. Numerical evaluation method for moisture content of transformer oil-paper insulation based on dielectric response technique[J]. Transactions of China Electrotechnical Society, 2018, 33(18): 4397-4407.
- [6] 陈彬,刘阁. 变压器油中微水含量在线监测方法研究进展[J]. 高电压技术, 2020, 46(4): 1405-1416.  
CHEN B, LIU G. Research progress on online monitoring method of micro-water content in transformer oil[J]. High Voltage Engineering, 2020, 46(4): 1405-1416.
- [7] 陈伟根,甘德刚,刘强. 变压器油中水分在线监测的神经网络计算模型[J]. 高电压技术, 2007, 33(5): 73-78.  
CHEN W G, GAN D G, LIU Q. On-line monitoring model based on neural network for moisture content in transformer oil[J]. High Voltage Engineering, 2007, 33(5): 73-78.
- [8] SARFI V, MOHAJERYAMI S, MAJZOABI A. Estimation of water content in a power transformer using moisture dynamic measurement of its oil[J]. High Voltage, 2017, 2(1): 11-16.
- [9] 王辰辰,杨梦冉,姚贞建. 噪声频谱混叠干扰下超声检测信号高质量提取方法[J]. 仪器仪表学报, 2024, 45(10): 244-252.  
WANG CH CH, YANG M R, YAO ZH J. High quality extraction method of ultrasonic detection signals under noise spectrum aliasing interference[J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 244-252.
- [10] 袁帅,吴健,曹阳,等. 基于三位置超声波检测的改进强跟踪UKF-SLAM方法研究[J]. 仪器仪表学报, 2021, 42(5): 261-269.  
YUAN SH, WU J, CAO Y, et al. Research on improved strong tracking UKF-SLAM method based on three-position ultrasonic detection[J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 261-269.
- [11] SUN Q, TAN CH, DONG F. Measurement of oil-water two-phase flow phase fraction with ultrasound attenuation[J]. IEEE Sensors Journal, 2018, 18(3): 1150-1159.
- [12] BAÊSSO R M, COSTA-FELIX R P B, MILORO P, et al. Ultrasonic parameter measurement as a means of assessing the quality of biodiesel production[J]. Fuel,

- 2019, 241(1):155-163.
- [13] 李建勋,王开. 基于时频特征的反监听技术研究与应用[J]. 电子测量技术, 2024, 47(7): 1-8.
- LI J X, WANG K. Anti-eavesdropping technology research and application based on time-frequency features[J]. Electronic Measurement Technology, 2024, 47(7): 1-8.
- [14] SU Y, LIU M H, KONG X H, et al. Evaluation of breakdown voltage and water content in transformer oil using multi frequency ultrasonic and generalized regression neural network[J]. Journal of Nanoelectronics and Optoelectronics, 2021, 16(3):387-394.
- [15] ESLAMI E, CHOI Y, LOPS Y, et al. Using wavelet transform and dynamic time warping to identify the limitations of the CNN model as an air quality forecasting system[J]. Geoscientific Model Development, 2020, 13(12): 6237-6251.
- [16] 袁发庭, 张乃月, 匡柏源, 等. 基于多孔介质的油浸式变压器磁场-流场-温度场仿真计算及热点温度反演预测[J]. 高电压技术, 2025, 51(1): 62-74.
- YUAN F T, ZHANG N Y, KUANG B Y, et al. Simulation calculation of magnetic-fluid-thermal field of oil-immersed transformer based on porous media and prediction of hot spot temperature inversion[J]. High Voltage Engineering, 2025, 51(1): 62-74.
- [17] ARTS L P A, VAN DEN BROEK E L. The fast continuous wavelet transformation (fcWT) for real-time, high-quality, noise-resistant time-frequency analysis[J]. Nature Computational Science, 2022, 2(1): 47-63.
- [18] 盛志超, 方勇, 徐强荣, 等. 从奈奎斯特采样到压缩感知拓展教学方法[J]. 电气电子教学学报, 2024, 46(1): 164-169.
- SHENG ZH CH, FANG Y, XU Q R, et al. Form nyquist sampling to compressed perception to expand teaching methods [J]. Journal of Electrical and Electronic Education, 2024, 46(1): 164-169.
- [19] 盖建新, 付平, 付宁, 等. 基于SVD与MUSIC的亚奈奎斯特采样重构算法[J]. 仪器仪表学报, 2012, 33(9): 2073-2079.
- GAI J X, FU P, FU N, et al. Sub-nyquist sampling reconstruction algorithm based on SVD and MUSIC[J]. Chinese Journal of Scientific Instrument, 2012, 33(9): 2073-2079.
- [20] 武媛媛, 徐克欣, 陈丹, 等. 一种 ADC 前端无源差分抗混叠滤波器设计[J]. 电子与封装, 2023, 23(4): 46-50.
- WU Y Y, XU K X, CHEN D, et al. Design of ADC front-end passive differential anti-aliasing filter [J]. Electronics & Packaging, 2023, 23(4): 46-50.
- [21] 陈铁, 陈一夫, 李咸善, 等. 基于 SDS-SSA-LSTM 的变压器油中溶解气体浓度预测[J]. 电子测量技术, 2022, 45(12): 6-11.
- CHEN T, CHRN Y F, LI X SH, et al. Prediction of dissolved gas concentration in transformer oil based on SDS-SSA-LSTM [J]. Electronic Measurement Technology, 2022, 45(12): 6-11.
- [22] 彭铎, 查海音, 曹坚, 等. 基于 CNN-LSTM 声速预测的水下移动节点定位算法[J]. 电子测量与仪器学报, 2024, 38(11): 146-157.
- PENG D, ZHA H Y, CAO J, et al. Under water mobile node location algorithm based on CNN-LSTM sound velocity prediction [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 146-157.
- [23] 惠永永, 孙凯文, 脱奔奔, 等. 基于 CNN-STA-DLSTM 模型的间歇过程质量预测[J]. 电子测量与仪器学报, 2024, 38(11): 168-181.
- HUI Y Y, SUN K W, TUO B B, et al. Batch process quality prediction based on CNN-STA-DLSTM model[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 168-181.
- [24] ZHANG ZH H, TIAN Z G. CNN-ALSTM soft-sensing model for resistivity gradient in cz monocrystalline silicon wafers[J]. Instrumentation, 2025, 12(2): 71-79.
- [25] ZHAO L P, WU K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-attention method[J]. Instrumentation, 2023, 10(4): 64-82.
- [26] ZHAO T W, WANG J, CHEN J X, et al. Performance degradation prediction of proton exchange membrane fuel cell based on CEEMDAN-KPCA and DA-GRU networks[J]. Instrumentation, 2024, 11(1): 51-61.
- [27] 周波, 田德盈. GB/T 11133—2015《石油产品、润滑油和添加剂中水含量的测定 卡尔费休库仑滴定法》修订解读[J]. 石油商技, 2016, 34(2): 73-77.
- ZHOU B, TIAN D Y. Interpretation of GB/T 11133—2015 'determination of water content in petroleum products, lubricating oils and additives' revised Karl

Fischer coulometric titration [J]. Petroleum Products Application Research, 2016, 34(2): 73-77.

[28] 王鹏, 陈广柱, 付宝鑫, 等. 液浸式电力变压器绕组温升计算的简化方法[J]. 电气传动, 2017, 47(1): 63-66.

WANG P, CHEN G ZH, FU B X, et al. The simplified calculation method of temperature rise for winding of liquid-immersed transformers[J]. Electric Drive, 2017, 47(1): 63-66.

作者简介



**覃兆宇**, 2001 年于武汉理工大学获得学士学位, 2005 年于中国石油大学(北京)获得硕士学位, 2008 年于中国科学院上海光学精密机械研究所获得光学工程博士学位。现为湖北工业大学电气与工程学院电气工程系教授(四级岗), 主要研究方向为光学传感、高压与绝缘在线监测及故障诊断、电力电缆运行维护。

E-mail: qinzhaoyu@hbut.edu.cn

**Qin Zhaoyu** received his B. Sc. degree from Wuhan University of Technology in 2001, his M. Sc. degree from China University of Petroleum (Beijing) in 2005, and his Ph. D. degree in optical engineering from Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences in 2008. He is currently a professor (four posts) in the Department of Electrical

Engineering, School of Electrical and Electronic Engineering, Hubei University of Technology. His main research interests include optical sensing, online monitoring and fault diagnosis of high voltage and insulation, and operation and maintenance of power cables.



**孔洒洒**(通信作者), 2023 年于合肥师范学院获得学士学位, 现为湖北工业大学在读硕士生, 主要研究方向为电力设备在线监测。

E-mail: 1517107575@qq.com

**Kong Sasa** (Corresponding author) received her B. Sc. degree from Hefei Normal University in 2023. She is currently a master's student at Hubei University of Technology. Her main research interest includes online monitoring of power equipment.



**姚远**, 2022 年于上海电力大学获得学士学位, 现为国网上海青浦供电公司现场工程师 T10, 主要研究方向为变电设备检修与电气试验。

E-mail: 1285246502@qq.com

**Yao Yuan** received his B. Sc. degree from Shanghai University of Electric Power in 2022. He is currently a field engineer T10 of Shanghai QingPu Power Supply Company of State Grid. His main research interests include substation equipment maintenance and electrical testing.