第 50 卷 第 12 期：5346-5356　　高电压技术　　Vol.50, No.12: 5346-5356
2024 年 12 月 31 日　　High Voltage Engineering　　December 31, 2024
DOI: 10.13336/j.1003-6520.hve.20231854

非典型数据集下基于 Swin Transformer 的局部放电模式识别

张雨啸[1]，张　贲[2]，宋　辉[3]，唐　忠[1]，刘广辉[4]，江长明[2]
（1. 上海电力大学计算机科学与技术学院，上海 201306；2. 国家电网有限公司华北分部，北京 100053；
3. 上海交通大学电子信息与电气工程学院，上海 200240；4. 国网山东省电力公司枣庄供电公司，枣庄 277000）

摘　要：随着深度学习算法在局部放电模式识别领域的广泛应用，其很大程度上弥补了传统方法施行困难、效率低下的缺点。但由于实际现场局部放电机理复杂且情况多变，且可供训练的缺陷放电数据稀缺，大部分深度学习算法仍难以在实际使用中取得理想的识别准确率。该文通过分析实际测得的局部放电相位分辨的脉冲序列(phase resolved pluse sequence，PRPS)图谱特征上存在的问题，对比前者和局部放电缺陷实验模型上测得的 PRPS 图谱特征之间的差异，发现实际测得的现场数据具有更多的非典型特征，因此针对其提出一种基于 Swin Transformer 网络的局部放电识别方法，测试了该网络在前述两种来源数据上的识别准确率，并与传统神经网络进行了对比。结果表明：Swin Transformer 网络可以在实际现场数据分类上取得 93.3%的识别准确率，与传统方法相比，其识别准确率更高，且适用于现场缺乏局部放电样本的情形，更适合实际条件下使用。

关键词：局部放电；深度学习；模式识别；非典型特征；Swin Transformer；PRPS

Partial Discharge Pattern Recognition Based on Swin Transformer in Atypical Datasets

ZHANG Yuxiao[1], ZHANG Ben[2], SONG Hui[3], TANG Zhong[1], LIU Guanghui[4], JIANG Changming[2]
(1. College of Computer Science and Technology, Shanghai University of Electric Power, Shanghai 201306, China;
2. North China Branch of State Grid Corporation of China, Beijing 100053, China;
3. Department of Electrical Engineering, Shanghai Jiaotong University, Shanghai 200240, China;
4. Zaozhuang Power Supply Company, State Grid Shandong Electric Power Company, Zaozhuang 277000, China)

Abstract：The extensive application of deep learning algorithms in the field of partial discharge pattern recognition largely makes up for the shortcomings of traditional works such as difficulty in practice and low efficiency. However, because the unpredictable situations happen on-site, the partial discharge has complex mechanisms, and partial discharge data are rarely available for training, most deep learning algorithms are still difficult to achieve ideal recognition accuracy in actual situations. By analyzing the problems in the features of actual PRPS pattern and comparing the differences with the features of PRPS pattern measured on partial discharge defect models, this paper finds that the actual pattern has more atypical features. Therefore, we put forward a partial discharge recognition method based on the Swin Transformer network. We tested the recognition accuracy of the network on the data from two sources mentioned above, and compared the results with traditional neural networks. The results show that the Swin Transformer can achieve a recognition accuracy of 93.3% on on-site data sets. Compared with traditional methods, the Swin Transformer has higher recognition accuracy. It is also suitable for situations where there is a lack of partial discharge samples and it is more suitable for practical use.

Key words：partial discharge; deep learning; pattern recognition; atypical feature; Swin Transformer; PRPS

基金资助项目：国家自然科学基金 (52007117)；国家电网有限公司科技项目 (编号略)。
Project supported by National Natural Science Foundation of China (52007117), Science and Technology Project of SGCC.

0　引言

电气设备状态情况良好是其稳定运行的重要保障，而由于各种因素导致的设备内部产生的局部放电(partial discharge，PD)问题，因其在初期阶段具有隐蔽性，长期累积下对于设备具有不可逆的损坏性，使得对局部放电进行准确的检测和识别有着重要意义。随着电力设备配置规模不断扩大，复杂性不断升高，单纯采用传统局部放电检测方法已经难以满足如今对绝缘状态评估的要求[1]，同时随着计算机视觉领域的不断发展，研究人员逐渐开始将基于机器学习的模式识别方法引入到局部放电的智能检测和识别当中[2-6]。

多年来，针对局部放电模式识别领域研究的主要方法可以分为传统的机器学习方法和新型的深度学习方法。在传统机器学习方法中，许多学者采用支持向量机(support vector machine, SVM)[7]、随机森林(random forest，RF)[8]等方法，通过模拟气体绝缘开关设备(gas insulated switchgear, GIS)、电缆等设备存在的多种缺陷从而产生多类型局部放电，并对采集到的局部放电相关数据进行分类训练和识别，取得了不错的效果；在新型深度学习方法中，有学者使用卷积神经网络(convolutional neural networks，CNN)对不同放电的特高频相位分辨的脉冲序列(phase resolved pluse sequence，PRPS)图谱进行分类识别[9]，准确率相比传统方法明显提升；还有学者使用图卷积网络(graph convolutional network，GCN)进行分类识别[10]，在小样本数据集上也能表现出良好的泛化能力；同样也有学者在数据集上入手，使用均值漂移算法去除特高频相位分辨的局部放电(phase resolved partial discharge，PRPD)图谱中的脉冲型干扰[11]，结合后续的分类识别工作，也能取得更好的效果。

然而，这些研究大多数倾向于实验模拟阶段，由于设备所在现场不确定性高，设备内部部件具有高耦合性，实际放电过程极其复杂，不同设备上的同种放电差异也很大，仅使用缺陷模型所采集的数据来衡量机器学习算法在实际应用中的好坏不具有客观性，且数据特征中还易包含外部干扰或其他种类放电，使得这部分数据集多为非典型局部放电数据集。以上这些因素导致现有的深度学习算法在实际使用过程中依旧面临误报率高、识别准确率低等问题。

Swin Transformer(Swin-T)网络[12]是一种基于Transformer[13]模型的计算机视觉领域的神经网络，不同于以 LeNet[14]、ResNet[15]、DenseNet[16]等网络为代表的传统 CNN 网络的卷积模块只能获取局部特征，Swin-T 模型使用的自注意力机制能够把握图像的全局特征以及不同输入特征之间的关系，在很多领域均取得了优于 CNN 的效果[17-19]，同样非常适合依赖全局特征的 PRPS 图像。

本文考虑到模式识别的有效性和实用性，从多个方面针对现场实际数据进行分析，并结合现场数据可能会出现的各种问题，提出基于 Swin-T 网络的局部放电模式识别方法，并将其运用到局部放电 PRPS 图像识别领域，通过与多种传统网络的对比，并结合现场数据和实验数据之间的差异，发现其在该领域具有显著优势。

1　局部放电现场 PRPS 数据存在的问题

在特高频局部放电 PRPS 图谱模式识别领域，根据训练测试数据样本来源分类，主要可将数据分为两类：一类是通过在实验室配置不同种类的缺陷模型，通过高压实验采集得到 PRPS 数据(以下称为实验数据)；另一类是在设备运行现场，利用特高频传感器进行不断电在线监测所得到的设备实时产生的 PRPS 数据(以下称为现场数据)。实验数据不同类型特征差异明显、数据质量高且干扰较少，属于典型数据，神经网络等分类算法在实验数据上往往能达到很好的效果。而由于设备运行环境复杂多变，现场数据往往出现无特征量、干扰明显及特征不典型等问题，经研究，本文主要将其分为 3 种情况：

1）PRPS 图谱明显不包含有效数据，只有些微底噪和不明显的少量放电或干扰，如图 1 所示。

2）如图 2 中 PRPS 图谱所示，在(0, –90°)相位之间存在 1 条明显不属于放电信号的干扰信号。

3）放电特征不符合典型放电特征，属于非典型特征。如图 3 与图 4 所示，可看出现场和实验室测得的悬浮放电 PRPS 图谱特征具有显著差异，现场图谱有效特征近乎平均分布在每个象限，而实验图谱特征基本集中在第 1、第 3 象限。究其原因，实际放电缺陷结构多种多样，绝大部分并不具有常见局放缺陷模型的典型性，不同位置产生的同种放电在特征上也会有差异，同时产生的放电也可能不止一种，所以实际现场采集到的数据大部分属于非典型数据，这使得网络在区分现场数据类型时难以达到与实验数据相同的效果。

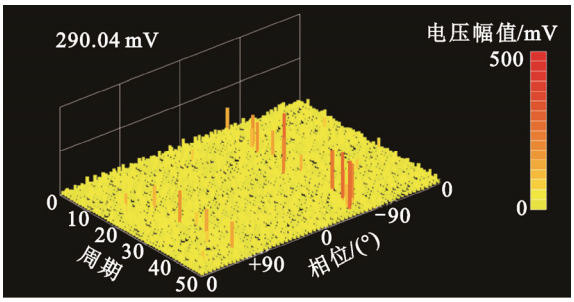


图 1 现场实测无有效数据的 PRPS 图谱

Fig.1 PRPS pattern measured on-site without valid data

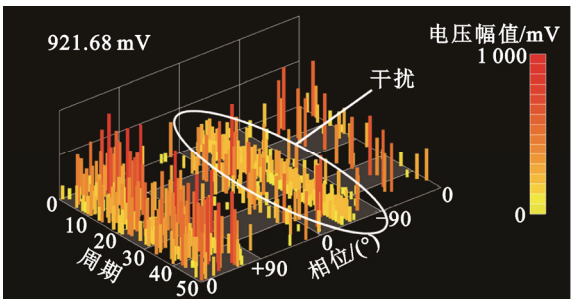


图 2 现场实测带干扰的 PRPS 图谱

Fig.2 PRPS pattern measured on-site with interference

情况 1）中单纯的无效数据与局部放电数据差异较大，可通过数据清洗算法予以剔除，而针对情况 2)、情况 3）中包含干扰及非典型放电的 PRPS 图谱数据进行准确识别分类，是本文提出基于 Swin-T 网络局部放电模式识别算法的主要目的。

2 基于 Swin-T 网络的 PRPS 图谱分类识别

自注意力机制最早由谷歌团队在 2017 年提出，并应用于 Transformer 模型中。其基本思想是通过建立输入中每个元素同其他序列元素之间的关系，从而找出不同元素之间的相似性，并将其转化为注意力权重。在 Vision Transformer(VIT)[20]将自注意力机制成功运用在计算机视觉领域后，Swin-T 在此基础上对其进行改进，借鉴了 CNN 的多层级思想，通过将图像块先拆分再合并，在不同的网络层中构建出一个特征金字塔(feature pyramid network, FPN)，如图 5 所示。

相比 VIT 中的全局自注意力计算(multi-head self-attention, MSA)，Swin-T 只对局部窗口中的内容进行自注意力计算(windows multihead self-attention, W-MSA)。其中 MSA 模块和 W-MSA 模块的计算复杂度表达式为：

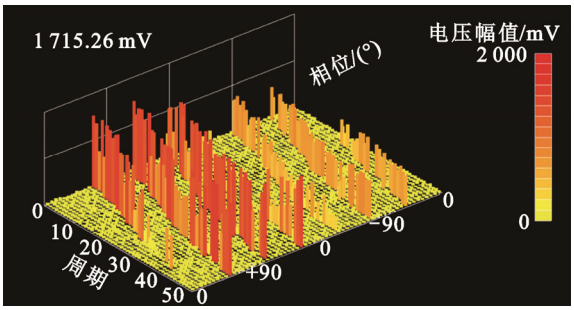


图 3 现场实测悬浮放电 PRPS 图谱

Fig.3 Surface discharge PRPS pattern measured on-site

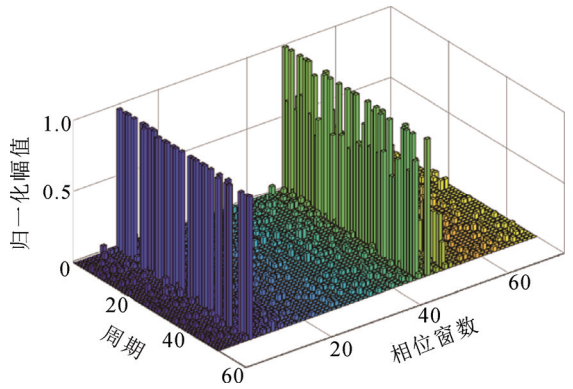


图 4 实验室测得的悬浮放电 PRPS 图谱

Fig.4 Experimental measurement of surface discharge PRPS pattern

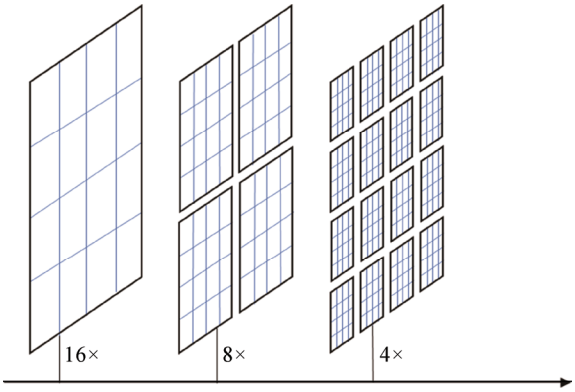


图 5 Swin Transformer 通过在更深层中合并图像块来构建分层特征图

Fig.5 The Swin-Transformer builds hierarchical feature maps by merging image patches in deeper layers

$$\begin{cases}\Omega(\text{MSA})=4h\omega C^2+2(h\omega)^2C\\ \Omega(\text{W-MSA})=4h\omega C^2+2M^2h\omega C\end{cases} \tag{1}$$

式中：h、ω 为网络中特征图(feature map)的高度和宽度；C 为 feature map 的深度；M 为每个正方形窗口的高度和宽度。因为每个窗口的高度和宽度 M 为固定值，这使得 Swin-T 的计算复杂度 Ω(W-MSA)

和图片拆分后的局部窗口的数量 $h\omega/M^2$ 呈线性关系，而 VIT 架构的计算复杂度 Ω(MSA)与输入图片的大小 $h\omega$ 呈平方关系，Swin-T 大大减少了网络的计算量。

由于 Swin-T 是对无重叠的窗口进行自注意力计算，这会使得不同窗口之间缺少关联，于是 Swin-T 在其架构中使用了一个移动窗口多头自注意力层(shifted windows multi-head self-attention，SW-MSA)，使其可在第二次自注意力计算时，将局部窗口重新划分，并对像素块进行重新组合，从而实现窗口之间的信息交互。相比于传统的 CNN 卷积神经网络，Swin-T 能够通过这种机制把握全局特征，而卷积神经网络只能对卷积核中的局部特征进行学习，难以把握长距离依赖关系。在移动窗口分割方法下，主干网络的一个 Stage 当中的 Swin-T 结构总是由分别带有 W-MSA 和 SW-MSA 的 2 个连续 Swin Transformer Block 组成，其计算方法如下：

$$\begin{cases} \hat{z}^{l}=\text{W-MSA}\left(\text{LN}\left(z^{l-1}\right)\right)+z^{l+1} \\ z^{l}=\text{MLP}\left(\text{LN}\left(\hat{z}^{l}\right)\right)+\hat{z}^{l} \\ \hat{z}^{l+1}=\text{SW-MSA}\left(\text{LN}\left(z^{l}\right)\right)+z^{l} \\ z^{l+1}=\text{MLP}\left(\text{LN}\left(\hat{z}^{l+1}\right)\right)+\hat{z}^{l+1} \end{cases} \tag{2}$$

式中：$\hat{z}^{l}$ 和 z^{l} 分别表示模块 l 中的 SW-MSA 模块和 MLP 模块的输出特征。

非典型 PRPS 数据本身含有局部放电信号特征，不同设备上的同种放电尽管会有特征差异，但同样也会有特征相似的地方，自注意力机制会使得网络更关注对图像识别分类更加有效的特征相似处，而降低特征差异处对网络判断的影响。且 Swin-T 通过多次下采样，使网络实现了层级式特征提取，融合了多尺度信息，并在此基础上引入相对位置偏置，极大程度上弥补了在小型数据集上 Transformer 架构因为没有归纳偏置而产生的劣势。这些优势、使得 Swin-T 能够很好地运用在局部放电 PRPS 数据集当中。

考虑到局部放电在线监测的实时性要求和测量系统的带宽限制，并且通过对比不同大小的 Swin-T 网络在本文所用 PRPS 数据集上的训练识别效率同准确率的平衡关系，本文选择了较小的 Swin-Tiny 版本，整体流程如图 6 所示，该主干网络的 4 个 Stage 中的 Swin Transformer Block 数分别为(2,2,6,2)，参数量较少，能够同时兼顾速度和网络性能。对网络进行训练前，需要将不同来源所得 PRPS 局部放电数据转化成统一大小的 2 维矩阵，并进行归一化，之后将数据传入 Patch Partition 层进行下采样分割图像，同时，在此载入预训练权重可大大减少局放数据在 Swin-T 网络上训练所需时间。本文在 Swin-T 主干网络的 Stage4 后加上了一个横向规范化层(layer normal，LN)，一个自适应池化层(Adaptive Avg-pool)和一个全连接层(Linear)来输出最终网络判别出的局部放电类型。

3　局部放电 PRPS 数据获取

3.1　局放模拟实验

本文搭建了局部放电实验测量平台，针对典型的 4 种局部放电缺陷进行了局放实验[21]，实验测量接线示意图及各设备的参数如图 7 所示。所使用的调理单元型号是上海驹电电气科技有限公司的 JD-S16，其采样率为 4 GHz，模拟带宽为 1~2 GHz。特高频传感器的频带范围为 300~1 500 MHz，等效高度测得约为 33.4 mm。示波器为 Tektronix 公司的 MDO3104 混合域示波器，有 4 个模拟通道(1 GHz)，采样率 5 GHz，记录长度为 10 M 个点。低通滤波器型号为 Mini-Circuits BLP-450+，截止频率为 440 MHz。

实验中使用的局部放电缺陷模型如图 8 所示，包含电晕放电、气隙放电、悬浮放电、沿面放电 4 种放电类型。缺陷模型设计参数如下：

1）电晕放电

针电极使用的针为半径 0.5 mm 的铜针，板电极使用的是半径 40 mm 的光滑铜板，针-板间隙距离为 20 mm。

2）沿面放电

球电极和板电极中间夹着环氧树脂材料薄片。球电极球半径为 10 mm，环氧树脂圆形薄片厚度为 2 mm，半径为 40 mm。

3）气隙放电

球电极和板电极中间夹着环氧树脂材料薄片。球电极球半径为 10 mm，使用的环氧树脂薄片厚度为 2 mm，薄片中间存在一个半径 0.5 mm，厚度 1 mm 的气隙。

4）悬浮放电

上、下两电极都使用棒半径 1 mm，针半径 0.25 mm 的铜针，通过环氧树脂材料固定下方针电极的位置，上、下针电极针尖间距为 3 mm，下方针电极与板电极之间距离约 1.5 cm。

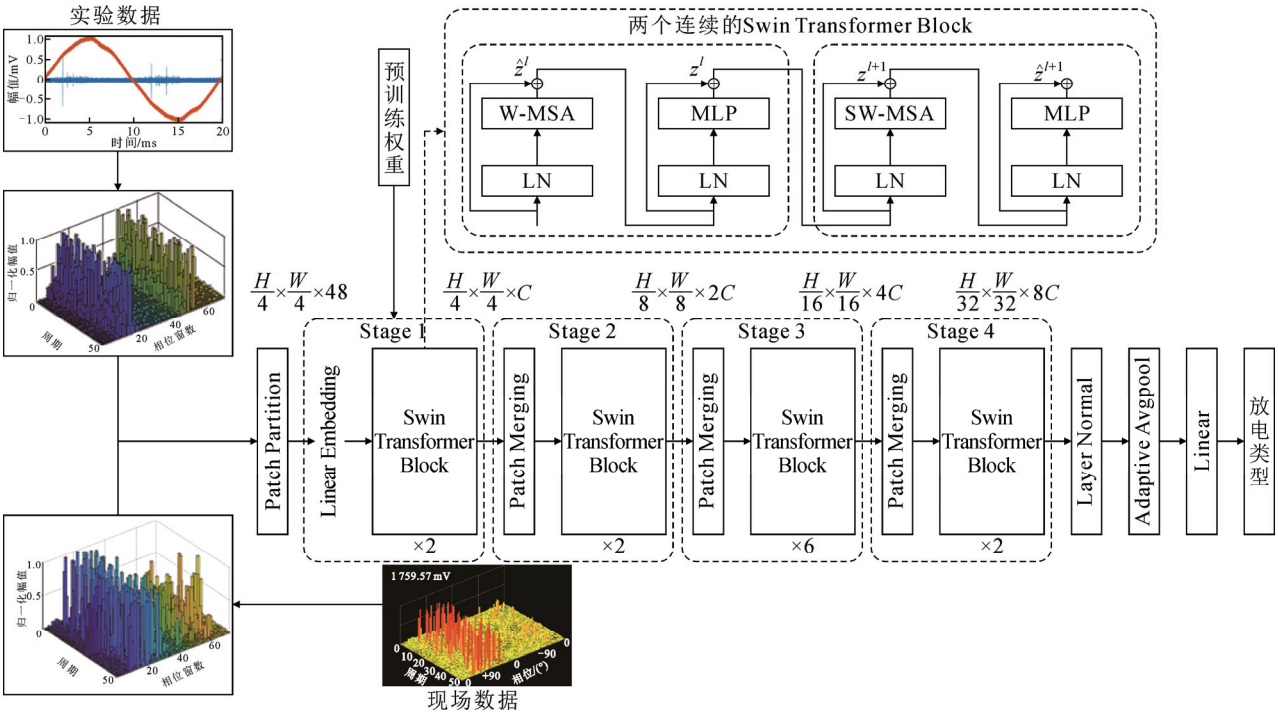


图 6 基于 Swin Transformer 的局部放电模式识别流程(H、W 分别为输入特征图的高度和宽度)

Fig.6 Process of partial discharge pattern recognition based on Swin-Transformer

(H and W are the height and width of the input feature map)

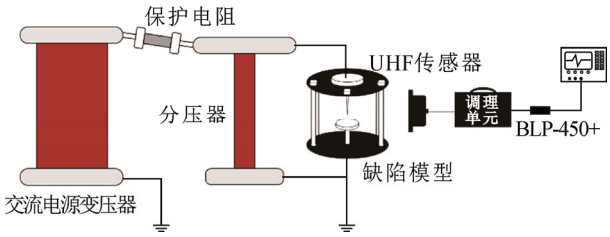


图 7 局部放电实验接线示意图

Fig.7 Partial discharge experiment wiring diagram

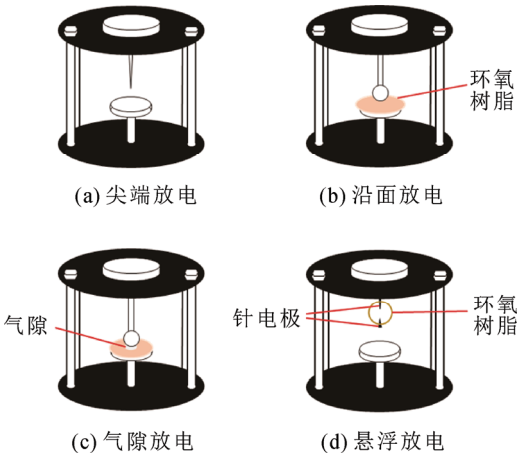


图 8 局部放电缺陷模型

Fig.8 Partial discharge defect models

根据图 7 所示实验平台，使用示波器测量了特高频局部放电的时域波形。实验中，施加在被测缺陷模型上的电压固定为 10 kV，特高频传感器摆放位置距离缺陷模型放电位置约 25 cm。

3.2 实验数据处理

对于实验数据，在 PC 上使用算法将示波器测量到的局部放电时域波形图转化为对应的 PRPS 图谱，如图 9 所示，每张时域图包含 1 s 内的局部放电参量，工频电压周期为 20 ms，1 s 内包含 50 个周期，总共测量了 10 万个时间点的数据，将相位等分成 72 个相位窗，利用最大池化筛选数据，最终在 PRPS 图谱上保留 50×72=3 600 个下采样数据。之后将 PRPS 图谱数据进行 98%最大归一化，得到最终的训练测试数据，4 种缺陷放电类型对应的 PRPS 图谱如图 10 所示。

3.3 现场数据获取

现场数据来源于变电站现场实测数据，数据采集使用的设备为 JD-S10 便携式局放检测仪，检测了总计 24 个变电站的具有异常放电情况的设备，得到对应的特高频局部放电 PRPS 谱图数据，如图 11 所示。被测设备包括 GIS 和开关柜。对于现场数据，

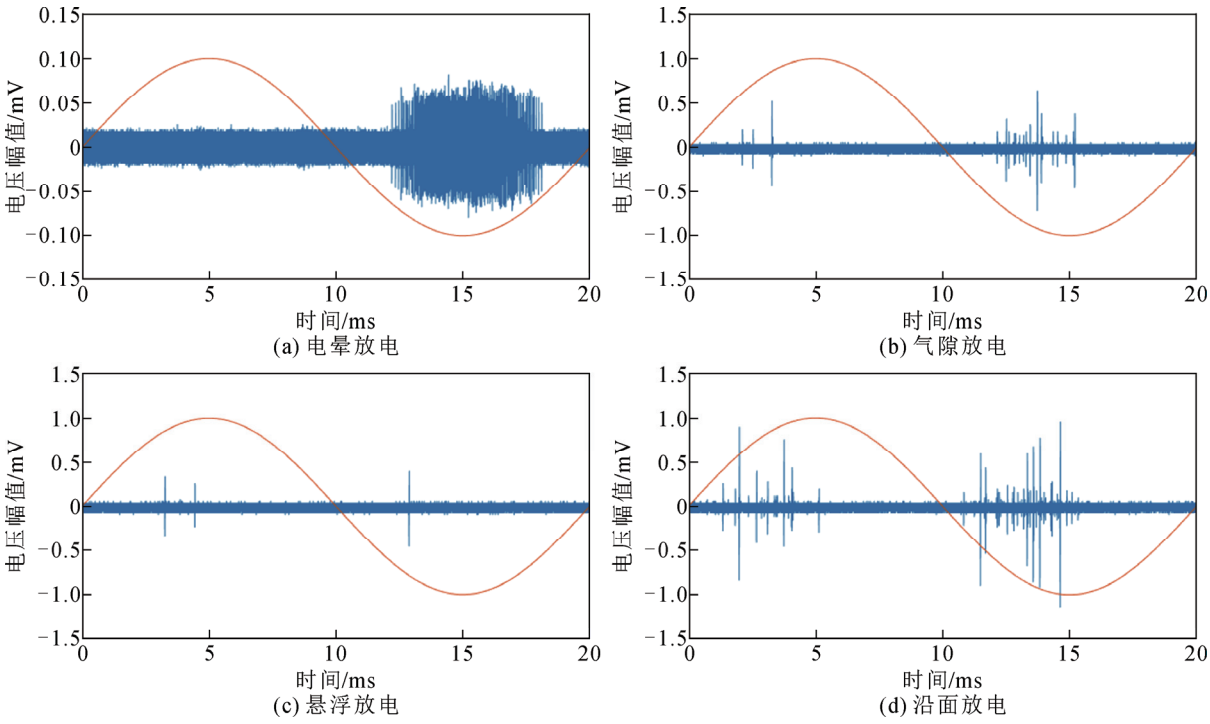


图 9　缺陷模型上测得放电一个工频周期内的时域波形图

Fig.9　Time domain waveform of discharge within one power frequency cycle measured on the defect model

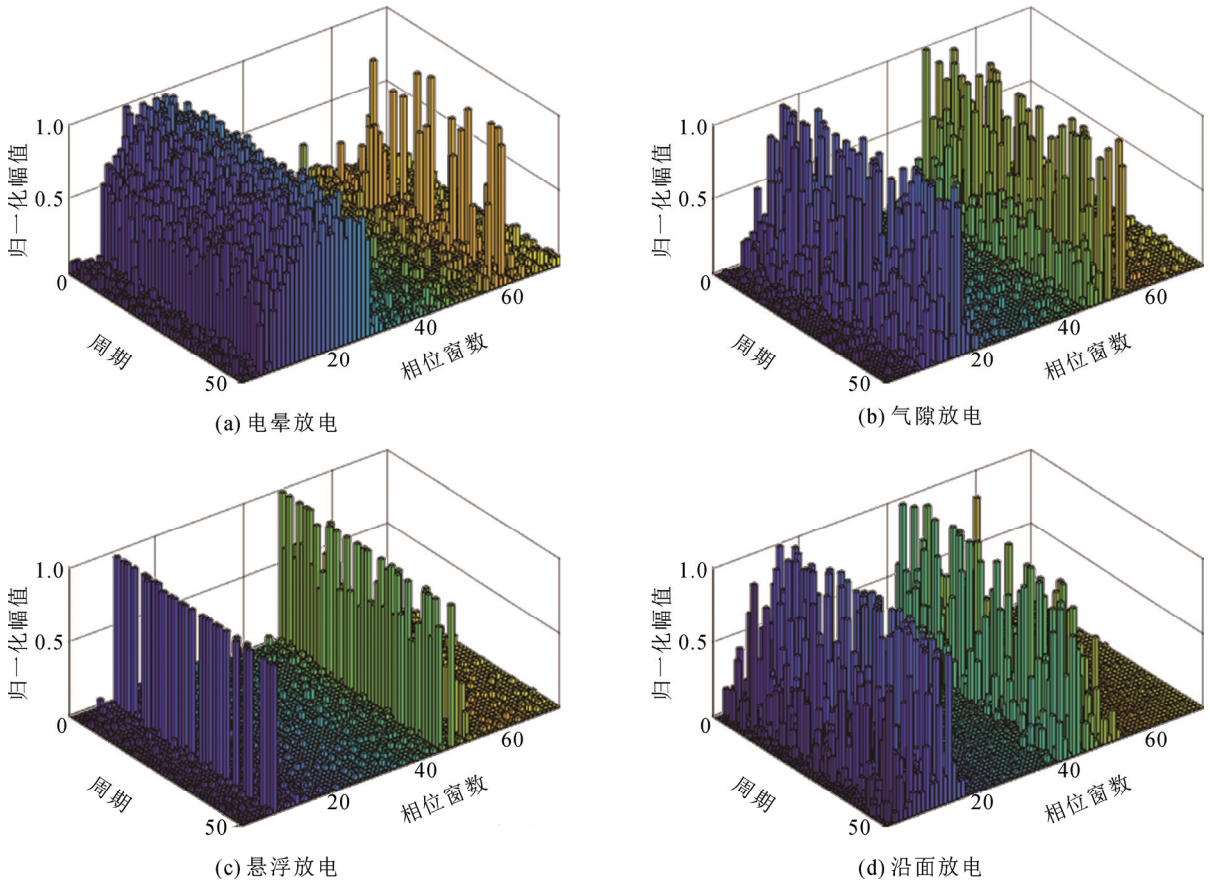
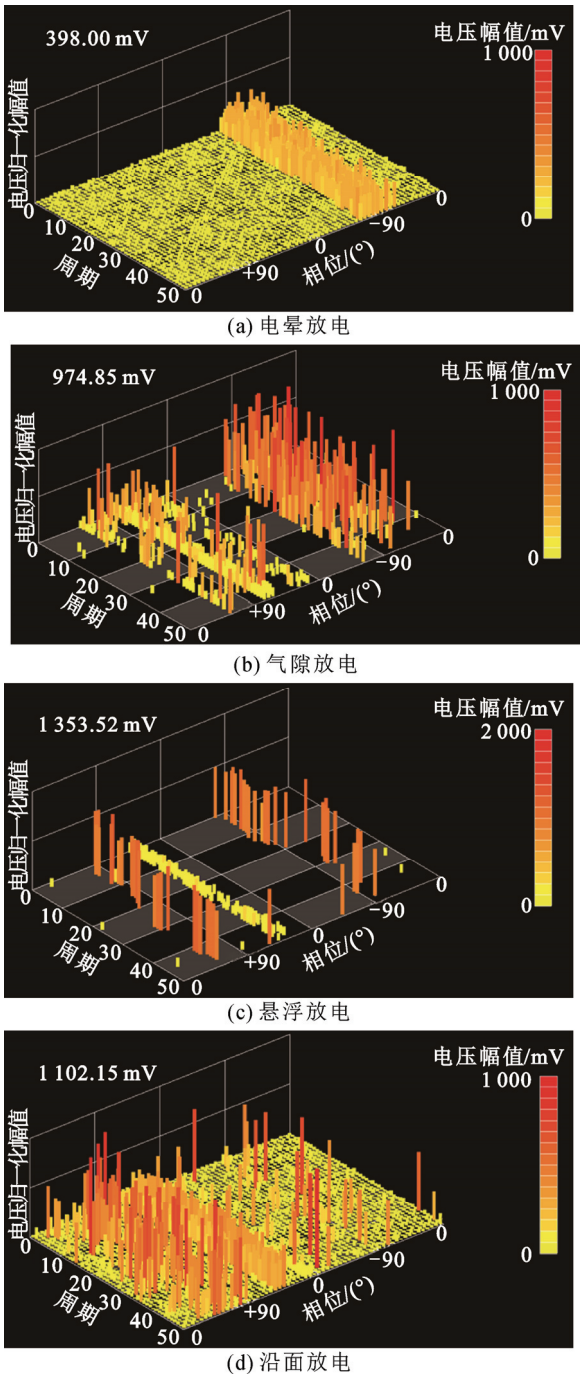


图 10　4 种放电缺陷模型上测得的 PRPS 图谱

Fig.10　PRPS pattern measured on four discharge defect models

原始数据本身就是大小为50×72的PRPS图谱数据，所以可直接进行归一化。由于测量范围是一段时间内的 n 个时间点，n 取决于设备的采集间隔，而设备局放也并非无时无刻都在发生，所以难以保证所有时间点的测量数据均为有效的局部放电数据，考虑到PRPS图谱的数据分布规律，在98%最大归一化后，通过设定一个阈值，将1张图谱中超过96%的数据点都小于0.1或都大于0.9的图谱记为无效图谱，对其进行清洗剔除，将剩下的部分作为优质现场数据集。最终，优质现场数据集数据样本量为2 000个，被清洗掉的无效样本为800个。



(a) 电晕放电

(b) 气隙放电

(c) 悬浮放电

(d) 沿面放电

图11 现场测得的4种放电PRPS图谱

Fig.11 PRPS pattern of four types of discharges measured on-site

3.4 数据集定义

将以上得到的数据样本进行分类以供后续实验使用。局放实验总计获得2 000个实验数据样本，从中分别选取400个和800个作为两种不同大小的训练集，每种放电样本数等量分配(以下称为实验400和实验800)，剩下的1 200个样本作为实验测试集。分出两种不同样本量训练集主要是为了对比样本量下降对识别结果的影响。同样，将优质现场数据随机提取20%和40%，得到的400个和800个样本作为现场数据训练集样本(以下称为现场400和现场800)，剩下的1 200个数据作为通用现场测试集(以下称为通用测试集)，同时，将加入了无效数据样本的测试集作为一般测试集进行对照，以验证问题数据对识别准确率的影响情况，样本数量为2 000个。最后，将现场800和实验800个实验数据合在一起作为训练集(以下称为混合数据集)，进行对照试验。样本分配如表1所示。

4 Swin-T与传统典型深度学习网络效果对比

基于实验数据和现场数据两种数据来源，本文同时针对Swin-T和LeNet、ResNet、DenseNet等多年被广泛应用于图像识别分类、自然语言处理等领域的典型网络在局部放电PRPS数据集上的缺陷识别效果进行对比分析。一组训练测试样本分别使用实验800和实验测试集，另一组分别使用现场800和通用测试集。

所使用的计算平台主要参数为：i7-13700F CPU、RTX3060 12G GPU，算法基于Anaconda3环境下用Python编写，使用的框架为Pytorch。实验数据主要对比了Swin-T、LeNet-5和ResNet-18这3

表1 不同数据集样本量

Table 1 Sample size for different data sets

数据集	名称	样本数
训练集	实验400	400
	实验800	800
	现场400	400
	现场800	800
	混合数据集	1 600
测试集	实验测试集	1 200
	通用测试集	1 200
	一般测试集	2 000

种网络的分类效果。其中，LeNet-5 具有 2 层卷积层和 2 层池化层，属于参数较少的卷积神经网络，ResNet-18 层数较深，有 17 个卷积层，1 个池化层，卷积层之间有残差连接。比较实验中的参数量，LeNet-5 最少，Swin-T 适中，ResNet-18 最多。3 种网络在实验数据上的识别准确率结果如表 2 所示。根据结果可见，3 者在实验数据上的识别能力几乎没有差别，均达到 99%以上，前两者略微高于 Swin-T 的准确率，说明在质量较好的实验数据上，最简单的 LeNet-5 网络即可满足对缺陷模型产生的 PRPS 数据的分类任务。

当把实验数据集换成现场数据集进行测试后，数据特征的复杂程度明显上升，各网络的识别准确率结果如表 3 所示，此时 LeNet-5 和 ResNet-18 网络识别准确率下降到 50.8%和 69.4%，其中 LeNet-5 网络在悬浮放电上的准确率达到 97.7%，比其他网络都高，却在沿面放电上只取得了 18.7%的准确率，并且在混淆矩阵中，如图 12 所示，LeNet-5 将绝大部分其余放电都识别成了悬浮放电，这种极不均衡的准确率差异说明 LeNet-5 网络无法对现场数据进行准确识别，尽管其在实验数据上有着 99.5%的识别准确率。其他 CNN 网络也都多少存在着同样的问题且准确率都不如 Swin-T，其中 ResNet-50 网络相比于 ResNet-18 具有更多的卷积层数，也属于深度残差网络。DenseNet-121 相比于 ResNet-50 层数更深，且引入了密集连接块(Dense Block)，其每层的输出都与前面所有层的输入连接在一起，实现了特征的复用。可以看出在这些网络当中 Swin-T 取得了最高 93.3%的识别准确率，且每种放电的识别准确率都在 90%以上，优势明显。

ResNet 作为最初的残差网络，只是回避了随着卷积网络层数加深出现的网络退化问题，却没能解决 CNN 网络本身难以获取全局特征能力不足的问题，在应对特征不够典型的较复杂的现场数据时难以充分获取数据特征；DenseNet 作为 ResNet 的一个变种，实现了同时利用低层次和高层次的特征，提升了网络效果，但其在沿面放电识别上仍存在不足，且对特征的利用过于频繁，对硬件要求高，不利于现场使用；VIT 由于没有采用分层式构建网络，不易处理图片中的细节，导致其最终结果距离 Swin-T 仍有一定差距，且其相较于 Swin-T 网络计算量太大，无论是处理时间还是模型文件大小都不适合于现场配置使用。

表 2　不同网络在实验数据上的识别准确率

Table 2　Recognition accuracy of different networks on experimental data varies

网络类型	识别准确率(实验测试集)/%
LeNet-5	99.5
ResNet-18	99.7
Swin-T	99.1

表 3　不同网络在现场数据上的识别准确率

Table 3　Identification accuracy of different nets on on-site partial discharge data

训练集	识别准确率(通用测试集)/%				总体准确率/%
	电晕	气隙	悬浮	沿面	
LeNet-5	51.0	35.7	97.7	18.7	50.8
ResNet-18	48.3	87.3	70.0	72.0	69.4
ResNet-50	53.0	86.7	76.0	73.0	72.2
DenseNet-121	96.7	89.7	81.7	65.0	83.3
VIT	90.0	92.0	84.0	91.3	89.3
Swin-T	93.3	93.0	91.0	95.7	93.3

LeNet-5	电晕	气隙	悬浮	沿面	召回率
电晕	153	38	109	0	51.0%
气隙	23	107	170	0	35.7%
悬浮	1	1	293	5	97.7%
沿面	0	3	241	56	18.7%
精确率	86.4%	71.8%	36.0%	91.8%	50.8%

图 12　LeNet-5 网络识别结果的混淆矩阵

Fig.12　Confusion Matrix of LeNet-5 Network

跟同类型的 VIT 相比，Swin-T 因为只针对了局部窗口进行自注意力机制计算，网络参数量明显降低，且由于移动窗口机制的存在，相比起一般 CNN 网络卷积窗口过小导致只能把握局部特征，Swin-T 更能把握局放图谱的整体特征关联，在这方面，DenseNet 的特征重用机制也起到相同效果，但比起残差网络的冗余问题，Swin-T 的机制更简洁明了，每个自注意力块只用了一次移动窗口，提升模型有

效性的同时，更易于现场使用时的模型配置和模型迁移等工作。

5 现场数据与实验数据在 Swin-T 网络上识别的效果对比

本章在 Swin-T 网络上对比了实验数据和现场数据在选定测试集上的识别效果，同时将现场数据和实验数据合在一起，形成混合数据训练集作为对照，以验证实验数据在实际局放模式识别中的作用。

不同数据集下识别准确率的实验结果如图 13 所示，每种放电的识别准确率如表 4 和表 5 所示，每种放电识别在通用测试集上识别结果的混淆矩阵如图 14 所示。首先，单用实验数据集进行 Swin-T 网络训练的情况下，在测试集上的预测准确率较低。在通用测试集上，样本数为 400 时，其平均识别准确率为 70.8%，当把样本数提升至 800 后，其准确率反而下降到 67.42%，对比图 14(a)和(b)混淆矩阵可知，对于悬浮、沿面这两种放电，实验数据模型较难分辨，且在训练集增大后，其误判程度更加严重。在引入一般测试集后，尽管两者总体准确率分别下降至 55.8%和 53.5%，但其关于悬浮和沿面放电的识别准确率几乎没有变化，这说明一般测试集中存在无效数据并不会对网络识别造成影响，也说明通过局放缺陷实验数据训练出来的网络在通用测试集上取得的准确率并不一定可靠，可能难以准确把握实际放电特征。

其次，在引入了现场数据集后，网络的平均识别准确率有大幅提升，在训练样本数量为 400 和 800 时准确率分别达到 90.6%和 93.3%，相比于实验数据有极大提升，且在 4 种放电上的识别准确率均可达到 90%以上。训练样本数量为 400 时的准确率可达到 90%以上，说明 Swin-T 网络在样本量较少的训练集上就可以取得较为理想的效果。

最后，通过对比现场数据集和混合数据集的测试结果可以看出，将两种来源的数据混合后，网络的识别准确率相比只用一种训练集确实得到了一定提升，且这种提升平均分布在了每种放电上。从中不难看出，实验数据集在进行模式识别时其实是起到了贡献作用的，但仅仅只使用实验数据训练的网络却不能取得较好效果。分析其原理，现场所产生的局部放电往往是非典型放电，所产生的 PRPS 图谱不仅仅包含了局放信息，还包含了部分干扰信息，而实验模型却基本只会产生具有单一特征的典型放电，不同输入之间特征差异较小，单纯使用实验数据训练网络会导致网络对信号特征把握不充分，面对更加复杂的分类任务时就会性能不足。而采取在现场数中混入实验数据的方式对网络进行训练时，不仅能够保证网络学习到足量的特征差异，实验数据的放电特征在一定程度上能够使本文网络的自注意力机制更加关注实验数据当中的有效特征，从而提升网络针对测试集的辨识能力。

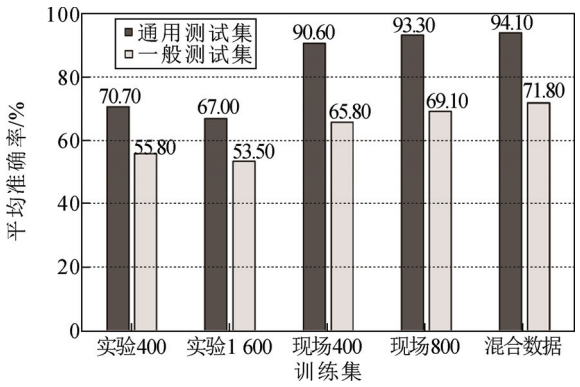


图 13 不同训练集针对两种测试集的识别准确率

Fig.13 Recognition accuracy of different training sets for two test sets

表 4 不同训练集在通用测试集上的识别准确率

Table 4 Recognition accuracy of different training sets on the universal test set

训练集	识别准确率(通用测试集)/%				总体准确率/%
	电晕	气隙	悬浮	沿面	
实验 400	90.0	90.3	23.0	79.3	70.7
实验 1600	93.3	89.3	22.7	62.7	67.0
现场 400	90.0	91.7	84.0	96.7	90.6
现场 800	93.3	93.0	91.0	95.7	93.3
混合数据	95.0	92.7	92.3	96.3	94.1

表 5 不同训练集在一般测试集上的识别准确率

Table 5 Recognition accuracy of different training sets on the general test set

训练集	识别准确率(一般测试集)/%				总体准确率/%
	电晕	气隙	悬浮	沿面	
实验 400	66.0	54.8	25.0	77.2	55.8
实验 1600	73.0	55.8	23.2	61.8	53.5
现场 400	59.0	53.6	64.8	87.6	66.3
现场 800	65.6	54.6	72.2	83.8	69.1
混合数据	72.8	57.6	72.4	84.2	71.8

实验400	电晕	气隙	悬浮	沿面	召回率
电晕	270	0	10	20	90.0%
气隙	2	271	22	5	90.3%
悬浮	23	9	69	199	23.0%
沿面	36	13	13	238	79.3%
精确率	81.6%	92.5%	60.5%	51.5%	70.7%

(a) 实验400

实验1 600	电晕	气隙	悬浮	沿面	召回率
电晕	280	0	10	10	93.3%
气隙	1	268	22	9	89.3%
悬浮	47	0	68	185	22.7%
沿面	101	1	10	188	62.7%
精确率	65.3%	99.6%	61.8%	48.0%	67.0%

(b) 实验1 600

现场400	电晕	气隙	悬浮	沿面	召回率
电晕	270	0	30	0	90.0%
气隙	0	275	24	1	91.7%
悬浮	4	0	252	44	84.0%
沿面	2	0	8	290	96.7%
精确率	97.8%	100.0%	80.3%	86.6%	90.6%

(c) 现场400

现场800	电晕	气隙	悬浮	沿面	召回率
电晕	280	0	20	0	93.3%
气隙	0	279	19	2	93.0%
悬浮	6	0	273	21	91.0%
沿面	3	0	10	287	95.7%
精确率	96.9%	100.0%	84.8%	92.6%	93.3%

(d) 现场800

图 14　4 种不同训练集在通用测试集上识别结果的混淆矩阵

Fig.14　Confusion matrix for identifying results of four different training sets on the universal test set

6　结论

本文将 Swin-T 网络引入局部放电模式识别中，通过实验数据和现场数据对比了 Swin-T 网络同传统方法之间的差异性，得出如下结论：

1）相比于 Resnet、Densenet 及 VIT 等经典网络，Swin-T 在局部放电 PRPS 数据分类识别上准确率提升了 6%~23.3%，证实了使用自注意力机制的 Swin-T 网络可在实际的非典型局部放电 PRPS 图谱的模式识别当中取得相比于传统网络更优的效果，提供了一种不同于传统 CNN 方法的新模式。

2）本文在 Swin-T 网络上使用现场数据训练且测试的分类准确率最高可达 93.3%，相比于实验数据训练并现场数据测试的分类准确率 70.7%，准确率提升了 22.6%，且将两类数据合在一起训练后，每种放电上的识别准确率均有一定提升，总体准确率可以达到 94.1%。该结果表明，实际测得的现场 PRPS 局部放电数据相比实验数据具有更多的非典型特征，且这些特征对识别算法的判断准确率影响较大，同时，仅依靠识别算法来处理这些特征总是有限的，下一步可以考虑从多方面入手来应对这一问题。

3）在训练样本数量为 400 和 800 时，Swin-T 网络对局部放电 PRPS 图谱的识别准确率分别为

90.6%和 93.3%，两者均能达到 90%以上的准确率。这说明 Swin-T 网络在数据量较少的训练集上就可以取得较理想的效果，很适用于现场缺乏局放样本的情形，降低了实际使用时的门槛，更易于变电站现场使用时的模型配置和模型迁移等工作。

参考文献 References

[1] 李军浩，韩旭涛，刘泽辉，等. 电气设备局部放电检测技术述评[J]. 高电压技术，2015，41(8)：2583-2601.
LI Junhao, HAN Xutao, LIU Zehui, et al. Review on partial discharge measurement technology of electrical equipment[J]. High Voltage Engineering, 2015, 41(8): 2583-2601.

[2] 谢 庆，张煊宇，王春鑫，等. 新一代人工智能技术在输变电设备状态评估中的应用现状及展望[J]. 高压电器，2022，58(11)：1-16.
XIE Qing, ZHANG Xuanyu, WANG Chunxin, et al. Application status and prospect of the new generation artificial intelligence technology in the state evaluation of power transmission and transformation equipment[J]. High Voltage Apparatus, 2022, 58(11): 1-16.

[3] 江秀臣，刘亚东，傅晓飞，等. 输配电设备泛在电力物联网建设思路与发展趋势[J]. 高电压技术，2019，45(5)：1345-1351.
JIANG Xiuchen, LIU Yadong, FU Xiaofei, et al. Construction ideas and development trends of transmission and distribution equipment of the ubiquitous power internet of things[J]. High Voltage Engineering, 2019, 45(5): 1345-1351.

[4] 盛戈皞，钱 勇，罗林根，等. 面向新型电力系统的数字化电力设备关键技术及其发展趋势[J]. 高电压技术，2023，49(5)：1765-1778.
SHENG Gehao, QIAN Yong, LUO Lingen, et al. Key technologies and development trends of digital power equipment for new type power system[J]. High Voltage Engineering, 2023, 49(5): 1765-1778.

[5] 江秀臣，许永鹏，李曜丞，等. 新型电力系统背景下的输变电数字化转型[J]. 高电压技术，2022，48(1)：1-10.
JIANG Xiuchen, XU Yongpeng, LI Yaocheng, et al. Digitalization transformation of power transmission and transformation under the background of new power system[J]. High Voltage Engineering, 2022, 48(1): 1-10.

[6] 盛戈皞，钱 勇，罗林根，等. 面向新型电力系统的电力设备运行维护关键技术及其应用展望[J]. 高电压技术，2021，47(9)：3072-3084.
SHENG Gehao, QIAN Yong, LUO Lingen, et al. Key technologies and application prospects for operation and maintenance of power equipment in new type power system[J]. High Voltage Engineering, 2021, 47(9): 3072-3084.

[7] 司良奇，钱 勇，白万建，等. 基于支持向量机的 GIS 超高频局部放电模式识别[J]. 高压电器，2014，50(11)：1-6.
SI Liangqi, QIAN Yong, BAI Wanjian, et al. Pattern recognition of UHF partial discharge for GIS with support vector machine[J]. High Voltage Apparatus, 2014, 50(11): 1-6.

[8] 刘文浩，吴毅江，李文泽，等. 基于随机决策森林的高压电缆局部放电模式识别[J]. 高压电器，2022，58(6)：165-170，177.
LIU Wenhao, WU Yijiang, LI Wenze, et al. Partial discharge pattern recognition of high-voltage cables based on random forest method[J]. High Voltage Apparatus, 2022, 58(6): 165-170, 177.

[9] 宋 辉，代杰杰，张卫东，等. 复杂数据源下基于深度卷积网络的局部放电模式识别[J]. 高电压技术，2018，44(11)：3625-3633.
SONG Hui, DAI Jiejie, ZHANG Weidong, et al. Partial discharge pattern recognition based on deep convolutional neural network under complex data sources[J]. High Voltage Engineering, 2018, 44(11): 3625-3633.

[10] 张 翼，朱永利. 图信号与图卷积网络相结合的局部放电模式识别方法[J]. 中国电机工程学报，2021，41(18)：6472-6480.
ZHANG Yi, ZHU Yongli. A partial discharge pattern recognition method combining graph signal and graph convolutional network[J]. Proceedings of the CSEE, 2021, 41(18): 6472-6480.

[11] 田嘉鹏，宋 辉，罗林根，等. 基于均值漂移的局部放电边缘计算方法研究[J]. 电网技术，2021，45(6)：2449-2456.
TIAN Jiapeng, SONG Hui, LUO Lingen, et al. Edge computing method of partial discharge based on mean-shift[J]. Power System Technology, 2021, 45(6): 2449-2456.

[12] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE, 2021: 9992-10002.

[13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017: 6000-6010.

[14] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.

[15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, USA: IEEE, 2016: 770-778.

[16] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA: IEEE, 2017: 2261-2269.

[17] HUANG X, DONG M J, LI J Y, et al. A 3-D-swin transformer-based hierarchical contrastive learning method for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5411415.

[18] LIN A L, CHEN B Z, XU J Y, et al. DS-TransUNet: dual Swin transformer U-Net for medical image segmentation[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 4005615.

[19] REN T D, XU H Y, JIANG G Y, et al. Reinforced Swin-Convs transformer for simultaneous underwater sensing scene image enhancement and super-resolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 4209616.

[20] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale[J]. arXiv preprint arXiv: 2010.11929, 2020.

[21] 丁 浩，苏志雄，王婷婷，等. 基于脉冲电流和紫外测弧的开关柜局部放电缺陷识别方法[J]. 高电压技术，2022，48(11)：4527-4537.
DING Hao, SU Zhixiong, WANG Tingting, et al. Partial discharge defect identification method of switch cabinet based on pulse current and ultraviolet arc measurement[J]. High Voltage Engineering, 2022, 48(11): 4527-4537.



张雨啸
1998—，男，硕士生
主要从事电力设备状态监测与故障诊断等方面的研究
E-mail: uki_zhang@qq.com

ZHANG Yuxiao



唐 忠(通信作者)
1964—，男，博士，教授
主要从事电力系统运行与控制、电力信息技术、基于电力电子技术的节能技术、电力安全技术等方面的研究
E-mail: tangzhong64@163.com

TANG Zhong
Ph.D., Professor
Corresponding author

收稿日期 2023-10-16 修回日期 2023-12-13 编辑 卫李静