第 49 卷 第 2 期：812-821 高电压技术 Vol.49, No.2: 812-821
2023 年 2 月 28 日 High Voltage Engineering February 28, 2023
**DOI**: 10.13336/j.1003-6520.hve.20220400

# 基于改进 SSD 的 GIS 多源局放模式识别

吴 闽[1]，蒋 伟[1]，罗颖婷[2]，沈道义[3]，杨俊杰[1,4]
（1. 上海电力大学电子与信息工程学院，上海 200090；2. 广东电网有限责任公司电力科学研究院，广州 510080；3. 上海格鲁布科技有限公司，上海 201210；4. 上海电机学院, 上海 201306）

**摘 要**：为了克服局部放电(partial discharge, PD)缺陷诊断中样本数量不足的困难，并解决传统模式识别算法无法有效识别多源局放的缺陷，文中提出了一种基于改进单阶段多框预测算法(single shot multi-box detector，SSD)的气体绝缘组合电器(gas insulated switchgear, GIS)多源局放谱图检测算法。首先，分析了多源局放的相位分布局部放电(phase resolve partial discharge, PRPD)谱图特征，搭建 GIS 实验平台并模拟了 4 种典型局放缺陷，采集样本数据并采用 ACGAN 算法进行样本扩充。然后，搭建了 SSD 网络模型，在特征提取网络中引入了空间与通道注意力机制。最后，利用实验室数据与某 220 kV 变电站收集的现场数据分别验证所提出算法的有效性。实验结果表明，提出的算法能够有效检测出复杂噪声下 PRPD 谱图中的多源局放特征，其实验室数据平均检测精度可达 97.8%，现场数据平均检测精度可达 91.6%。

**关键词**：多源局放；目标检测；PRPD 谱图；SSD；ACGAN

## Multi-source Partial Discharge Pattern Recognition in GIS Based on Improved SSD

WU Min[1], JIANG Wei[1], LUO Yingting[2], SHEN Daoyi[3], YANG Junjie[1,4]
(1. College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. Electric Power Research Institute of Guangdong Power Grid Corporation, Guangzhou 510080, China;
3. Shanghai Gelubu Technology Co., Ltd., Shanghai 201210, China; 4. Shanghai DianJi University, Shanghai 201306, China)

**Abstract**: In order to overcome the difficulty of insufficient sample size in partial discharge (PD) defect diagnosis, and to solve the defect that multi-source PD cannot be effectively identified by traditional pattern recognition algorithms, an improved SSD (single shot multi-box detector)-based multi-source PD map detection algorithm for gas insulated switchgear (GIS) was proposed. Firstly, the PRPD (phase resolve partial discharge) spectral characteristics of multi-source partial discharge were analyzed, GIS experimental platform was built and four typical partial discharge defects were simulated, sample data were collected, and ACGAN was used for sample expansion. Then, an SSD network model was built, and a spatial and channel attention mechanism was introduced into the feature extraction network. Finally, laboratory data and field data collected from a 220 kV substation were used to verify the effectiveness of the proposed algorithm. The experimental results show that the proposed algorithm can be adopted to effectively detect the multi-source partial discharge features in the PRPD spectrum under complex noise. The average detection accuracy of laboratory data can reach 97.8%, and the average detection accuracy of field data can reach 91.6%.

**Key words**: multi-source partial discharge; target detection; PRPD pattern; SSD; ACGAN

## 0 引言

气体绝缘组合电器(gas insulated switchgear, GIS)将断路器和隔离开关等高压设备集成封闭于金属接地的外壳中并充填绝缘气体，是电网运行中重要的一环[1]。由于 GIS 设备受到长期运行中的机械振动等外力因素的影响，绝缘子和气室内不可避免地将出现绝缘缺陷[2]，逐渐累积演变为 GIS 局部放电(以下简称局放)。

据统计，高压设备绝缘性能的劣化是导致其发生事故的主要原因，累积程度严重的局部放电甚至会造成绝缘击穿，导致大面积的停电[3]。特高频检测法由于具有良好的灵敏度和抗干扰性能而适用于 GIS 等高压设备的局放实时监测[4-5]。在 GIS 局放诊断中，局放类型的模式识别一直是一个核心问题。传统的模式识别方法主要以对相位分布局部放电

**基金资助项目**：中国南方电网有限责任公司科技项目(GDKJXM20199427)。Project supported by Science and Technology Project of China Southern Power Grid Co., Ltd. (GDKJXM20199427).

(phase resolve partial discharge, PRPD)谱图手动提取特征(如陡峭度、偏斜度、放电因素等)并放入分类器进行诊断为主[6-8]。近年来深度学习领域掀起了一股热潮，许多学者将基于深度学习的模式识别算法应用在了局放类型识别上[9-12]。文献[13]提出利用卷积神经网络识别局放 PRPD 谱图，通过模型自主提取特征并经过大量图片训练，成功识别出几种典型局放缺陷类型；文献[14]利用深度残差网络进行局放识别，该网络在卷积神经网络中加入了残差模块，解决了网络层数过深模型无法拟合的问题；这些研究无不验证了基于深度学习的模式识别相较于传统方法的优越性。然而，上述方法都是针对单源局放的模式识别，对于多源局放的 PRPD 谱图无法做到有效地分离识别。当多种局放源同时发生时，依然会造成漏检、漏告警的情况。

因此针对目前多源局放识别领域内的空缺，结合单阶段多框预测算法(single shot multi-box detector，SSD)能实现图像局部特征识别的优势，本文提出了一种基于改进 SSD 的 GIS 多源局放谱图检测算法，利用目标检测算法检测 PRPD 谱图的局部特征，从而实现多局放源的分离识别。首先搭建了 GIS 模拟平台构造 4 类典型局放缺陷，分别采集单源与多源局放 PRPD 谱图并利用改进的辅助分类生成对抗网络(auxiliary classifier generative adversarial network, ACGAN)扩充样本生成数据集，投入改进后的 SSD 算法模型中训练，该算法可检测出谱图中每处局放特征并生成目标框，避免了小特征局放被忽略的可能性，实现了多源局放的识别。

## 1　多源局放谱图分析

随着 GIS 运行年限的增长，在其腔室、同轴导体和绝缘子内，容易产生多处局放源，出现多种局放缺陷同时存在的情况[15]。

GIS 结构模拟如图 1 所示，在转角处的盆式绝缘子表面装有外置式特高频传感器，假设在局放源 1 和局放源 2 处同时发生局放且类型不同。由于在实际应用中特高频传感器的动态监测范围约为 40 dB，即若局放源 1 和局放源 2 处发生的特高频信号在传播至特高频传感器过程中的衰减小于 40 dB，都将被传感器采集到并形成 PRPD 谱图[16]。

图 2 为某 220 kV 变电站现场检测到的 PRPD 谱图，横坐标表示放电相位、纵坐标表示放电幅值，颜色由绿到黄到红表示放电次数越来越密集。由于

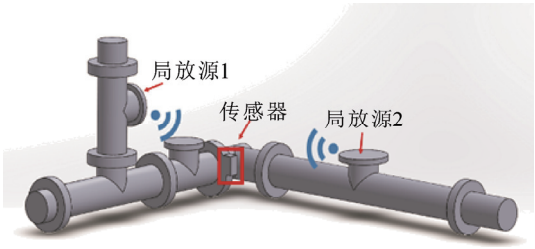



图 1　GIS 结构模拟图

Fig.1　GIS structure simulation

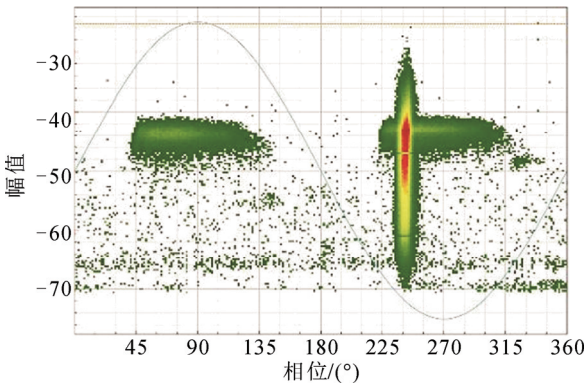



图 2　多源局放 PRPD 谱图

Fig.2　Multi-source PRPD Pattern

GIS 现场进行带电检测时无法连接电压互感器，所以无法获取被测设备的准确工频相位，只能获取其工频频率。因此绝大多数带电检测图谱与真实图谱之间均会发生相位偏移。由图 2 可见：谱图中既出现了两个“云团”形状的特征，幅值相等、相位相差 180°，是典型的浮动电极放电谱图特征；又出现了“尖针”形状的特征，幅值跨度大，相位跨度窄，中心处放电次数多，是典型的电晕放电谱图特征。这验证了 PRPD 谱图同时存在多种局放特征的情况。

目前，主流的模式识别方法本质上都是对 PRPD 谱图的图像分类，模型通过大量单源谱图形成的数据集学习各类局放的特征后，对新输入的谱图整体预测，取概率值最高的分类结果作为输出。当要预测的谱图中出现两种局放类型的特征时，模型无法对谱图的局部特征分别预测，只能通过预测谱图整体的特征进行分类[17]。这就导致了预测多源局放 PRPD 谱图时，网络模型往往会只取特征更显著的一种局放类型作为输出，而忽略另一种局放类型，从而造成漏检、漏告警的情况。

而目标检测算法可以弥补这一缺陷，通过将 PRPD 谱图中的局放特征定义为检测目标，对谱图的局放特征分别检测并在目标处生成预测框，以此实现检测出多源 PRPD 谱图中不同局放特征的目

的。SSD 算法已经广泛应用于车牌识别、口罩检测和安全帽检测等多种场景[18]。

## 2 基于改进 SSD 的 GIS 多源局放谱图检测

针对上述困难，本文提出了一种基于改进 SSD 的 GIS 多源局放谱图检测算法，其流程图如图 3 所示。具体算法步骤如下：

1）首先搭建了 GIS 模拟实验平台并设计构造了 4 种典型局放缺陷。将实验模拟的单源局放 PRPD 谱图作为训练集用于学习各类缺陷的谱图特征，多源局放 PRPD 图谱作为测试集验证算法的有效性。

2）将数据集灰度化后，经由 ACGAN 网络进行样本扩充形成新数据集，解决了样本数量不足的问题。

3）采用 SSD 目标检测算法代替主流模式识别中的图像分类算法，以实现检测出 PRPD 谱图中每处局放特征的目的。

4）在 SSD 网络中加入了空间与通道注意力机制(convolutional block attention module, CBAM)，以适应局放环境中的噪声干扰、提高检测精度。

5）将新训练集投入改进后的 SSD 网络中迭代训练。最后，利用训练权重对测试集进行推理。

### 2.1 ACGAN 样本扩充

样本数量不足一直是阻碍深度学习模式识别的一大难题，由实验采集的数据量不足以支撑深度学习的需求。而由于 PRPD 谱图的格式有严格的标准，故无法使用翻转、镜像、旋转等传统数据增强方法扩充数据集，因此，本文利用改进的 ACGAN 算法实现样本扩充。

辅助分类生成对抗网络(ACGAN)是一种无监督学习算法，通过生成器(generator,G)和判别器(discriminator, D)之间的互相竞争来学习局放样本的分布规律，以生成类似真实局放样本的虚假局放样本[19]。其原理如图 4 所示。

生成器学习局放样本的潜在分布规律，通过采样随机噪声 $z$ 生成虚假局放样本 $G(z)$，再与真实局放样本 $x$ 一起送入判别器由 $D(x)$进行判别，通过 Sigmoid 函数输出判定类别。反向迭代优化 D 和 G 的损失函数，根据 D 的判别结果不断提升 G 的生成质量直至达到收敛，即 D 已经无法判断 G 生成的局放样本的真假性，使得双方对抗达到平衡[20-22]。

同时，本文借鉴了深度残差网络的思想，分别在生成器 G 和判别器 D 的卷积层中引入残差模块，其单元结构如图 5 所示。

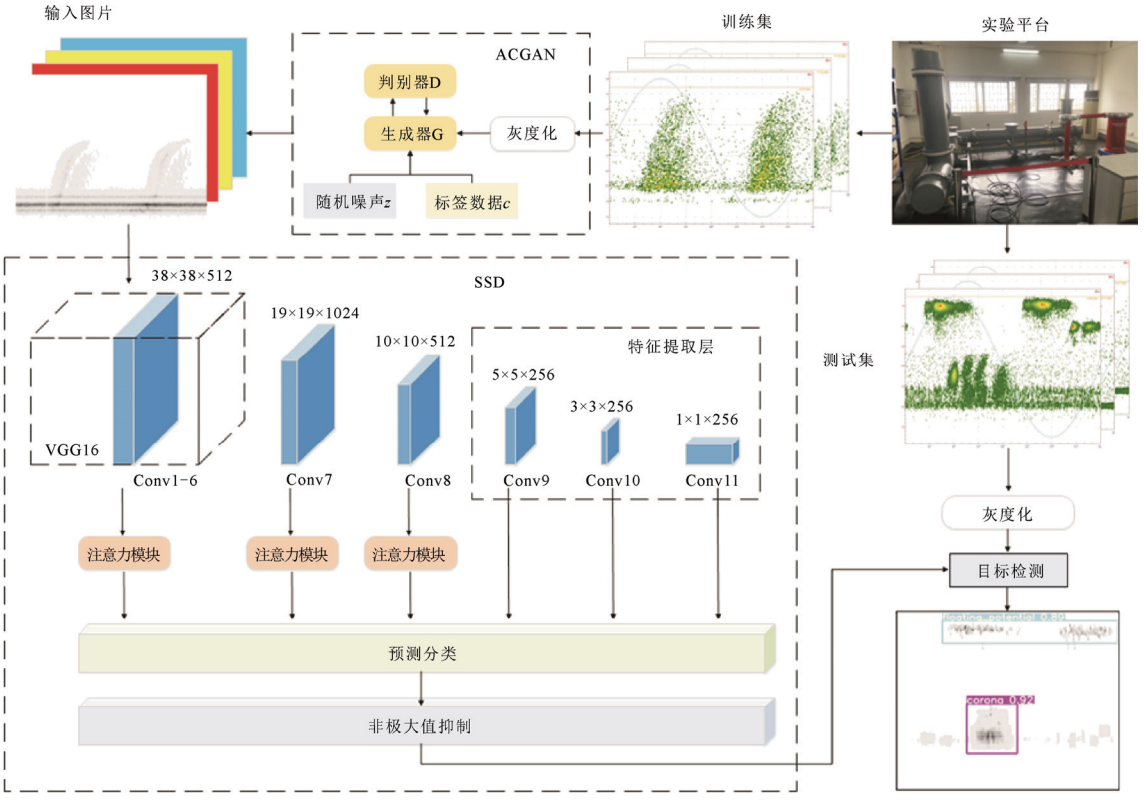



图 3 算法总流程

Fig.3 Algorithm process

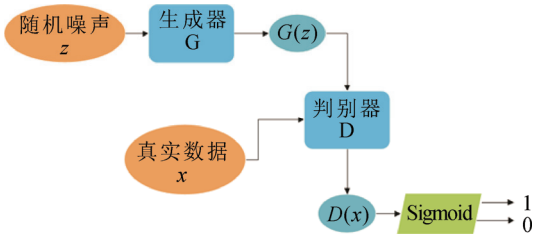



图 4　GAN 网络结构

Fig.4　GAN network structure

假设输入是 $x$，经过卷积层学习的结果是 $f(x)$，期望输出是 $h(x)$，即 $h(x)$是期望的复杂潜在映射。引入恒等映射后，将输入 $x$ 映射到输出作为初始结果，而最终输出结果为 $h(x)=f(x)+x$，当 $f(x)=0$ 时，则 $h(x)=x$。即如果学习后的准确率已经饱和或下降，则保留学习前一次的权重，以保持在后面的层级中不会造成精度下降。

改进后的 ACGAN 网络结构如图 6 所示，为使生成样本的尺寸符合局放样本尺寸，调整了卷积层数量和通道数；引入残差模块，在每两个卷积层之间加入恒等映射连接；生成器卷积层采用 5×5 的卷积核，判别器卷积层采用 5×5 的卷积核。

改进 ACGAN 的目标函数为：

$$L_Y = E[\ln P(\mathrm{F}=F_{\mathrm{real}} \mid X_r)] + E[\ln P(F=F_{\mathrm{fake}} \mid (G(c,z))] \quad (1)$$

$$L_C = E[\ln P(C=c \mid X_r)] + E[\ln P(C=c \mid (G(c,z))] \quad (2)$$

式中：$L_Y$为样本真假性目标函数；$L_C$为分类准确率目标函数；$X_r$代表真实样本；$G(c,z)$代表生成样本；$E[\cdot]$代表数学期望；$C$ 代表标签类别；$P(F \mid X_r)$为真实样本的概率分布；$P(F_{\mathrm{fake}} \mid G(c,z))$为虚假样本的概率分布；$P(F_{\mathrm{real}} \mid X_r)$为真实分类的概率分布；$P(F \mid G(c,z))$为虚假分类的概率分布。该目标函数的优化原则为判别器 D 最大化辨别真假样本的能力并有效分类，生成器 G 最小化真实局放样本和虚假局放样本之间的差异并被有效分类。

## 2.2　SSD 目标检测

本文采用改进后的 SSD 算法检测 PRPD 谱图中的局放特征，SSD 是目标检测中应用广泛的算法，具有高检测精度和良好的实时性。算法原理如图 7 所示。

SSD 采用 Visual Geometry Group 16 (VGG16) 网络作为基础模型(卷积层 1—6)，将 VGG16 原有的两层全连接层转换为卷积层 7—8，并额外增加了卷积层 9—11 用于提取更多的特征图。本文在卷积层 6、7 和 8 后加入了空间与通道注意力机制模块，

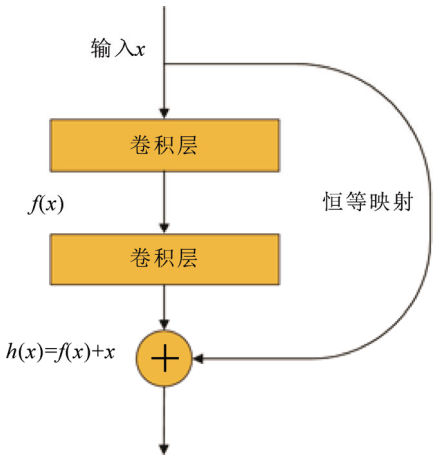



图 5　残差模块单元

Fig.5　Residuals Module

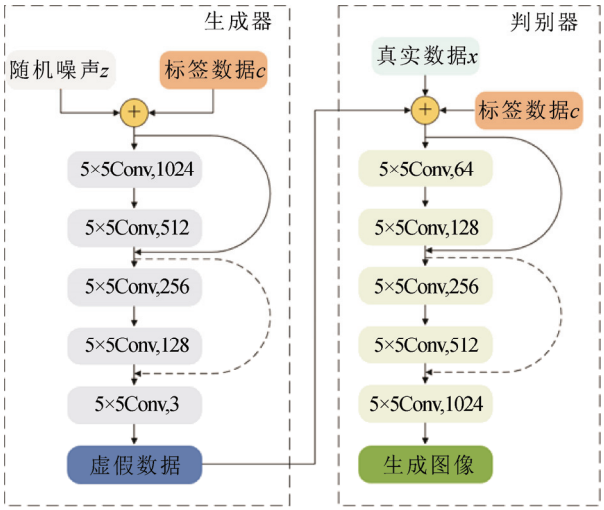



图 6　ACGAN 网络结构

Fig.6　ACGAN network structure

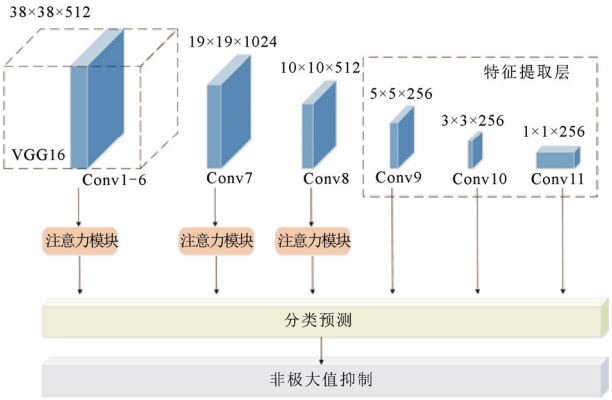



图 7　SSD 网络结构

Fig.7　SSD network structure

用于在复杂背景下加强特征显著性，在下一小节中作出了详细解释。

首先，对训练集进行手动标注，在 PRPD 谱图

中含有局放特征处，标注目标框及其局放类别。经过卷积层提取谱图的特征，得到 6 个不同尺度的特征层，低尺度特征层更为关注大目标的特征(如内部放电、颗粒放电)，高尺度特征图更为关注小目标的特征(如尖端放电、悬浮放电)。

提取到特征映射图后，在特征图的每个单元格上设置不同长宽比及数量的预测框。预测框负责目标的定位及分类，在目标周围生成一定数量的预测框集合以及预测框中目标的类别置信度得分。

最后调整置信度得分阈值和重叠度(intersection over union, IoU)阈值，通过非极大值抑制算法过滤多余的预测框，得到最终输出的预测框。其中，IoU 为预测框与训练集中手动标注的真实框之间的重叠率。以悬浮放电+尖端放电为例，如图 8 所示。

该算法的损失函数包括目标分类损失函数和目标定位损失函数，具体计算公式如下：

$$L(x,c,p,r)=\frac{1}{N}(L_{\text{con}}(x,c)+\alpha L_{\text{loc}}(x,p,r)) \tag{3}$$

式中：$c$ 为局放类别；$p$ 为预测框；$r$ 为真实框；$N$ 为生成预测框的数量；$\alpha$ 为分类与定位损失函数之间的权重比，默认设置为 1；$L_{\text{con}}$ 和 $L_{\text{loc}}$ 分别表示分类损失函数和定位函数，计算式为

$$L_{\text{con}}(x,c)=-\sum_{i\in P_{\text{os}}}x_{ij}^{p}\ln(c_i^{p})-\sum_{i\in N_{\text{eg}}}\ln(c_i^{0}) \tag{4}$$

$$L_{\text{loc}}(x,p,r)=\sum_{i\in P_{\text{os}}}\sum_{n\in\{c_x,c_y,w,h\}}x_{ij}^{k}S(p_i^{n}-r_j^{n}) \tag{5}$$

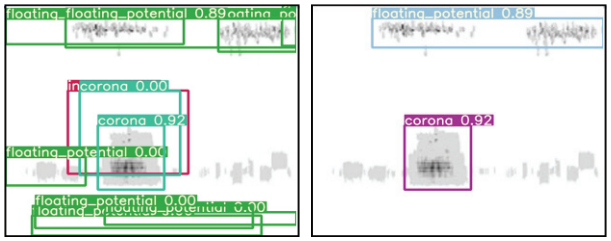
$$S(x)=\begin{cases}0.5x^2, & |x|<1\\ |x|-0.5, & |x|\geq 1\end{cases}$$

式中：$x_{ij}^{p}$ 表示对于类别 $p$，第 $i$ 个预测框与第 $j$ 个真实框的匹配，取值为 0 或 1；$x_{ij}^{p}$=1 为正样本匹配，$x_{ij}^{p}$=0 为负样本匹配；$P_{\text{os}}$ 为正样本预测框的集合；$N_{\text{eg}}$ 为负样本预测框的集合；$S(x)$为平滑损失；$c_x$ 和 $c_y$ 分别为预测框相对于 PRPD 谱图原点的坐标位置；$w$ 和 $h$ 分别为预测框的长和宽。

### 2.3 CBAM 注意力机制

在实际变电站环境中，会存在如通讯噪声、振动噪声等多种干扰。为了降低噪声形成的谱图对局放谱图的干扰，同时加强局放谱图的特征显著性。本文在 SSD 网络中引入了空间与通道注意力机制(CBAM)，在卷积层 6、7 和 8 后面加入 CBAM 模块。其结构如图 9 所示。

注意力机制本质上是根据局放特征的重要程




(a) 初始预测框 (b) 过滤后预测框

图 8 非极大值抑制

Fig.8 Non-maximum suppression

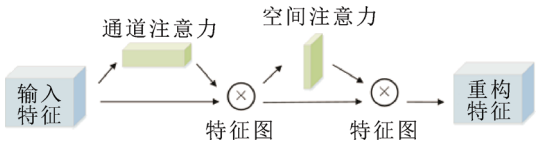



图 9 CBAM 网络结构

Fig.9 CBAM network structure

度进行不同的权重分配[23]。在通道注意力机制中，首先进行全局平均池化和全局最大池化，经由两层权值共享的全连接层后通过 sigmoid 函数得到通道权值系数，加权后得到最终输出的特征映射图。其计算式如下：

$$M_{\text{c}}(F)=\sigma(M_{\text{AvgPool}}(F)+M_{\text{MaxPool}}(F))=\sigma(W_1(W_0(F_{\text{avg}}^{\text{c}}))+\sigma(W_1(W_0(F_{\text{max}}^{\text{c}})) \tag{6}$$

式中：$\sigma$ 表示 sigmoid 函数；$F$ 表示输入特征；$M_{\text{AvgPool}}$ 表示全局平均池化；$M_{\text{maxPool}}$ 表示全局最大池化；$W_0$ 和 $W_1$ 分别表示全连接层中的隐藏层权重和输出层权重；$F_{\text{avg}}^{\text{c}}$ 和 $F_{\text{max}}^{\text{c}}$ 分别表示平均池化和最大池化的特征。

在空间注意力机制中，同样先进行一个通道维度的最大池化和平均池化，然后将这两个特征映射图在通道维度拼接起来，经过卷积后输出的特征映射图单通道，最后通过 Sigmoid 函数生成空间权重系数，分别与输入特征映射图相乘得到最终特征映射图。其计算式为

$$M_s(F)=\sigma(f^{7\times7}([M_{\text{AvgPool}}(F);M_{\text{MaxPool}}(F)]))=\sigma(f^{7\times7}([F_{\text{avg}}^{S};F_{\text{max}}^{S}])) \tag{7}$$

式中：$f^{7\times7}$ 表示卷积核为 7×7 的卷积运算；$F_{\text{avg}}^{S}$ 和 $F_{\text{max}}^{S}$ 分别表示平均池化和最大池化的特征；$[F_{\text{avg}}^{S};F_{\text{max}}^{S}]$表示将两个特征图在通道维度拼接起来；$[M_{\text{AvgPool}}(F);M_{\text{MaxPool}}(F)]$同理可知。

图 10 为加入空间与通道自注意力机制前后的

特征映射图对比。图 10(a)为灰度化处理后的多源谱图，图中包含内部放电和悬浮放电两种谱图特征。在算法预测分类时，将根据谱图中各特征的显著程度分配权重，颜色由蓝到绿到红，越深代表特征越显著。由图 10(b)和 10(c)对比可明显看出在加入 CBAM 模块后，算法将更多的注意力分配到了局放信号对应的谱图处，同时放电中心处呈密集的红色，而内部放电周围的背景噪声所对应的谱图颜色更浅。验证了空间与通道自注意力机制有助于提高目标的特征显著性。

## 3　实验分析

本章节搭建了 GIS 模拟实验平台，通过实验室生成的谱图和现场采集的谱图分别验证该算法的有效性。

### 3.1　实验平台搭建及数据采集

本文搭建了 GIS 模拟实验平台并设计构造了 4 种典型 GIS 局放缺陷模型。图 11 为实验平台的示意图，GIS 外壳直径约为 560 mm，内部同轴导体直径约为 160 mm。在每个间隔表面安装外置式特高频传感器，保证数据多样性，采样频率为 300 MHz~1.5 GHz。采用 YWDT–12/120 kV 工频无晕试验变压器作为外施电压，对腔体逐级加压试验。

由于本文暂时仅讨论两种类型的局放缺陷同时存在的情况，因此仅在两个模拟气室内设置局放缺陷。采用长度约为 25 mm 的铜针贴于同轴导体表面模拟电晕放电；在腔体内放置一些金属颗粒以模拟颗粒放电；采用松动螺丝模拟浮动电极放电；在导体内制造绝缘空穴以模拟内部气隙放电。首先在一个气室内设置 4 类单源局放缺陷，收集其谱图形成训练集，用于训练模型学习谱图特征。接着在两个气室内分别设置两种不同类型的局放缺陷，两两组合，共 6 种叠加谱图类型，收集其谱图形成测试集，用以验证本文算法的有效性。为保证实验的严谨性与数据的复杂多样性，改变缺陷位置进行多次实验。

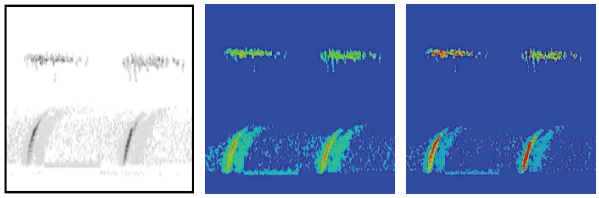
### 3.2　实验室数据分析

由实验采集的多源局放 PRPD 谱图共 756 张，其中电晕+悬浮放电 154 张、电晕+内部放电 126 张、电晕+颗粒放电 184 张、悬浮+内部放电 137 张、悬浮+颗粒放电 155 张，如表 1 所示。由于各厂家对于 PRPD 谱图的保存颜色和格式各不相同，为避免颜色不同对模型检测产生影响，统一将训练集和测试转化为灰度图，并调整模型内的相应通道数。

表 1 为数据集分布统计，由 GIS 模拟实验平台采集的单源局放 PRPD 谱图共 1033 张，其中电晕放电 291 张、悬浮放电 213 张、内部放电 236 张、颗粒放电 293 张。经过 ACGAN 网络扩充至 4233 张，其中电晕放电 1091 张、悬浮放电 1013 张、内部放电 1036 张、颗粒放电 1093 张。

实验中 ACGAN 网络和 SSD 网络的训练均在 pytorch 框架下进行，环境配置参数为：GPU GeForce RTX 2060 Ti；CPU AMD Ryzen 7 4800H；操作系统为 Win10；CUDA 10.1；opencv 4.5.5。

利用 ACGAN 网络进行样本扩充时，首先将输入图片调整尺寸至 640×640，迭代次数 Epoch 设置



(a) 原图　(b) 未加入 CBAM　(c) 加入 CBAM 后

图 10　特征映射图

Fig.10　Feature map

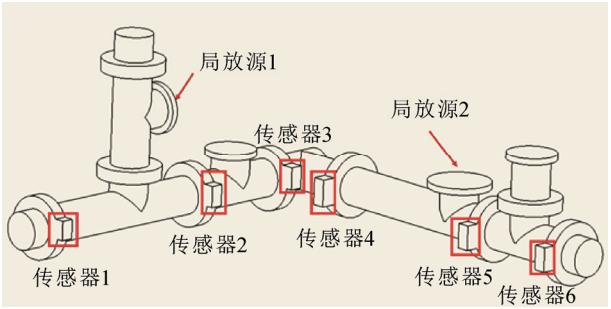



图 11　GIS 局部放电实验平台

Fig.11　GIS PD experimental platform

表 1　数据集分布

Table 1　Data set distribution

| 局放类型 | 放电类型 | 采集数量 | 扩充数量 |
|---|---|---|---|
| 单源局放 | 电晕放电 | 291 | 1091 |
| | 悬浮放电 | 213 | 1013 |
| | 内部放电 | 236 | 1036 |
| | 颗粒放电 | 293 | 1093 |
| | 合计 | 1033 | 4233 |
| 多源局放 | 电晕+悬浮 | 154 | |
| | 电晕+内部 | 126 | |
| | 电晕+颗粒 | 184 | |
| | 悬浮+内部 | 137 | |
| | 悬浮+颗粒 | 155 | |
| | 合计 | 756 | |

为 100 轮，生成器学习率设置为 0.004，判别器学习率设置为 0.001，使用 Adam 优化器加速训练，beta1 设置为 0.5，batch size 设置为 16，每一批次训练 16 张图片，如表 2 所示。由表中可知，第一轮训练时，网络输出为随机噪声，无明显规律。训练 50 轮后，各类局放谱图特征初具雏形，规律仍不明显且背景包含大量噪点。训练 100 轮后，各类局放谱图相位分布特征显著，规律明显，符合实验预期要求。

将 ACGAN 生成的新数据集投入到 SSD 网络中训练，按 8：2 的比例划分训练集和验证集。设置各项参数，迭代次数设置为 500 轮，前 300 轮学习率为 0.01，后 200 轮学习率为 0.001，每一批训练尺寸为 16 张样本图像。

使用该网络对测试集进行检测，检测效果如图 12 所示，在各谱图特征处分别产生了目标框，并且在目标框上显示相应标签，成功识别出两种局放类型，符合实验预期。

定义各项评价指标：平均检测精度(mAP)、准确率(Precision)、召回率(Recall)和损失函数(Loss)，具体计算公式如下：

$$P_{\mathrm{mA}}=\frac{\sum_{i=1}^{N}P_{\mathrm{A}i}}{N} \tag{5}$$

$$R=\frac{N_{TP}}{N_{TP}+N_{FN}} \tag{6}$$

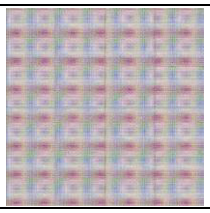
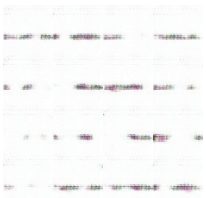
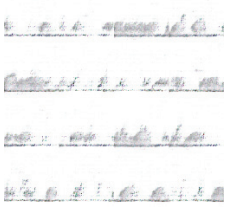
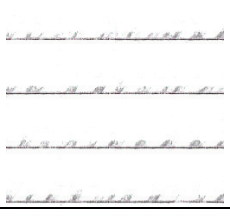
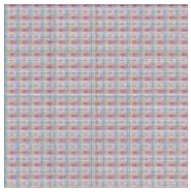
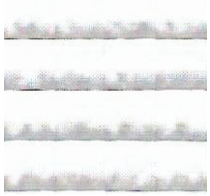
$$P=\frac{N_{TP}}{N_{TP}+N_{FP}} \tag{7}$$

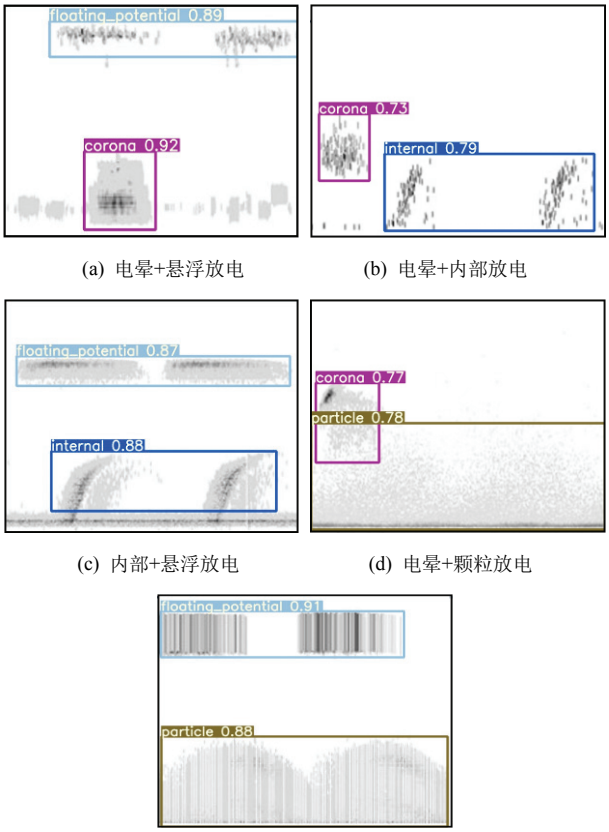
式中：$P_{\mathrm{mA}}$ 为平均检测精度；$P$ 为准确率；$R$ 为召回率；$N_{\mathrm{TP}}$、$N_{\mathrm{FP}}$ 和 $N_{\mathrm{FN}}$ 分别表示正确检测数、误检数和漏检数；$P_{\mathrm{A}i}$ 为 $P$-$R$ 曲线积分；$N$ 为检测类别的数量。

图 13 为训练过程中的平均检测精度曲线，纵坐标为 mAP_0.5，mAP_0.5 表示在 IoU 取 0.5 时的 mAP，横坐标为迭代轮数。由图可知本算法具有高精度，经过 100 轮迭代后 mAP 上升了 90%，之后陡降至 80%，本文推测是由于谱图特征差异性造成的，由于不同变电站环境不同，局放缺陷的幅值、相位、发生环境和发展程度各有差异，导致同一类型局放所产生的谱图特征也具有差异性，对网络学习特征造成一定的困难。经过 200 轮迭代后曲线基本收敛且十分平滑，mAP 值也高达 97.8%。

表 2 ACGAN 生成样本

Table 2 Samples generated by ACGAN

| 局放类型 | 真实样本 | Epoch=1 | Epoch=50 | Epoch=100 |
|---|---|---|---|---|
| 电晕放电 |  |  |  |  |
| 悬浮放电 |  |  |  |  |
| 内部放电 |  |  |  |  |
| 颗粒放电 |  |  |  |  |




(a) 电晕+悬浮放电　(b) 电晕+内部放电

(c) 内部+悬浮放电　(d) 电晕+颗粒放电

(e) 悬浮+颗粒放电

图 12　检测效果图

Fig.12　Detection effect

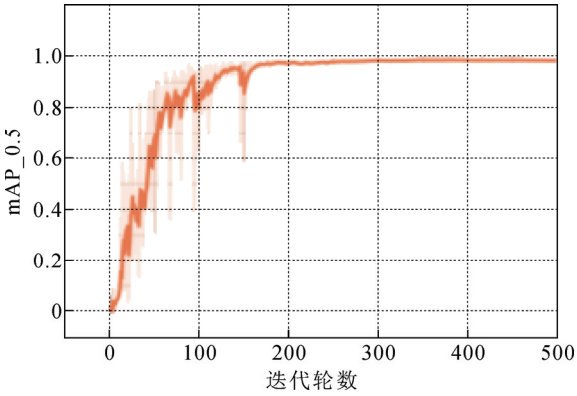



图 13　平均检测精度

Fig.13　mAP_0.5

图 14 为网络加入空间与通道注意力机制的前后对比，如图中所示，加入 CBAM 后准确率显著提高，高达 97%；召回率在 150 轮后也达到收敛，有略微提高；损失函数降至 0.013。综上所述，加入空间与通道注意力机制各项评价指标均有提升，收敛速度加快。

图 15 为 SSD 网络的混淆矩阵，纵轴代表预测的局放类别，横轴代表真实样本的局放类别，颜色越深代表数量越多。如图中所示，电晕放电有 97% 预测正确，3%漏检；悬浮放电有 96%预测正确，4% 漏检；内部放电和颗粒放电均全部预测成功，无互相混淆的情况。

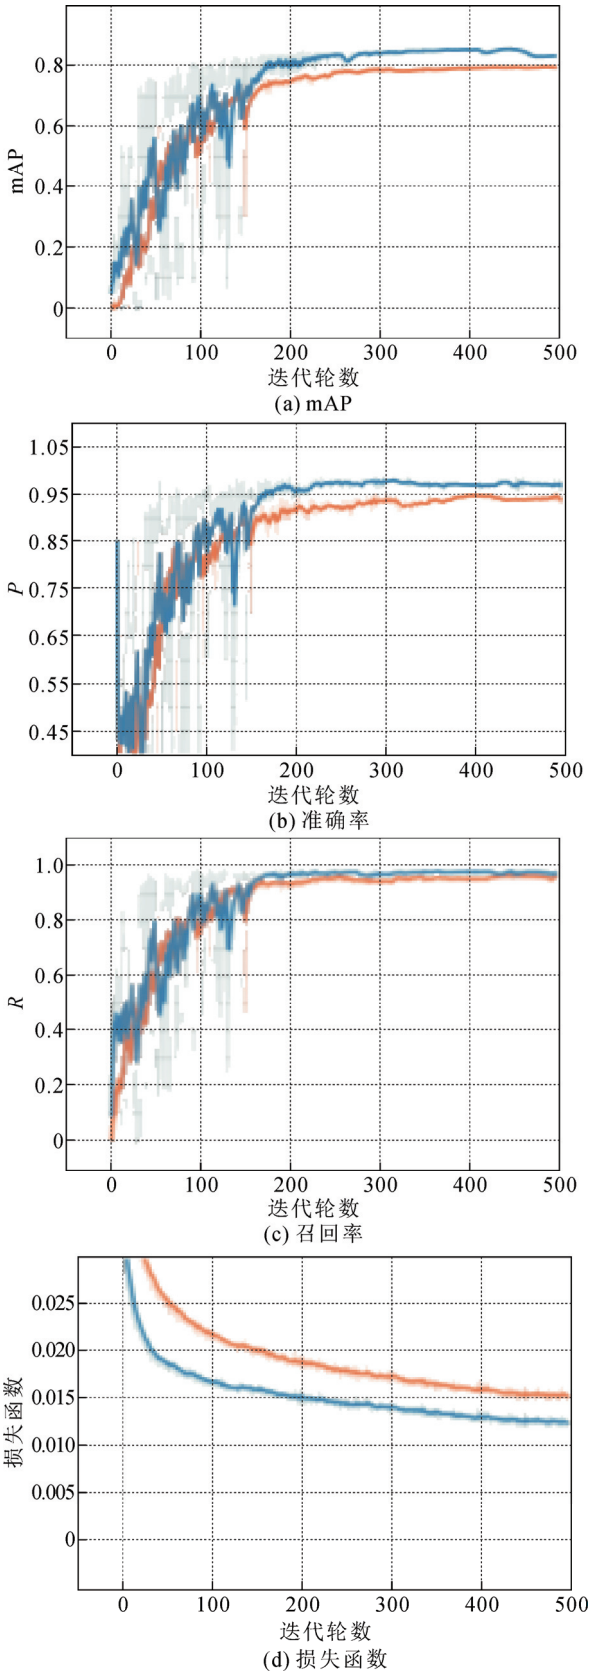



图 14　加入 CBAM 前后对比

Fig.14　Before and after joining CBAM

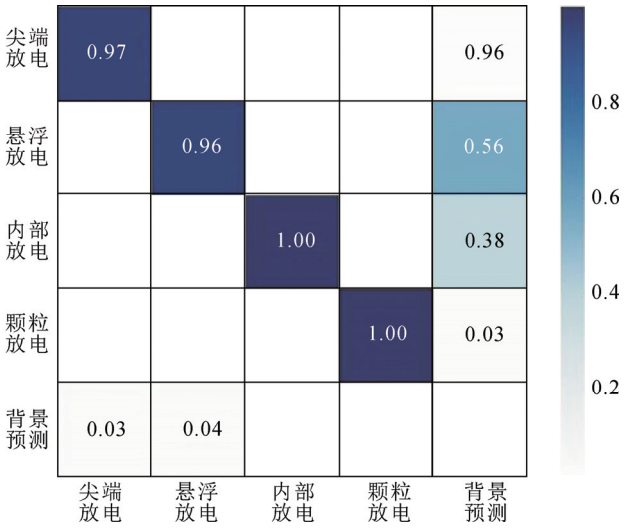



图 15 混淆矩阵

Fig.15 Confusion matrix

表 3 为使用各目标检测算法分别对数据集进行训练及预测，Yolo 和 Yolov2 作为相对较早提出的算法，在检测精度上有所欠缺，其 mAP 仅 82%和 85%; Yolov3 在同样引入 CBAM 模块后检测精度略高于普通 SSD，可达 96.5%，但低于引入 CBAM 模块的 SSD；同时，SSD 网络因其轻量化而实时性最强，单张图像预测时间最短。故经过各算法对比，引入 CBMA 机制的 SSD 算法效果最优。

### 3.3 现场数据分析

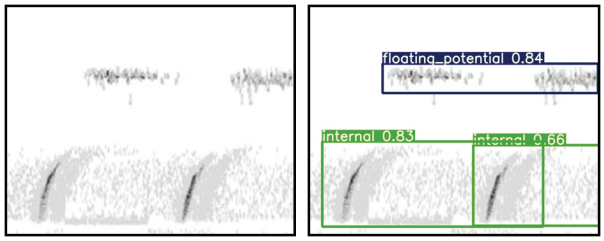
为了进一步验证该算法在实际工程应用中的有效性，利用现场数据作为测试集再次实验。现场谱图数据来源于珠海某 220 kV 变电站，经过长期带电运行期间在线监测得到，谱图库由 GIS 在线监测装置的厂家提供。该站于每个间隔的母线侧三相开关与线路侧三相开关均安装有特高频传感器。

经过手动筛选清洗无效谱图(如无放电谱图、不完整谱图)后，共收集 500 张现场 PRPD 谱图，其中 477 张为单源局放谱图，23 张为多源局放谱图，将谱图经过灰度化处理，利用该算法对测试集进行检测后由人工统计结果。实验结果如表 4 所示，由于实际变电站噪声较为复杂，噪声所形成的谱图与局放信号所形成的谱图重叠面积较大，部分局放谱图特征不显著，检测精度有所下降，成功检测率仍能达到 91.6%。以内部放电和悬浮放电的叠加谱图为例，如图 16 所示，图 16(a)为经过灰度化处理的多源谱图，图 16(b)为算法检测结果。尽管 PRPD 谱图中存在部分噪声影响，算法仍然成功识别出悬浮放电与内部放电所形成的谱图，符合实验预期。

表 3 各算法对比

Table 3 Comparison of versions

| 算法 | mAP | 单张预测时间/s |
|---|---|---|
| Yolo | 0.82 | 0.015 |
| Yolov2 | 0.85 | 0.011 |
| Yolov3 | 0.933 | 0.007 |
| Yolov3+CBAM | 0.965 | 0.007 |
| SSD | 0.952 | 0.006 |
| SSD+CBAM | 0.978 | 0.006 |




(a) 多源谱图 (b) 算法检测结果

图 16 多源局放谱图

Fig.16 Multi-resource PD pattern

表 4 检测结果统计

Stable 4 Test result statistics

| 局放类型 | 缺陷个数 | 检测个数 | 检测率 |
|---|---|---|---|
| 电晕放电 | 112 | 102 | 0.91 |
| 悬浮放电 | 124 | 111 | 0.89 |
| 内部放电 | 87 | 75 | 0.86 |
| 颗粒放电 | 154 | 150 | 0.97 |
| 悬浮+尖端 | 14 | 13 | 0.92 |
| 内部+悬浮 | 9 | 7 | 0.77 |
| 合计 | 500 | 458 | 0.916 |

## 4 结论

1）提出了一种基于改进 SSD 的 GIS 多源局放谱图检测算法，实验采集 1033 张谱图，经 ACGAN 算法扩充至 4233 张，经算法检测后目标精度可达 97.8%。

2）利用某 220kV 变电站现场数据验证该算法的有效性，成功检测出多源局放缺陷，平均检测率可达 91.6%，具有良好的鲁棒性。

3）当某些噪声相位分布过大，与局放谱图重叠甚至覆盖时，对目标检测造成阻碍，后期将针对该问题展开进一步研究。

## 参考文献 References

[1] 许 渊，刘卫东，陈维江，等. 基于高灵敏测量的 GIS 绝缘子表面微金属颗粒局部放电特性[J]. 高电压技术，2019，45(9)：2707-2714.

XU Yuan, LIU Weidong, CHEN Weijiang, et al. Partial discharge characteristics of metal particles on spacer surface in GIS based on high sensitivity measurement[J]. High Voltage Engineering, 2019, 45(9): 2707-2714.

[2] 金　虎. 基于多参量的 GIS 局部放电发展过程研究及严重程度评估[D]. 北京：华北电力大学，2015.
JIN Hu. GIS partial discharge development process research and its severity evaluation based on the multiple parameters[D]. Beijing, China: North China Electric Power University, 2015.

[3] PENG X S, YANG F, WANG G J, et al. A convolutional neural network-based deep learning methodology for recognition of partial discharge patterns from high-voltage cables[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1460-1469.

[4] 郑闻文，李功新，舒胜文. GIS 局部放电 UHF 检测系统性能检验方法研究进展[J]. 电气技术，2016，17(10)：1-7.
ZHENG Wenwen, LI Gongxin, SHU Shengwen. Review of calibration methods for UHF detection system performance of GIS partial discharge[J]. Electrical Engineering, 2016, 17(10): 1-7.

[5] 李　通，薛　峰. UHF 局放检测技术在 GIS 故障诊断中应用与分析[J]. 供用电，2018，35(12)：80-88.
LI Tong, XUE Feng. Application and analysis of UHF partial discharge detection technology in GIS fault diagnosis[J]. Distribution & Utilization, 2018, 35(12): 80-88.

[6] BASHARAN V, SILUVAIRAJ W I M, VELAYUTHAM M R. Recognition of multiple partial discharge patterns by multi-class support vector machine using fractal image processing technique[J]. IET Science, Measurement &Technology, 2018, 12(8): 1031-1038.

[7] 张新伯，唐　炬，潘　成，等. 用于局部放电模式识别的深度置信网络方法[J]. 电网技术，2016，40(10)：3272-3278.
ZHANG Xinbo, TANG Ju, PAN Cheng, et al. Research of partial discharge recognition based on deep belief nets[J]. Power System Technology, 2016, 40(10): 3272-3278.

[8] 饶章权，郑书生，王增彬，等. 负极性 OLIV 下 GIS 局部放电 UHF 信号的相位特征[J]. 高电压技术，2019，45(12)：3924-3931.
RAO Zhangquan, ZHENG Shusheng, WANG Zengbin, et al. Phase characteristics of UHF signals radiated by partial discharges in GIS under negative oscillating lightning impulse voltage[J]. High Voltage Engineering, 2019, 45(12): 3924-3931.

[9] BARRIOS S, BULDAIN D, COMECH M P, et al. Partial discharge classification using deep learning methods—Survey of recent progress[J]. Energies, 2019, 12(13): 2485.

[10] GU F C. Identification of partial discharge defects in gas-insulated switchgears by using a deep learning method[J]. IEEE Access, 2020, 8: 163894-163902.

[11] KARIMI M, MAJIDI M, MIRSAEEDI H, et al. A novel application of deep belief networks in learning partial discharge patterns for classifying corona, surface, and internal discharges[J]. IEEE Transactions on Industrial Electronics, 2020, 67(4): 3277-3287.

[12] 王雨萌，孙长海，赵树春，冯晓东，韩寅峰. 基于改进的 Wasserstein 生成对抗网络和深度残差网络的电缆中间接头局部放电缺陷识别[J]. 科学技术与工程，2022，22(35)：15650-15658.
WANG Yumeng, SUN Changhai, ZHAO Shuchun, FENG Xiaodong, HAN Yingfeng, et al. Partial discharge defect identification of cable intermediate joint based on improved Wasserstein generation antagonism network and deep residual network[J]. Science Technology and Engineering, 2022, 22(35): 15650-15658.

[13] WANG L H, HOU K, TAN L Q. Research of GIS partial discharge type evaluation based on convolutional neural network[J]. AIP Advances, 2020, 10(8): 085305.

[14] BORGHEI M, GHASSEMI M. A deep learning approach for discrimination of single- and multi-source corona discharges[J]. IEEE Transactions on Plasma Science, 2021, 49(9): 2936-2945.

[15] 朱永利，张　翼，蔡炜豪，等. 基于辅助分类–边界平衡生成式对抗网络的局部放电数据增强与多源放电识别[J]. 中国电机工程学报，2021，41(14)：5044-5053.
ZHU Yongli, ZHANG Yi, CAI Weihao, et al. Data augmentation and pattern recognition for multi-sources partial discharge based on boundary equilibrium generative adversarial network with auxiliary classifier[J]. Proceedings of the CSEE, 2021, 41(14): 5044-5053.

[16] 吴诗优，郑书生，钟爱旭，等. 基于智能聚类算法的 UHF 法变电站空间多源局部放电定位方法[J]. 高电压技术，2020，46(12)：4309-4318.
WU Shiyou, ZHENG Shusheng, ZHONG Aixu, et al. Location method of multiple partial discharges sources in substation space by UHF method based on intelligent clustering algorithm[J]. High Voltage Engineering, 2020, 46(12): 4309-4318.

[17] 许辰航，陈继明，刘伟楠，等. 基于深度残差网络的 GIS 局部放电 PRPD 谱图模式识别[J]. 高电压技术，2022，48(3)：1113-1123.
XU Chenhang, CHEN Jiming, LIU Weinan, et al. Pattern recognition of partial discharge PRPD spectrum in GIS based on deep residual network[J]. High Voltage Engineering, 2022, 48(3): 1113-1123.

[18] 李瑞生，张彦龙，翟登辉，等. 基于改进 SSD 的输电线路销钉缺陷检测[J]. 高电压技术，2021，47(11)：3795-3802.
LI Ruisheng, ZHANG Yanlong, ZHAI Denghui, et al. Pin defect detection of transmission line based on improved SSD[J]. High Voltage Engineering, 2021, 47(11): 3795-3802.

[19] 卢锦玲，朱晨菲. 基于改进 ACGAN 样本增强的变压器故障诊断技术[J]. 电力科学与工程，2021，37(11)：42-51.
LU Jinling, ZHU Chenfei. Power transformer fault diagnosis technology based on improved ACGAN data augmentation[J]. Electric Power Science and Engineering, 2021, 37(11): 42-51.

[20] 杨光友，刘　浪，习晨博. SA-ACGAN 样本生成模型及轴承故障诊断应用研究[J/OL]. 中国机械工程：1-11[2022-03-26].
YANG Guangyou, LIU Lang, XI Bochen. SA-ACGAN sample generation model and application research on bearing fault diagnosis[J/OL]. China Mechanical Engineering: 1-11[2022-03-26].

[21] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]// the 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA: IEEE, 2017: 105-114.

[22] LIN F D, CHEN J, SUN J C, et al. Cross-band spectrum prediction based on deep transfer learning[J]. China Communications, 2020, 17(2): 66-80.

[23] 郭　蕾，曹伟东，白龙雷，等. 融合注意力机制与多尺度网络的 EPR 电缆终端故障诊断方法[J]. 高电压技术，2021，47(11)：3872-3880.
GUO Lei, CAO Weidong, BAI Longlei, et al. Fault diagnosis method for EPR cable terminals based on attention mechanism and multiscale network[J]. High Voltage Engineering, 2021, 47(11): 3872-3880.



**吴　闽**
1998—，男，硕士生
主要从事 GIS 在线监测及故障诊断的研究工作
E-mail: 970373008@qq.com

WU Min



**杨俊杰**(通信作者)
1977—，男，博士，教授，硕导
研究方向为电力用户侧智能控制技术、变电站设备远程状态监测、电力通信技术、无线传感器网络及嵌入式系统
E-mail: iamyjj@163.com

YANG Junjie
Ph.D., Professor
Corresponding author

收稿日期　2022-03-28　修回日期　2022-10-21　　编辑　曹昭君