

基于深度学习的变电站高压柜内绝缘子缺陷检测

王昭雷¹, 李 强¹, 卞建鹏², 王雍会¹

(1. 国网河北省电力有限公司超高压分公司, 河北 石家庄 050070; 2. 石家庄铁道大学, 河北 石家庄 050043)

摘要: 高压柜内绝缘子是变电站一次设备中重要的组成部分, 直接影响变电站的稳定运行。传统高压柜内绝缘子缺陷检测方法具有安全隐患大、检测效率低和检测精度不足的问题。为解决上述问题, 本文提出一种基于深度学习的高压柜内绝缘子故障识别算法, 通过将注意力机制谱归一化(spectral normalization, SN)和空间注意力(spatial attention, SA)模块融入生成对抗网络(GAN)中形成改进 SAGAN 模型, 然后在 YOLOv8 中引入 Focus 卷积模块和卷积块注意力机制(convolutional block attention module, CBAM), 接着引入轻量级通道注意模块(efficient channel attention, ECA)注意力机制对 ShuffleNetV2 的结构进行改进。实验结果表明改进 SAGAN 和 YOLOv8-ShuffleNetV2 的网络模型能够识别复杂背景下的破损和缺失绝缘子图像, 准确率达 92.6%, 与 Faster-RCNN、ResNet-50 等传统算法相比, 本文所提模型在准确率、召回率和 F1 值上均有较大提升, 能够有效检测出高压柜内绝缘子的缺陷。

关键词: 改进 SAGAN; YOLOv8-ShuffleNet V2; 高压柜; 绝缘子; 缺陷检测; 注意力机制

中图分类号: TM216 **文献标志码:** A **文章编号:** 1001-9898(2026)01-0050-09

Insulator Defect Detection in High-voltage Cabinets of Substations Based on Deep Learning

WANG Zhaolei¹, LI Qiang¹, BIAN Jianpeng², WANG Yonghui¹

(1. State Grid Hebei Electric Power Co., Ltd. Ultra High Voltage Branch, Shijiazhuang 050070, China;

2. Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

Abstract: Insulators within high-voltage switchgear cabinets represent critical components of substation primary equipment, directly impacting the stable operation of power systems. Conventional defect detection methods for these insulators suffer from high safety hazards, low detection efficiency, and insufficient precision. To address these challenges, this paper presents a deep learning-based fault recognition algorithm for insulators in high-voltage switchgear cabinets. The proposed approach integrates Self-Attention (SA) and Semantic Normalization (SN) mechanisms into a Generative Adversarial Network (GAN). Additionally, it incorporates the Focus convolution module and Convolutional Block Attention Module (CBAM) into YOLOv8, while also improving the ShuffleNetV2 architecture through the introduction of lightweight Efficient Channel Attention (ECA) mechanism. Experimental results demonstrate that the improved SAGAN and YOLOv8-ShuffleNetV2 models achieve accurate identification of damaged and missing insulator images under complex backgrounds, attaining an overall accuracy of 92.6%. Compared with traditional algorithms such as Faster-RCNN and ResNet-50, the proposed model exhibits significant improvements in accuracy, recall, and F1-score, and can effectively detect insulator defects in high-voltage switchgear cabinets.

Key words: improved SAGAN; YOLOv8-ShuffleNet V2; high-voltage switchgear; insulators; defect detection; attention mechanism

0 引言

高压柜作为电力系统核心组件, 其内部绝缘子采用陶瓷或环氧树脂材料, 承担着电气绝缘与机械固定的关键作用。在长期运行中, 内部过电

压、局部放电、机械应力疲劳等因素易导致绝缘子破裂, 严重威胁电力系统安全稳定运行。据统计, 绝缘子缺陷问题占电网系统故障的 50% 以上, 成为影响电网输电可靠性的主要因素^[1-4]。因此, 建立科学高效的绝缘子缺陷检测体系, 对保障电网

收稿日期: 2025-04-06

修回日期: 2025-05-12

作者简介: 王昭雷(1983—), 男, 正高级工程师, 主要从事超特高压变电站安全生产智能检测技术工作。

基金项目: 国网河北省电力有限公司科技项目(kj2023-054)。

安全运行具有重要现实意义。

传统人工巡检方式通过外观检查、绝缘电阻测试等手段检测绝缘子缺陷,存在效率低、实时性差且受限于工程师技术经验等问题。随着深度学习技术的发展,智能巡检逐渐替代人工方式,成为绝缘子缺陷检测研究热点。

近年来,众多学者聚焦绝缘子缺陷检测算法优化。在高压柜内绝缘子缺陷检测方面,通常采用基于传统图像处理方法,以及基于深度学习的绝缘子故障检测方法^[5]。基于传统图像处理方法虽能在一定程度上提取绝缘子特征,但存在适用场景单一、检测效率低、准确率不足等局限。深度学习方法则通过卷积神经网络实现特征自动提取,显著提升检测性能。例如 FANG S 及其团队在使用算法对无人机拍摄到的绝缘子图像进行故障检测时,充分考虑了绝缘子串的盘间距离、绝缘子颜色和绝缘子的轮廓信息,使得算法能够同时关注不同绝缘子片之间的位置和外形信息,从而在有效减少算法误检率和漏检率的同时快速对绝缘子图像进行状态检测^[6]。为解决含有复杂背景的绝缘子图像难以进行状态检测的问题,李浩然等人首先利用色调、饱和度、亮度(hue saturation intensity, HSI)对图像进行预处理,其次为更好地突出目标绝缘子,使用强化的 S 分量对多余背景进行弱化,然后优化 Canny 算子的阈值选取过程,最后通过实验对比证明改进算法对具有微小破损的绝缘子具有较高的检测准确率^[7]。但是上述基于图像处理的检测方法只能检测特定场景下的绝缘子,对于模糊和复杂背景下的绝缘子图像难以进行绝缘子状态检测。此外检测过程时间长和准确率低,难以满足工程要求。

相较于传统的图像处理方法,利用深度学习算法提取绝缘子图像特征信息,再根据这些特征信息对绝缘子进行准确的定位与识别,取得了较好的效果。例如 LOKANATH M 等人提出的改进 Faster-RCNN 网络算法在同样实验条件下的识别准确率较原网络提升了 2%^[8]。LI X F 等人实现对输电线路绝缘子的缺陷检测,首次将 Faster-RCNN 网络与 U-Net 网络相结合,在提高了检测速度的同时,增强了检测准确率^[9]。卞建鹏等人将改进的胶囊网络应用于绝缘子故障分类,这种网络能够有效地保存绝缘子的特征信息,

从而提升故障识别率^[10]。黄新波等人提出了用 VGG16 替换 CNN 中的特征提取部分,并在此基础上加入了自注意力机制以增强其特征描述力,从而提高了强光环境下玻璃绝缘子的识别精度^[11]。沈陆朋等人将 YOLOv5 网络中的主干特征网络 CSPDarknet 替换为 Swin Transformer,结果显示改进的算法可将检测准确率提高 1.8%^[12]。王凯等人提出了一种绝缘子缺陷检测模型 MF-BN-YOLOv5,通过设计 MC3、Fenhence 模块,并引入 BiFPN 结构,提升了对绝缘子不同缺陷特征的融合能力^[13]。罗悦东等人提出一种面向变电站设备缺陷检测的深度特征感知方法。通过设计 C2f+模块、整合 SimAM 模块、融合 NWD 和 CI-OU 的损失函数,提高了对变电站 11 种缺陷类别检测的平均精度^[14]。唐炳南等人提出一种基于改进 YOLOv10 的模型。通过设计一种多尺度通道信息提取模块、一种全局-局部注意力模块,并采用残差结构设计一种 ReSPANet 改进模型,提高了对小目标缺陷的检测性能^[15]。尽管上述基于深度学习的目标检测方法有效克服了传统人工巡检周期长、效率低及安全风险高等难题^[16],提高了绝缘子缺陷检测的精度和效率,但仍存在一些问题:在多类别变电站设备上检测不同类型缺陷的能力受限,导致模型泛化能力不足、过度增加模型的特征提取或融合性能可能会导致计算复杂度变高,无法满足变电站设备智能检测应用的实时性要求等。

针对以上问题,本文提出了一种基于深度学习的高压柜内绝缘子缺陷识别算法。首先,将 SAGAN 中的卷积层替换为残差结构,在加深网络深度的同时,提高网络对深层次特征的提取能力,以解决生成图像模糊的问题。然后,在 YOLOv8 模型中的 Backbone 层中加入 Focus 卷积模块来降低下采样过程中信息丢失的风险,其次,在 Neck 层中添加 CBAM 注意力机制,在保证模型参数不变的前提下增强网络在复杂背景下的特征识别能力。最后,将 ShuffleNetV2 单元结构中的部分“ 1×1 卷积层”去除,并在网络的 stage1 和 stage2 之间插入 ECA 通道注意模块,以增强网络对特征信息的提取能力,最终实现对高压柜绝缘子破损的精准识别与定位。

1 改进 SAGAN 和 YOLOv8-ShuffleNet V2 算法原理

1.1 改进 SAGAN 原理

为获得更多的数据集样本, GoodFello S 在 2014 年提出了 GAN^[17]。其结构如图 1 所示。该网络采用零和博弈的思想逐渐完成对 GAN 性能的优化, 进而达到可以生成高质量绝缘子图像的目的。




图 1 生成对抗网络结构

GAN 主要由生成网络和对抗网络组成, 2 个网络之间通过互相监督、互相博弈进而提高 GAN 的性能。网络的具体工作流程为: 首先向生成网络输入一个随机噪声向量 z 用以生成足够欺骗判别网络的子样本, 然后将子样本和真实绝缘子样本分别输入判别网络中进行判别, 最后通过判别器输出判别类型的概率值, 直观地表示输入进判别网络的是真实样本还是伪样本, 若输入的是真实样本, 判别器输出值为 1, 若输入的是伪样本, 判别器输出值为 0。该网络的损失函数可以用式(1)来表示

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\lg D(x | y)] + E_{z \sim p_z(z)} [\lg(1 - D(G(x | y)))] \quad (1)$$

式中: x 为输入的真实绝缘子图像; z 为输入生成网络的随机噪声向量; $G(x | y)$ 和 $D(x | y)$ 分别为生成网络生成的伪绝缘子样本和判别网络判断输入具体为真伪绝缘子样本的概率值。 $p_{data}(x)$ 为真实绝缘子样本的数据分布; $x \sim p_{data}(x)$ 为 $p_{data}(x)$ 数据分布中的期望 x ; $E_{z \sim p_z(z)}$ 为期望 z 的值是由 $p_z(z)$ 产生的; $p_z(z)$ 为生成的假绝缘子样本的数据分布, 即输入生成对抗网络(GAN)的随机噪声向量的相关表述误差; $z \sim p_z(z)$ 为 p_z 数据分布中的期望 z 。

GAN 难以训练且训练过程极其不稳定, 因此可能引起梯度消失和模式崩溃的问题。使用 GAN 增广绝缘子数据集, 会面临 2 个问题: 1) 将判别器网络训练完成后会引起梯度消失, 进而无法训练生成器网络; 2) 由于生成器网络生成的绝缘子图像多样性有限, 无法包含真实绝缘子的全

部种类。基于上述问题, 需要将谱范数归一化, 同时应用于生成器网络和判别器网络, 将 2 种模型的不对等进行一定的平衡。

在空间中, 从一点到原点的欧几里得距离被设定为二范数。通过对某个矩阵内的向量进行空间转换(包括空间映射、向量翻转和伸缩)可以生成一个新的矩阵, 这些在矩阵内经历空间转换的向量就被称作谱范数。判断一个实矩阵 A 模型是否收敛, 谱范数是必不可少的依据。实矩阵 A 的谱范数如下

$$\rho(A) = \sqrt{\max_{\lambda_i} (\lambda(A^T A))} \quad (2)$$

式中: $\lambda(A^T A)$ 为特征向量; λ_i 为第 i 个特征值, 具体表示为 $[\lambda_1, \lambda_2, \dots, \lambda_{n-1}, \lambda_n]$ 。

当矩阵 A 取最大特征值 $\lambda_i = \lambda_{\max}$ 时, 此时实矩阵 A 的谱范数如下

$$\rho(A) = \sqrt{\max_{\lambda_{\max}} (\lambda_{\max})} \quad (3)$$

在矢量空间中, 要想使一个 x 变为 y , 可以通过矩阵变换的方法, 即通过 $y = Ax$ 来实现, 此时 y 的二范数的平方如下

$$\|y\|^2 = y^T y = (Ax)^T (Ax) \quad (4)$$

因为矩阵具有平移不变性, 则 $(Ax)^T = x^T A^T$, 式(4)可改为

$$\begin{aligned} \|y\|^2 &= x^T (A^T A) x = x^T B \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} B^T x \\ &= (B^T x)^T \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} B^T x \end{aligned} \quad (5)$$

根据矩阵的正交性且令 $z = B^T x$, 向量 z 为 x 与矩阵 B^T 进行矩阵乘法后的输出向量, 因为向量 z 的长度与 x 的长度相等, 因此把向量 z 代入式(5)得:

$$\begin{aligned} \|y\|^2 &= z^T \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} z = \sum_i \lambda_i z_i^2 = \sum_i (\sqrt{\lambda_i} z_i)^2 \end{aligned} \quad (6)$$

由于向量平方和的最大值必须大于或者等于加权特征向量的最大值这一要求, 故根据等式变换, 可将式(6)写为

$$\begin{aligned} \| \mathbf{y} \|^2 &= \\ \sum_i (\max_j (\sqrt{\lambda_j}) \mathbf{z}_j)^2 &\leq \max_j (\sqrt{\lambda_j})^2 \sum_i \mathbf{z}_i^2 = \\ \max_j (\lambda_j) \| \mathbf{z} \|^2 \end{aligned} \quad (7)$$

根据左右平移变换可将式(7)写为式(8),且在长度上 $\mathbf{z}$ 与 $\mathbf{x}$ 是相等的,谱范数表达式可写为:

$$\frac{\| \mathbf{y} \|^2}{\| \mathbf{z} \|^2} = \frac{\| \mathbf{Ax} \|^2}{\| \mathbf{x} \|^2} \leq \max_j (\lambda_j) = \rho(\mathbf{A}) \quad (8)$$

式(9)为实矩阵 $\mathbf{A}$ 满足 K-Lipschitz 约束的充分且必要条件。

$$\| \mathbf{Ax} \| \leq K \| \mathbf{x} \|, \forall \mathbf{x} \in \mathbb{R}^n \quad (9)$$

式(10)为式(9)中的 $\| \mathbf{Ax} \|$ 和 $\| \mathbf{x} \|$ 进行左右平移变换所得。

$$K - \frac{\| \mathbf{Ax} \|}{\| \mathbf{x} \|} \geq 0 \quad (10)$$

当 $K \geq \frac{\| \mathbf{Ax} \|}{\| \mathbf{x} \|} = \sqrt{\lambda}$ 时,式(10)成立,并且实

矩阵 $\mathbf{A}$ 也满足 K-Lipschitz 的约束条件,从而避免了生成网络和判别网络的梯度消失。

为解决在训练 GAN 时出现的梯度消失、模式崩溃和不能很好的捕捉具有固定几何结构的绝缘子特征的问题,将 SA 和 SN 引入到生成网络与判别网络中组成 SAGAN,用以实现少样本下的绝缘子数据集扩充^[18],其结构如图 2 所示。




图 2 SAGAN 网络结构

由图 2 可知,将服从 $N(0,1)$ 正态分布的随机噪声作为输入,先经过全连接层生成特征图,再经过由 $L/2+1$ 个上采样残差结构构成的残差模块进行上采样,其中 $L = \lceil \lg_2(\max(H, W)) \rceil - 3$ 。为避免生成绝缘子图像清晰度不高的情况发生,将上采样残差网络通过层层叠加的方式组成残差模块。在保留了特征图中重要信息的前提下,对重要特征信息进行细化,从而对绝缘子图像进行细化。随后经过自注意力模块,使得生成网络更关注重要特征信息,经过上采样模块继续对绝缘子图像进行细化,经过 SN 和 BN,避免梯度消失和模式崩溃,经过 Leaky ReLU 避免模型过拟合。最后通过 3×3 卷积来调整生成绝缘子图像的尺寸,同时利用 G-Loss 激活函数生成 128×128 的

伪绝缘子样本图像。

改进判别网络的具体结构如图 3 所示。




图 3 改进判别网络结构

由图 3 可知,改进判别网络是交替地使用 128×128 的伪绝缘子样本和真实样本作为输入。在不改变重要特征信息的前提下,输入图像先经过一次下采样残差结构处理以达到缩小图像的目的。经过注意力模块,使得判别网络更加关注图像中的重要特征信息,再经过由 L 个下采样结构组成的下采样模块对图像进行进一步缩小,然后经过 SN 和 BN,避免梯度消失和模式崩溃,再经过 Leaky ReLU 避免模型过拟合,最后经过 Global Sum Pool 和全连接层,选用 L-Loss 作为损失函数,输出判别值。

1.2 改进 YOLOv8-ShuffleNetV2 算法原理

YOLOv8 算法在 YOLOv5 和 YOLOv7 算法基础上改进而来^[19],由输入层、主干网络、特征融合层和 3 个解耦头构成,结构如图 4 所示。输入的故障绝缘子图像难免会有一些分辨率比较低,因此在特征提取网络的第一层基础构建(convolution、batch normalization and SiLU, CBS)模块之上添加一层 Focus 卷积模块,以加强模型对低分辨率图片的检测效果;通过将损失函数改为 WIoU 损失函数,可以动态评估锚框质量,更容易聚焦普通质量的锚框,提高锚框质量。为了使模型更关注主要信息,在网络的 Neck 层添加 CBAM 注意力机制,在保证模型参数不变的前提下增强网络在复杂背景下的特征识别能力,进而提高网络的定位准确率。




图 4 YOLOv8 网络结构

具体改进如下:

1) 主干特征提取结构引入 Focus 卷积模块

由图 4 可得,该网络的 Input 层输入的是经过数据增强后的绝缘子数据集。数据增强方法采用的是马赛克增强、混合增强、空间扰动和颜色扰动^[20]。数据增强不仅可以增强绝缘子数据集的多样性,还可以提高模型对绝缘子的定位能力进而增强模型的鲁棒性。但是有一些输入的故障绝缘子图像分辨率比较低,因此,在特征提取网络的第一层 CBS 上添加一层 Focus 卷积模块,如图 5 所示。




图 5 Focus 卷积模块

通过 Slice 切片技术,该结构的通道数量提升到了原来的 4 倍,也就是说,原本的 3 个通道特征图被转化为 12 通道的特征图。Focus 卷积模块能够有效减少因下采样过程而导致数据丢失问题的发生。

2) 优化损失函数

由于传统 IoU 损失函数会对评估结果造成一定的偏差,因此引入 WIoU 损失函数用以提高锚框质量。

引入 WIoU 损失函数的方法是:首先对预估框与实际框间的 IoU 分数进行计算,以此来测量两框的交集大小;然后利用两者边界框中心点的间距来测算其最远距离,从而得到二者所占的空间范围,并将此空间范围用作评价框之间关系的指标;最后基于此空间范围去计算相应的权重因子,以便对 IoU 分数进行调整,可以有效地判断目标检测的结果是否正确,同时也能消除 IoU 评分中可能出现的误判风险。具体如下

$$W_{IoU} = \frac{\sum_{i=1}^n w_1 \cdot I_{IoU}(b_i, g_i)}{\sum_{i=1}^n w_1} \quad (11)$$

式中: n 为被网络标记的缺陷框的数目; b_i 为第 i 个预测框的坐标; g_i 为第 i 个实际框的坐标; $I_{IoU}(b_i, g_i)$ 为预测框与实际框之间的 IoU 值; w_1 为权重值。

3) Neck 特征层添加 CBAM 注意力机制

由于高压柜内其他设备的影响,网络难以对绝缘子特征进行提取,因此需要引入卷积块注意力机制(convolutional block attention module, CBAM)来解决此问题,其结构如图 6 所示。




图 6 CBAM 模块

由图 6 可知,CBAM 模块被划分为 2 个部分:通道注意力模块和空间注意力模块。其具体流程为:先将特征图送入通道注意力模块,生成对应的注意力图,并将输入特征图与注意力图相乘,得到第一次输出;再对空间注意力模块执行相同操作,得到最终的输出特征图。将流程用数学表达式的形式呈现出来:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (12)$$

式中: F' 为注意力图; $\otimes$ 为两个量进行叉乘; F 为输入特征图; $M_c(F)$ 为通道特征图; $M_s(F')$ 为空间特征图; F'' 为由 CBAM 输出的特征图。

式(13)为通道注意力模块的数学表达式。

$$M_c(F) = \sigma \left(\begin{matrix} \text{MLP}(\text{avgPool}(F)) \\ + \text{MLP}(\text{maxPool}(F)) \end{matrix} \right) = \sigma(W_1(W_0(F_{\text{avg}}^c) + W_1(W_0(F_{\text{max}}^c)))) \quad (13)$$

式中: σ 为 Sigmoid 激活函数; W_0 和 W_1 为 MLP 的权重, $W_0 \in \mathbb{R}^{C/r \times C}$, $W_1 \in \mathbb{R}^{C \times C/r}$, 其中, r 为降维因子。

其空间注意力模块的数学表达式为

$$\begin{aligned} M_s(F) &= \sigma(f^{7 \times 7}([\text{avgPool}(F); \text{maxPool}(F)])) \\ &= \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \end{aligned} \quad (14)$$

式中: 7×7 为卷积核的大小。

CBAM 模块被插入到 PAN-FPN 的上采样 upsample 部分和 C2f 模块下采样部分之后,并在 CBS 模块的前部(也就是在合并特征之前)进行了该步骤。增加 CBAM 模块之后的网络可以更专注于复杂背景下的目标细节,从而提高网络对复杂背景下绝缘子的定位能力。

ShuffleNet 网络目前主要有 V1 和 V2 两个版本。ShuffleNetV1 的核心是采用了分组卷积和通道重组技术^[21],而分组卷积的采用会引起特征信息在卷积网络中丢失的问题,为了使通道间的

特征信息进行互相交流进而避免特征信息的丢失,需要引入通道重组技术用以提高网络的精度。ShuffleNetV2 是 ShuffleNetV1 网络的升级版,将 V1 中的分组卷积替换为密集卷积有效的避免了通道信息之间不能相互交流的问题,此外改进网络不仅剔除了跳跃连接层还在原网络的基础上加入了通道混洗技术,ShuffleNetV2 网络结构如图 7 所示。




图 7 ShuffleNetV2 网络结构

本文在 ShuffleNetV2 网络结构中引入了有效通道(efficient channel attention,ECA)注意力机制^[22],使得加入了 ECA 的改进 ShuffleNetV2 网络可以更准确的关注绝缘子特征,从而提升网络对复杂背景下绝缘子图像特征值的提取能力。为有效增强卷积模块在分类任务中的准确率,将常被用于图像分类任务的 ECA 加到卷积层之后和 stage 2 之前。

ECA 注意力模块结构如图 8 所示。




图 8 ECA 注意力模块结构

由图 8 可知,输入特征图 $F_{M_j}(x) \in \mathbb{R}^{H \times W \times C}$ 先经过全局平均池化进而得到聚合特征 $v \in \mathbb{R}^{1 \times 1 \times C}$,为实现各个通道信息的交互,聚合特征通

过一维卷积学习了相邻通道的特征信息,然后采用 Sigmoid 激活函数来创建通道权重 ω ,输出的 ω 与 $F_{M_j}(x) \in \mathbb{R}^{H \times W \times C}$ 进行逐点卷积,最后标定出新的通道空间特征。ECA 的表达式如下

$$\omega = \sigma(\text{Conv1D}_K(v)) \quad (15)$$

式中:Conv1D 为一维卷积的符号; σ 为 Sigmoid 激活函数; K 为卷积核的大小。

由于 ECA 注意力模块的高效性,可以在不增加计算成本的情况下提高模型的性能,因此加入了 ECA,其网络模型结构如图 9 所示。




图 9 改进 ShuffleNetV2 网络结构

2 算法实现

高压柜内绝缘子缺陷检测算法流程如图 10 所示。




图 10 绝缘子缺陷检测流程

改进 YOLOv8-ShuffleNetV2 网络的绝缘子缺陷检测具体步骤如下:

1) 将 1 600 张原始绝缘子图像经过预处理后输入到训练好的定位网络进行定位;

2) 在改进 YOLOv8 定位网络中判断输入图像中是否存在绝缘子, 对于存在绝缘子的图像进行定位操作, 并对输出的绝缘子图像进行裁剪, 共计裁剪出 6 000 张绝缘子图像, 最终得到 7 600 张处理过的绝缘子图像;

3) 将其中的 6 400 张绝缘子图像作为训练集, 使得改进 ShuffleNetV2 网络可以接受重复的训练;

4) 将剩下的 1 200 张绝缘子图像作为预测集输入到训练好的改进 ShuffleNetV2 识别网络中进行绝缘子状态识别;

5) 输出的绝缘子由网络进行具体状态识别, 识别的结果包括: 正常绝缘子和缺陷绝缘子。

3 实验验证

为了验证基于改进 SAGAN 的绝缘子图像样本增广算法生成的绝缘子图像在清晰度上更优于原网络。通过计算并对比 GAN、SAGAN 和改进 SAGAN 3 种算法的 IS 分数来判断由改进网络生成的绝缘子图像是否具有更高的清晰度和多样性。

实验采用 Adam 优化器优化网络参数, 训练 3 000 个 epoch, 生成网络的初始学习率设置为 0.001, 判别网络为 0.005, 每 300 个 epoch 学习率减小 0.000 5。使用 Mini-Batch 的方式进行训练, 使模型的初始权重服从均值为 0 和方差为 0.02 的正态分布^[23]。模型训练时采用交替训练的方式, 即训练判别网络时对生成网络参数进行封锁, 训练生成网络时对判别网络参数进行封锁。更新 1 次生成网络的权重, 对应着就需要更新 5 次判别网络的权重, 如此进行权重的交替更新。改进 SAGAN、SAGAN 和 GAN 的 IS 分数对比结果如图 11 所示。

由图 11 可知, GAN 网络的 IS 分数比较不稳定, 而 SAGAN 网络的 IS 分数变化趋势为: 从一开始的 1.8 下降到 1.6, 随后逐步增加到 2.5, 然后逐渐下降到 2.3 并趋于稳定。改进 SAGAN 的 IS 分数随着迭代次数的增高逐渐升高, 当网络叠加到 2 900 次时基本趋于稳定的 2.9。




图 11 IS 分数变化

然后, 采用北京某变电站拍摄的高压柜内绝缘子及拆卸的缺陷绝缘子图像经过改进 SAGAN 图像增广并扩充之后的 12 600 张数据集, 其中训练集 8 960 张, 测试集 3 640 张。表 1 为实验训练环境与参数设置。

表 1 实验训练环境与参数设置

参数名称	参数值
操作系统	Windows11
CPU	i7-10700F 处理器
GPU	NVIDIA GeForce GTX 1660 SUPER 显卡
学习率	0.001
迭代次数/次	1 400
训练尺寸	640×640

为了验证改进 YOLOv8-ShuffleNetV2 网络的实用性和识别准确性, 使用改进 YOLOv8-ShuffleNetV2 与 YOLOv5、YOLOv8、Faster-RCNN 和 YOLOv10 等网络对本文数据集进行训练, 然后对不同网络训练的损失值进行对比, 其对比结果如图 12 所示。




图 12 不同网络的损失曲线对比

由图 12 可知, 本文改进算法的损失值图像相比于其他算法较为稳定, 从起初的 0.38 在迭代了 300 次之后保持稳定的 0.15; YOLOv10 网络相比于其他网络而言, 其损失值较低, 从起初的 1.28 在迭代了 1 200 次后基本趋于稳定的 0.27, 但是迭

代次数在 900 次之前的网络稳定性较差,且有一定的上下波动;YOLOv5 网络的损失值从起初的 1.43 在迭代了 1 500 次以后才基本趋于稳定的 0.45,此外其网络的波动性是最大的;Faster-RCNN 网络的损失值从起初的 1.27 在迭代了 1 200 左右才趋于稳定的 0.33;YOLOv8 网络的损失值从起初的 1.42 在迭代了 1 100 次左右便趋于稳定的 0.40,网络的波动性较 Faster-RCNN 和 YOLOv5 相对更小。

然后对本文改进算法与 YOLOv5、YOLOv8、Faster-RCNN 和 YOLOv10 识别率进行对比,其识别率对比结果如图 13 所示。不同网络在准确率、平均精度、召回率、F1 值以及损失值指标的对比结果如表 2 所示。




图 13 不同网络的识别准确率对比

表 2 不同网络的识别性能对比

网络	平均精度 /%	每秒 帧数	召回率 /%	F1	准确率 /%
YOLOv5	60.5	4.3	75.3	0.737	63.32
Faster-RCNN	76.5	8.1	84.0	0.903	77.35
YOLOv8	88.76	58.3	87.1	0.863	89.76
YOLOv10	90.8	60.4	89.3	0.894	92.39
本文改进算法	91.7	61.7	93.1	0.923	92.60


结合图 13 和表 2 可知,本文所采用的基于改进 SAGAN 和 YOLOv8-ShuffleNetV2 的高压柜绝缘子缺陷检测网络相比于 YOLOv8,准确率升高了 2.84%,平均精度提高了 2.94%,召回率升高了 4.8%,F1 值升高了 0.029;相比于 YOLOv5,准确率升高了 29.28%,平均精度提高了 31.2%,召回率升高了 17.8%,F1 值升高了 0.186;相比于 Faster-RCNN,准确率升高了 15.25%,平均精度提高了 15.2%,召回率升高了 9.1%,F1 值升高了 0.02;相比于 YOLOv10,准确率升高了 0.21%,平均精度提高了 0.9%,召回率升高了 3.8%,F1 值升高了 0.029。通过与上述模型的对比,在相同的

数据集和实验环境下,本文改进算法的 5 项指标是最高的。这是由于对网络进行的单元改进、结构改进和引入 ECA 注意力机制使得网络可以更容易的提取到更深层次的特征值,进而提升了网络的各项性能。

采用本文改进 SAGAN 和 YOLOv8-ShuffleNetV2 算法对高压柜正常绝缘子、破损和缺陷绝缘子进行识别与定位,其结果如图 14 所示。



(a) 正常 I 类绝缘子 (b) 正常 II 类绝缘子



(c) 破损 I 类绝缘子 (d) 破损 II 类绝缘子



(e) 缺失 I 类绝缘子 (e) 缺失 II 类绝缘子

图 14 复杂背景下高压柜内绝缘子改进算法检测效果

由图 14 可知,本文改进算法可以准确检测复杂背景下的高压柜内正常、破损和缺失绝缘子状态,具有良好的鲁棒性。从而为技术人员提供技术支持,根据缺陷程度来确定故障的等级,即优先替换故障等级高的绝缘子。

4 结论

绝缘子是变电站高压柜内关键设备之一,其运行状态的好坏直接影响到配电柜能否正常的传输电力。本文提出了一种基于深度学习的高压柜内绝缘子缺陷检测技术,解决了绝缘子数据集少、

传统神经网络小样本场景下模型泛化能力不足和多尺度特征融合机制不完善等问题,对缺陷绝缘子的检测达到了较好的效果。通过对缺陷绝缘子进行仿真和实验验证可得以下结论。

1)通过对比改进 SAGAN、SAGAN 和 GAN 的 IS 分数可知,改进 SAGAN 的 IS 为 2.9,相比于 SAGAN 和 GAN 分别提升了 1.1 和 0.6,改进网络生成的绝缘子图像具有更高的清晰度和多样性,且拥有更好的样本生成性能。

2)在不同深度学习模型的性能比较中,改进 SAGAN 和 YOLOv8-ShuffleNetV2 的准确率为 92.6%,表现出所有模型中最高的识别准确率。

参考文献:

- [1] 李文彬,王 勇,冯砚厅,等.复合绝缘子压接接头模拟极端气温力学试验分析[J].河北电力技术,2022,41(5):71-74.
- [2] 巨建成.500 kV 断路器六氟化硫泄漏故障分析及处理[J].河北电力技术,2024,43(1):52-55.
- [3] 王怡欣,谢铭涵,刘 杰,等.运行后复合绝缘子硅橡胶伞裙老化特性研究[J].河北电力技术,2024,43(4):64-69.
- [4] 张丕沛,郭晨瑞,王伟伟,等.GIS 盆式绝缘子开裂引起放电故障的原因分析[J].河北电力技术,2022,41(6):58-62.
- [5] 李应宏,王贵山,何学敏.复合支柱绝缘子击穿故障及防范措施分析[J].广西电力,2021,44(2):100-104.
- [6] SHANG F S, ZHU M Z, LIU S, et al. Fast detection method of insulator fault based on image processing technology [C]//2020 IEEE 5th Information Technology and Mechatronics Engineering Conference, Chongqing, New York: IEEE, 2020:400-406.
- [7] 李浩然,高 健,吴 田,等.基于改进 Canny 算子的绝缘子裂纹检测研究[J].智慧电力,2021,49(2):91-98.
- [8] LOKANATH M, SAI K K, SANATH K E. Accurate object classification and detection by faster-RCNN [C]//International Conference on Science, Engineering and Technology, Vellore, Bristol, UK: Institute of Physics, 2018:2346-2353.
- [9] LI X F, SU H S, LIU G H. Insulator defect recognition based on global detection and local segmentation[J]. IEEE Access, 2021, 8(9):59945-59965.
- [10] 卞建鹏,郝嘉星,赵 帅,等.基于改进胶囊网络的接触网吊弦故障识别与定位[J].电工技术学报,2020,35(24):5187-5196.
- [11] 黄新波,高玉蕊,张 烨,等.基于联合分量灰度化算法和深度学习的玻璃绝缘子目标识别算法[J].电力自动化设备, 2022, 42(4):203-209.
- [12] 沈陆朋.基于改进 YOLO 算法的高压输电线路绝缘子与缺陷检测技术研究[D].南昌:南昌大学,2023.
- [13] 王 凯,黄陈蓉,顾 杰,等.基于 MFBN-YOLOv5 输电线路绝缘子缺陷检测研究[J].计算技术与自动化,2025,44(1):80-87.
- [14] 罗悦冬,杜思超,李 猷,等.基于深度特征感知的变电站设备典型缺陷检测方法[J/OL].南方电网技术:1-13[2025-12-16]. <https://link.cnki.net/urlid/44.1643.TK.20250328.1131.003>.
- [15] 唐炳南,柳明贤,李 华,等.基于改进 YOLOv10 的绝缘子缺陷检测算法[J/OL].南方电网技术:1-11[2025-12-16]. <https://link.cnki.net/urlid/44.1643.TK.20250325.1429.002>.
- [16] 蒋寰游.基于 YOLOv5 的无人机航拍输电线路绝缘子多缺陷检测[D].广州:广东工业大学,2021.
- [17] SARAVANAN G, BABU S V A. Workload prediction for enhancing power efficiency of cloud data centers using optimized self-attention-based progressive generative adversarial network[J]. International Journal of Communication Systems, 2023, 37(1):154-156.
- [18] WANG C, XU C, YAO X, et al. Evolutionary generative adversarial networks[J]. IEEE Transactions on Evolutionary Computation, 2019, 23(6):921-934.
- [19] CHEN Y, LIU H, CHEN J, et al. Insu-YOLO: An insulator defect detection algorithm based on multiscale feature fusion[J]. Electronics, 2023, 12(15):3655-3658.
- [20] YU J, WENZHE V Y, MARCO G, et al. Excited state properties of point defects in semiconductors and insulators investigated with time-dependent density functional theory [J]. Journal of Chemical Theory and Computation, 2023(25):2234-2235.
- [21] SU J, YANG M, TANG X. Integration of shuffleNetV2 and YOLOv5s networks for a lightweight object detection model of electric bikes within elevators[J]. Electronics, 2024, 13(2):899-893.
- [22] CHENGYIN R, SHIHAI Z, CHONGNIAN Q, et al. The high-precision detection method for insulators' self-explosion defect based on the unmanned aerial vehicle with improved lightweight ECA-YOLOX-tiny model[J]. Applied Sciences, 2022, 12(18):9314-9314.
- [23] 余小松.面向输电线路绝缘子图像的数据增广方法研究[D].成都:电子科技大学,2023.

本文责任编辑:王洪娟