

基于X-DR图像与YOLO-MS模型的输电线路耐张线夹压接缺陷检测

李俊轩¹, 邱志斌¹, 石大寨², 张润¹, 李攀³

(1. 南昌大学能源与电气工程系, 南昌 330031; 2. 国网安徽省电力有限公司池州供电公司, 安徽 池州 247000; 3. 江西大荣电力设备有限公司, 南昌 330096)

摘要: 针对输电线路耐张线夹压接质量检测产生的海量X-DR图像, 提出一种基于YOLO-MS模型的压接缺陷智能识别方法。根据耐张线夹压接质量现场检测图像, 构建6类典型压接缺陷的X-DR图像数据集, 并对其进行高斯滤波、直方图均衡化、伽马校正等预处理。利用CSPDarknet、CBAM-PANet以及Head-4构建多尺度(multi-scale, MS)目标检测网络YOLO-MS, 并使用数据集中训练样本与测试样本对模型进行训练与测试。结果表明, 所提出的YOLO-MS模型能够有效检测6类耐张线夹压接缺陷, 平均精度均值可达92.57%, 检测速度为26帧/s, 可用于辅助输电线路运维人员开展耐张线夹压接图像的自动识别与缺陷检测。

关键词: 输电线路; 耐张线夹; X射线图像; 压接质量; 缺陷检测

Crimping Defect Detection of Transmission Line Strain Clamp Based on X-DR Image and YOLO-MS Model

LI Junxuan¹, QIU Zhibin¹, SHI Dazhai², ZHANG Run¹, LI Pan³

(1. Department of Energy and Electrical Engineering, Nanchang University, Nanchang 330031, China; 2. Chizhou Power Supply Company of State Grid Anhui Electric Power Co., Ltd., Chizhou, Anhui 247000, China; 3. Jiangxi Darong Electric Power Equipment Company, Nanchang 330096, China)

Abstract: Aiming at the massive X-DR images generated by crimping quality detection of transmission line strain clamps, an intelligent recognition method for crimping defects is proposed based on YOLO-MS model. A X-DR image dataset including 6 typical crimping defects is constructed using the field crimping quality detection images of strain clamps, and the image preprocessing is carried out by Gaussian filtering, histogram equalization, and gamma correction. The multi-scale (MS) object detection network YOLO-MS is constructed using CSPDarknet, CBAM-PANet, and Head-4. The model is trained and tested using concentrated training and testing samples from a dataset. The results show that the YOLO-MS model can effectively detect 6 types of strain clamp crimping defects, with a mean average precision of 92.57%, and a detection speed of 26 frames per second. It can be used to assist transmission line operation and maintenance personnel to carry out automatic recognition and defect detection of strain clamp crimping images.

Key words: transmission line; strain clamp; X-ray image; crimping quality; defect detection

0 引言

耐张线夹是架空输电线路的重要部件, 用于固定耐张杆塔上的导、地线终端, 在运行中需要承受

导线或地线的全部张力和电流负载以及覆冰、舞动等环境因素的作用, 可能出现线夹断裂引发的掉线事故^[1-3]。目前输电线路广泛应用的液压型耐张线夹由钢锚和铝管组成, 并与导线的钢芯和铝线压

基金项目: 国家自然科学基金资助项目(52167001); 江西省“双千计划”创新领军人才长期(青年)项目(jxsq2019101071)。

Foundation item: Supported by the National Natural Science Foundation of China (52167001); the Innovative Leading Talents Long-Term Project of Jiangxi “Double Thousand Plan” (jxsq2019101071).

接为一体^[4], 安装后即不再拆卸, 其压接质量直接影响电力输送的安全。根据电网公司相关规定^[5], 对于输电线路“三跨”耐张线夹在投运之前和运行阶段均需开展 X 射线无损检测。

X 射线具有较强的穿透力, 由 X 射线机、平板探测器和计算机等构成的成像系统可对物体内部状态进行无损检测。X 射线数字成像(X-ray digital radiography, X-DR)技术在工业探伤、安全检查、医学诊疗等领域具有广泛应用^[6-8], 近年来也被用于复合绝缘子^[9]、气体绝缘组合电器(gas insulated switchgear, GIS)^[10-12]、碳纤维复合芯导线^[13-14]、耐张线夹^[15-17]等电力设备的内部缺陷检测。对于输电线路施工或检修现场采集到的耐张线夹 X-DR 图像, 目前主要根据技术导则^[18]并通过人工识别判断其中是否存在压接缺陷。由于耐张线夹压接缺陷在 X-DR 图像中的占比较小, 人工逐张检测易受主观因素影响且检测效率较低, 亟需开展智能化的 X-DR 图像识别与缺陷检测技术研究。

随着人工智能技术的进步, 利用基于深度学习的图像分类与目标检测算法对输变电设备的各类缺陷进行自动识别, 已成为电网智能运维的发展方向^[19-21]。针对电力设备 X-DR 图像的智能识别已有少量研究。文献[12]在高效亚像素卷积神经网络中引入双层注意力机制 SE 模块, 构建了一种超分辨率网络模型, 用于对 GIS 设备内部 X-DR 图像进行增强, 以提高细微缺陷检测的准确性。文献[16]构建了一种融合 SE 模块与 DenseNet 密集连接结构的 SEPreDenseNet-121 模型, 对 10 大类耐张线夹压接缺陷进行检测, 准确率可达 79.28%。文献[17]采用 CenterNet 定位耐张线夹 X-DR 图像中的压接部位, 并对其进行切割与数据增强, 然后通过 RetinaNet 算法识别压接部位是否存在缺陷, 准确率可达 95.9%, 但尚未实现不同类型的缺陷识别。文献[19]采用 EfficientNet 改进 YOLOv3 目标检测算法的特征提取环节, 对耐张线夹存在的“凹槽欠压”、“飞边”、“弯曲”、“散股”四类压接缺陷的 X-DR 图像进行检测, 平均精度均值(mean average precision, mAP)可达 90.03%。深度学习算法具有较强的图像特征提取与目标定位能力, 但目前输电线路耐张线夹的 X-DR 图像识别与缺陷检测研究尚处于起步阶段, 由于压接缺陷目标较小, 实现缺陷定位与分类检测仍存在一定的难度。

本文构建了包含 6 类压接缺陷的输电线路耐张线夹 X-DR 图像数据集, 并对图像进行高斯滤波、直方图均衡化、伽马校正等预处理; 利用 YOLOX 目标检测算法建立了压接缺陷检测模型, 在主干特征提取网络和特征融合网络之间添加卷积注意力模块(convolutional block attention module, CBAM), 并额外增加一个解耦头对其进行改进优化; 最后结合 Mosaic 数据增强方法进行模型训练。通过对测试集图像进行压接缺陷检测, 验证了改进 YOLOX 模型的准确性, 可为输电线路耐张线夹压接质量检测提供智能化工具。

1 耐张线夹 X-DR 图像预处理

1.1 X-DR 图像数据集

针对架空输电线路常用的钢芯铝绞线耐张线夹, 压接位置如图 1 中的区域 A、B、C 所示, 采用 X-DR 技术进行无损检测时重点检测部位包括区域 A 的钢锚凹槽与铝管的连接处、区域 B 的钢锚与钢芯连接处、区域 C 的铝绞线与铝管连接处^[22]。




图 1 耐张线夹压接位置

Fig. 1 Crimping position of the strain clamp

本文从架空输电线路压接工程实例中收集了 5 223 幅耐张线夹 X-DR 图像, 根据相关标准^[18, 23]并结合图 1 将压接缺陷划分为 A 区漏压、C 区漏压、欠压、过压、弯曲、飞边 6 类, 其典型 X-DR 图像如图 2 所示。其中, “A 区漏压”是指铝管和钢锚凹槽未被压接, 此时危害最大, 应及时开断重压; “C 区漏压”是指区域 C 压接不完全或者未被压接; “欠压”是指铝管和钢锚凹槽未被完全压接, 之间留有缝隙, 应及时补压; “过压”是指压接过度, 致使非压区受到压接; “弯曲”是指钢锚受到外力导致表面发生形变; “飞边”是指钢锚表面存在裂纹。在上述耐张线夹 X-DR 图像数据集中, 共标注 11 132 个缺陷, 另有无缺陷图像 247 幅。




图2 耐张线夹典型缺陷X-DR图像

Fig. 2 X-DR images of typical defects in the strain clamp

1.2 X-DR 图像预处理

在对耐张线夹进行X射线无损检测时, 成像环境、成像位置等因素会对X-DR图像质量产生影响。本文采用高斯滤波、直方图均衡化与伽马校正进行图像预处理, 提升细微缺陷的特征表达, 具体如下。

1) 将耐张线夹X-DR图像作为输入, 利用高斯滤波算法去除图像噪声。该方法是对图像窗口内所有像素点的像素值进行加权平均, 其权重服从二维正态分布, 权值 $H(x, y)$ 可表示为

$$H(x, y) = \frac{1}{(\sqrt{2\pi}\sigma)^2} e^{-\frac{[(x-\mu_x)^2 + (y-\mu_y)^2]}{2\sigma^2}} \quad (1)$$

式中: σ 为标准差; x 、 y 分别为矩形窗口内任意一点横纵坐标; μ_x 、 μ_y 分别为矩形窗口中心点横纵坐标, 在滤波时可认为是整数。

设原始图像的像素为 $f(x, y)$, 则滤波后的图像像素为 $g(x, y) = f(x, y) \times H(x, y)$ 。以图3(a)所示耐张线夹X-DR图像为例, 经过高斯滤波后的效果如图3(b)所示, 图像中的噪声得到了抑制。

2) 将滤波后的图像进行直方图均衡化。首先通过划分图像的灰度等级为 $[0, l-1]$, 并计算原始图像的直方图分布概率 $P_r(r_k)$, 具体计算方式如下。

$$P_r(r_k) = \frac{n_k}{n} \quad (0 \leq r_k \leq l-1, k = 0, 1, 2, \dots, l-1) \quad (2)$$

式中: r_k 为第 k 个灰度级; n_k 为其对应的像素数量; n 为图像像素数量; 然后采用直方图累积分布函数 S_k 修正图像的灰度级, 具体计算可表示为:

$$S_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j), \quad (0 \leq r_j \leq l-1) \quad (3)$$

最后通过将 S_k 进行反变换, 可得到处理后的像素灰度分布, 并取代原图像的灰度分布, 其效果如图3(c)所示, 由图3可见耐张线夹压接部分与背景的对比度得到了增强。

此外, 由于直方图均衡化在对图像像素进行处理时不加选择, 可能增加背景的灰度值并降低目标缺陷的灰度值, 使得图像灰度级减少, 某些细微缺陷不显著。因此进一步采用伽马校正进行图像处理。

3) 伽马校正是对图像中的伽马曲线进行非线性色调编辑, 通过检测深色与浅色部分并使两者的比例增大或减少达到图像对比度增强或减弱的效果。对于原始图像中的某个像素, 首先将其归一化为0~1之间的实数, 然后以 $1/\gamma$ 为指数求出该实数的预补偿值, 最后对其进行反归一化, 变换为0~255之间的整数值, 即可实现伽马校正。通过改变指数 γ 可以调节图像对比度。对图3(c)所示X-DR图像进行




图3 耐张线夹X-DR图像预处理

Fig. 3 X-DR image preprocessing of the strain clamp

伽马校正,其效果如图3(d)所示。由图3可知,经过上述图像预处理后,耐张线夹压接部位的清晰度与对比度得到了加强。

2 基于YOLO-MS的缺陷检测

2.1 YOLO-MS检测模型

受YOLOX^[24]目标检测模型的启发,本文利用CSPDarknet、CBAM-PANet以及Head-4构建多尺度(multi-scale, MS)目标检测网络YOLO-MS,如图4所示。其中,CBS是由普通卷积Conv、标准化batch normalization以及激活函数SiLU所构成的卷积模块,CSP结构表示一个大的残差模块,Concat表示上采样与下采样的维度堆叠。

2.1.1 主干特征提取网络

将耐张线夹的X-DR图像作为输入,图像大小设置为640×640×3,经过卷积、标准化以及激活函数等操作对图像进行特征提取。由图4可知,图像输入主干特征提取网络CSPDarknet后,先经过Focus网络结构,将图像的宽高信息集中到通道信息中,使得输入通道扩充了四倍;然后采用跨阶段局部网络CSP结构,增强主干网络的学习能力并且大大减少模型的计算量,其中,神经元Res unit的个数 x 决定了网络的深度。此外,在主干网络中引入空间金字塔池化(spatial pyramid pooling, SPP)结构,从而增加网络的感受野,分离出显著的特

征^[25]。此外,网络采用SiLU激活函数,其表达式为:

$$f(x) = x \cdot \text{sigmoid}(x) \quad (4)$$

式中 x 为输入的特征参数。SiLU函数具备无上界有下界、平滑非单调的特性,在深层模型上的效果优于ReLU激活函数。

2.1.2 基于CBAM-PANet的特征融合

特征融合网络可以将不同大小的特征层进行融合,有利于提取出更好的图像特征^[26]。本文构建PANet网络融合图像浅层与深层的特征^[27],并在其输入端加入CBAM注意力机制,以提高神经网络对图像信息的关注度。

CBAM注意力机制^[28]包含2个独立的子模块,分别为通道注意力模块(channel attention module, CAM)与空间注意力模块(spatial attention module, SAM),具体结构如图5所示。对于大小为 $c \times h \times w$ 的输入特征层,先通过CAM模块利用最大池化与平均池化对特征层的空间信息进行聚集,可得到聚集结果最大值 $F_{\max}$ 和平均值 F_{avg} ,然后利用多层感知机(multi-layer perceptron, MLP)生成两个 $1 \times 1 \times c$ 的注意力向量,并将其进行相加;通过sigmoid函数激活得到对应的通道注意力特征 $M_c(F)$,具体计算可表示为:

$$M_c(F) = \sigma(\text{MLP}(F_{\text{avg}}) + \text{MLP}(F_{\max})) \quad (5)$$

式中 σ 为sigmoid函数。随后特征层 F' 通过SAM模




图4 YOLO-MS网络结构图

Fig. 4 Network structure diagram of YOLO-MS

块, 利用平均池化与最大池化聚合特征层的空间信息, 得到两个大小为 $H \times W \times 1$ 的空间注意力特征, 将其进行特征拼接后利用一个 7×7 的卷积产生 2D 空间注意力图, 最后通过 sigmoid 函数进行标准化, 得到最终的空间注意力特征 $M_c(F')$, 具体计算可表示为:

$$M_c(F') = \sigma[f^{7 \times 7}(\text{concat}(F'_{\text{avg}}, F'_{\text{max}}))] \quad (6)$$

式中: $f^{7 \times 7}$ 为卷积运算; concat 为特征拼接; F'_{max} 和 F'_{avg} 分别为聚合结果最大值和平均值。




图 5 CBAM 模型结构图

Fig. 5 Structure diagram of CBAM model

从主干网络中提取出 4 个大小分别为 $160 \times 160 \times 128$ 、 $80 \times 80 \times 256$ 、 $40 \times 40 \times 512$ 以及 $20 \times 20 \times 1024$ 的有效特征层, 加入 CBAM 注意力机制后进行自顶向下与自底向上的特征融合, 融合过程如图 6 所示。Feat 代表有效特征层, P 与 N 代表不同特征层融合后的结果。




图 6 PANet 结构示意图

Fig. 6 Schematic diagram of PANet structure

2.1.3 基于 Head-4 的分类预测

耐张线夹 XDR 图像在经过主干特征提取网络和特征融合网络后, 利用分类预测网络进行解码。本文所用 YOLOIMS 模型的 4 个解耦头大小分别为 160×160 、 80×80 、 40×40 、 20×20 , 可预测大、中、小、极小四类目标, 由于在解码过程中考虑分类和定位具有一定的冲突, 对性能会产生影响, 因此将

分类和定位进行解耦, 采用 Decoupled 结构提高模型收敛速度, 其结构如图 7 所示。




图 7 Decoupled 结构示意图

Fig. 7 Schematic diagram of decoupled structure

对于每个特征层, 可获得 3 个预测结果。Cls ($H \times W \times C$) 用于判断每一个特征点所包含的物体种类; Reg ($H \times W \times 4$) 用于判断每个特征点的回归参数, 而回归参数调整后可获得预测框; Obj ($H \times W \times 1$) 用于判断每一个特征点是否包含物体。将 3 个预测结果进行堆叠, 则每个特征层获得的结果为 $H \times W \times (4+1+C)$, 其中 4 为位置参数, 1 代表是否存在目标, C 则代表包含目标物体的种类。

2.2 数据增强模块

在模型的训练阶段使用数据增强可以丰富检测目标数量并提高模型的泛化能力。常见的数据增强方式有 Mosaic 数据增强与 Mixup 数据增强。其中, Mosaic 数据增强是在每一轮次的训练中随机采用 4 幅图像拼接成一幅新的图像, 并对标签进行处理, 得到新的图像进行训练; Mixup 数据增强则是在每一轮次的训练中随机选取两张图像, 并以一定的比例混合生成新的图像, 但该方法在训练时仅采用混合的新图像训练, 原图像并不参与模型的训练。耐张线夹 X-DR 图像使用以上两种数据增强的效果如图 8 所示。

可见, 使用 Mixup 数据增强后的图像中会存在




图 8 数据增强效果图

Fig. 8 Data enhancement results

压接缺陷的重合,且重合后的图像轮廓较浅,这会造成缺陷特征的丢失,导致模型训练时对缺陷的学习率下降,从而使检测时的置信度偏低。因此,本文选择仅使用Mosaic数据增强辅助模型的训练。

2.3 模型评价指标

在目标检测领域中,通常采用mAP与检测速度(frames per second, FPS)评价模型训练的优劣,而模型参数量则影响训练过程的快慢。其中mAP是最常用、最关键的评价指标,其大小直接关系着模型对此类目标的检测是否有效。mAP值是指模型检测所有目标类别的平均精度均值,而平均精度AP为模型训练时准确率 P_r 曲线与召回率 R_c 曲线下所围成的面积,准确率表示预测结果中有多少样本为正确检测,当 $P_r=100\%$ 时,表示不存在误检;召回率表示预测结果中有多少正样本被正确检测, $R_c=100\%$ 时,表示不存在漏检。 P_r 与 R_c 的计算式为:

$$P_r = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad R_c = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (7)$$

式中: N_{TP} 为正样本被正确检测数; N_{FP} 为负样本被正确检测数量; N_{FN} 为正样本被误检数量。

3 实验结果与分析

在TensorFlow深度学习框架上构建基于YOLO-MS算法的架空输电线路耐张线夹压接缺陷检测模型,为评估所用方法的有效性,在相同环境配置与参数设置下分别测试了SSD、Faster RCNN、YOLOv5与YOLOX等算法模型的预测性能。实验环境配置及所需硬、软件设施如表1所示,测试代码的编译均基于Python语言。

表1 实验环境配置

Tab. 1 Experimental environment configuration

设备清单	设备规格
处理器	Intel Xeon E5-2678 v3
显卡	RTX 3080 Ti
硬盘容量	1 T
RAM	128 GB
显存	12 GB
框架	TensorFlow2.0
CUDA	CUDA11.1

训练时采用多阶段迁移学习的方式,利用在VOC2007数据集上已训练好的模型权重,迁移到新的模型辅助训练。辅助训练可分为两个阶段,共

训练100轮次,第一阶段冻结模型主干训练50轮次,冻结模型主干可提升训练效率并防止迁移权重被破坏,此时模型训练占用显存较小,训练速度较快;第二阶段为解冻训练,对模型再训练50轮次,此时训练占用显存较大,训练参数应适当调小。训练轮数Epoch、迭代次数、学习率以及批尺寸Batch size的大小如表2所示。

表2 模型训练参数

Tab. 2 Parameters for model training

学习步骤	模型参数				
	训练样本	Batch_size	学习率	迭代次数	Epoch
冻结	4 230	16	1×10^{-3}	264	50
解冻	4 230	8	1×10^{-4}	528	50

3.1 算例结果分析

将耐张线夹X-DR图像数据集按9:1分为训练集与测试集,其中,训练集中共包含4 700幅缺陷图像,将其中的10%作为验证集。在进行图像预处理后将训练集分别输入到不同算法模型进行训练,训练过程中各模型的损失函数曲线如图9所示。可见,随着训练迭代次数的增加,各网络模型的损失值不断降低。在迭代训练50轮次时,对冻结的模型主干进行解冻,损失值有较为明显的波动,波动结束后损失值进一步降低,模型逐渐收敛。




图9 训练过程中的损失曲线

Fig. 9 Loss curves during training

训练结束后,取各模型中损失值最小的权重,利用耐张线夹X-DR图像数据集中的测试集对各模型进行测试,各类缺陷的检测结果如表3所示。可知,各模型对“A区漏压”、“C区漏压”、“过压”、

“飞边”4类缺陷的检测精度较高,AP值均在84%以上,且组1、组2的AP值相差较小,表明图像预处理对特征较明显的缺陷影响不大;而各模型对“欠压”、“弯曲”两类缺陷的检测精度较低,且组1、组2的AP值相差较大,表明图像预处理可以有效提升模型对细微缺陷的检测性能;同时,在对比模型中,YOLOX模型的检测效果较好,在组2上的mAP值可达90.27%,而本文提出的YOLO-MS模型在组2上的mAP值可达92.57%,且各类缺陷的AP值均达到80%以上。

此外,各模型的参数量以及在组2上的检测速度如表4所示。可见,SSD、Faster RCNN的参数量分别达到26.1 M与28.5 M,大于其他模型,表明其训练速度较慢;而YOLOv5、YOLOX以及YOLO-MS的参数量较少,且FPS均在20帧/s以上,相较于其他算法,其检测速度较快;综上所述,本文所提出的YOLO-MS模型的整体性能优于对比模型,验证了YOLO-MS模型的有效性。

3.2 准确率与召回率

采用YOLO-MS模型对组2中的压接缺陷进行检测,各类缺陷的PR曲线如图10所示。可见,在召回率为0.5以下时,模型对各类缺陷均可取得较高的检测准确率。随着召回率的提高,“欠压”与“弯曲”两类缺陷的准确率显著下降,此时误检与漏检情况有所增多,表明模型对此类缺陷的检测效果不佳;而“A区漏压”、“C区漏压”、“过压”、“飞边”4类缺陷的检测准确率与召回率均取得较好的结果,表明这4类缺陷的漏检与误检情况较少。

各类缺陷的误检、漏检与成功检测数如表5所示。可见,“欠压”、“弯曲”的检测效果不如其他缺陷类型,其漏检率分别为17.1%和17.9%,误检率分别为30.5%和22.8%,这是由于耐张线夹

X-DR图像中凹槽的欠压程度与钢锚的弯曲程度不尽相同,且此类缺陷的特征不够显著,导致模型对这两类缺陷的学习效果不佳。其余4类缺陷的误检与漏检数均处于较低水平,表明其特征显著、学习效果较好,其中“C区漏压”可达到零误检与零漏检。

3.3 消融实验

消融实验可以更好地展示模型改进对检测性能的影响情况,从而得出每个改进点对整个模型性能的贡献程度。本文受YOLOX模型结构的启发,使用CBAM-PANet与Head-4构建多尺度目标检测网络YOLO-MS,其消融实验在组2上的检测结果如表6所示。可见,YOLOX模型单独使用CBAM-PANet与Head-4后,模型的mAP值分别提升了0.83%与1.23%,同时使用两种模块构成YOLO-MS后,模型的mAP值可达92.57%,相较于YOLOX提升了2.3%,准确率和召回率分别提升了2.75%和9.07%,表明模型可有效降低模型的误检与漏检。

以两幅存在压接缺陷的耐张线夹X-DR图像为例,采用YOLO-MS模型对其进行目标检测,并通过可视化工具Grad-CAM^[29]显示网络的决策区域,可以得出如图11所示的热力图与缺陷检测结果。检测结果中不同颜色的矩形框表示不同压接缺陷,数字表示此类缺陷的置信度。

由热力图可知,YOLO-MS模型对X-DR图像中的压接缺陷部位检测能力更强,可有效检测出图像中的单一目标缺陷或多目标缺陷。从检测结果可以看出,图11(a)中存在“弯曲”缺陷,置信度为0.91;图11(b)中同时存在“C区漏压”(0.89)、“欠压”(0.83、0.79)、“弯曲”(0.87)缺陷。可见,本文提出的YOLO-MS模型可用于耐张线夹X-DR图像中的

表3 不同模型的检测结果对比

Tab. 3 Detection result comparison of different models

目标检测模型	AP 值												mAP 值/%	
	A 区漏压		C 区漏压		欠压		过压		弯曲		飞边			
	组 1	组 2	组 1	组 2	组 1	组 2	组 1	组 2	组 1	组 2	组 1	组 2	组 1	组 2
SSD	0.97	0.98	0.99	0.99	0.56	0.67	0.94	0.93	0.38	0.47	0.81	0.84	77.53	81.59
Faster RCNN	0.98	0.99	0.98	0.99	0.62	0.68	0.94	0.94	0.42	0.53	0.86	0.85	80.13	83.04
YOLOv5	0.98	0.98	0.98	0.99	0.72	0.80	0.94	0.95	0.66	0.71	0.94	0.95	87.26	89.84
YOLOX	0.99	0.99	0.99	0.99	0.75	0.82	0.95	0.95	0.68	0.70	0.93	0.96	88.17	90.27
YOLO-MS	0.99	0.99	1.00	1.00	0.80	0.83	0.94	0.96	0.79	0.82	0.93	0.95	90.95	92.57

表 4 不同模型的检测结果对比

Tab. 4 Detection result comparison of different models

目标检测模型	参数量/M	FPS/(帧·s ⁻¹)
SSD	26.1	21
Faster RCNN	28.5	15
YOLOv5	7.3	26
YOLOX	9.7	27
YOLO-MS	11.3	26




图 10 模型在测试集中的 PR 曲线

Fig. 10 PR curves of the model in the test dataset

表 5 各类压接缺陷的误检、漏检与成功检测数

Tab. 5 Missed, false and successful detection numbers of different crimping defects


缺陷种类	检测结果		
	误检数	漏检数	成功检测数
A区漏压	0	2	176
C区漏压	0	0	256
欠压	164	64	310
过压	53	28	634
弯曲	23	14	64
飞边	2	10	191

表 6 消融实验结果


Tab. 6 Results of ablation experiments

模型	准确率 /%	召回率 /%	mAP值 /%	FPS /(帧·s ⁻¹)
YOLOX	91.89	79.31	90.27	27
YOLOX+CBAM-PANet	93.15	82.45	91.10	27
YOLOX+Head-4	93.37	87.29	91.50	26
YOLO-MS	94.64	88.38	92.57	26

压接缺陷检测, 可为输电线路投运前的质量管控和运行中的检修维护提供帮助。



(a) 单一目标缺陷



(b) 多目标缺陷

图 11 YOLO-MS 模型的压接缺陷检测效果

Fig. 11 Crimping defect detection results by the YOLO-MS model

4 结论

本文提出了一种基于 X-DR 图像与 YOLO-MS 模型的输电线路耐张线夹压接缺陷检测方法, 构建了含有 6 类压接缺陷的耐张线夹 X-DR 图像数据集, 开展了图像预处理与模型训练, 通过算例实验验证了方法有效性, 可得出以下结论。

1) 采用高斯滤波、直方图均衡化与伽马校正对耐张线夹 X-DR 图像进行预处理, 可有效增强“欠压”、“弯曲”等细微缺陷的特征表达, 进而提升目标检测模型的识别精度。

2) 使用 CBAM-PANet 与 Head-4 结构可有效提升模型对细微缺陷的检测效果, 模型的准确率与召回率分别可达 94.64% 与 88.38%, 相较于原模型提升了 2.75% 和 9.07%, 实现了更少的误检与漏检。

3) YOLO-MS 模型对于耐张线夹 X-DR 图像中的压接缺陷检测精度和检测速度优于 SSD、Faster RCNN、YOLOv5、YOLOX 等模型, 6 类缺陷的 mAP 值可达 92.57%, FPS 为 26 帧/s, 能够有效识别耐张线夹 X-DR 图像的单一目标 and 多目标缺陷。

参考文献

- [1] 周立宪, 孙涛, 顾建, 等. 大截面导线用耐张线夹压接性能评价[J]. 中国电机工程学报, 2020, 40(S1): 149–154.

- ZHOU Lixian, SUN Tao, GU Jian, et al. Evaluation of strain clamp crimping property for large cross-section conductor[J]. Proceedings of the CSEE, 2020, 40(S1): 149 – 154.
- [2] 王炜, 袁奇, 顾俊杰, 等. X射线无损探伤技术在检测输电线路压接金具中的应用[J]. 上海交通大学学报, 2018, 52(10): 1189 – 1194.
- WANG Wei, YUAN Qi, GU Junjie, et al. Application of X-ray nondestructive flaw detection technology in transmission line's press fittings [J]. Journal of Shanghai Jiao Tong University, 2018, 52(10): 1189 – 1194.
- [3] 陈俊, 秦怡宁, 熊细涛, 等. 输电线路压接质量检测装置的研究和设计[J]. 电测与仪表, 2017, 54(24): 50 – 56, 72.
- CHEN Jun, QIN Yining, XIONG Xitao, et al. Research and design of inspection device for the crimping quality of transmission line[J]. Electrical Measurement & Instrumentation, 2017, 54(24): 50 – 56, 72.
- [4] 全国架空线路标准化技术委员会. 耐张线夹: DL/T 757—2021[S]. 北京: 中国电力出版社, 2021.
- [5] 国家电网有限公司. 国家电网有限公司十八项重大反事故措施(2018修订版)及编制说明[M]. 北京: 中国电力出版社, 2018.
- [6] DU W, SHEN H, FU J. Automatic defect segmentation in X-ray images based on deep learning [J]. IEEE Transactions on Industrial Electronics, 2021, 68(12): 12912 – 12920.
- [7] SAAVEDRA D, BANERJEE S, MERY D. Detection of threat objects in baggage inspection with X-ray images using deep learning [J]. Neural Computing and Applications, 2021 (33): 7803 – 7819.
- [8] TRAN V L, LIN H Y, LIU H W. Multitask deep learning for segmentation and lumbosacral spine inspection [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 4005910.
- [9] 闫文斌, 王达达, 李卫国, 等. X射线对复合绝缘子内部缺陷的透照检测和诊断[J]. 高压电器, 2012, 48(10): 58 – 66.
- YAN Wenbin, WANG Dada, LI Weiguo, et al. Application of X-ray technology in composite insulators defect diagnosis [J]. High Voltage Apparatus, 2012, 48(10): 58 – 66.
- [10] 许焕清, 马君鹏, 王成亮, 等. GIS设备典型缺陷的X射线数字成像检测技术[J]. 电网技术, 2017, 41(5): 1697 – 1702.
- XU Huanqing, MA Junpeng, WANG Chengliang, et al. Study on digital X-ray imaging technology for detecting typical defects in GIS equipment [J]. Power System Technology, 2017, 41(5): 1697 – 1702.
- [11] WANG J, DING W, LIU Y, et al. Application of X-Ray inspection for ultra-high voltage gas-insulated switchgear [J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1412 – 1422.
- [12] 罗潇, 於锋, 彭勇. 基于深度学习的无人机电网巡检缺陷检测研究[J]. 电力系统保护与控制, 2022, 50(10): 132 – 140.
- LUO Xiao, YU Feng, PENG Yong. UAV power grid inspection defect detection based on deep learning [J]. Power System Protection and Control, 2022, 50(10): 132 – 140.
- [13] 王郑, 杜怀云, 王金沛, 等. 基于改进YOLOv4的输电线路耐张线夹缺陷检测[J]. 广东电力, 2023, 36(5): 105 – 114.
- WANG Zheng, DU Huaiyun, WANG Jinpei, et al. Defect detection of strain clamps in transmission lines based on improved YOLOv4 [J]. Guangdong Electric Power, 2023, 36(5): 105 – 114.
- [14] 张鑫, 叶俊杰, 崔瑶, 等. 基于语义信息距离解耦的变电运维多类别缺陷图像检测[J]. 中国电力, 2023, 56(6): 209 – 218.
- ZHANG Xin, YE Junjie, CUI Yao, et al. Decoupled semantic distance based multi-class defect scene detecting for substations [J]. Electric Power, 2023, 56(6): 209 – 218.
- [15] 刘国特, 周锦辉, 宋新明, 等. 基于超分辨率注意力机制改进的GIS内部细微缺陷X-DR图像检测方法[J]. 高电压技术, 2021, 47(11): 3803 – 3809.
- LIU Guote, ZHOU Jinhui, SONG Xinming, et al. Improved X-DR image detection method for GIS internal defects based on super-resolution attention mechanism [J]. High Voltage Engineering, 2021, 47(11): 3803 – 3809.
- [16] 陈大兵, 魏寒来, 胡铁宁, 等. 碳纤维复合芯导线X射线图像标准化增强与缺陷检测方法[J]. 数据采集与处理, 2020, 35(4): 739 – 744.
- CHEN Dabing, WEI Hanlai, HU Yining, et al. Standardized enhancement and detection of defects in X-ray images of carbon fiber composite core wires [J]. Journal of Data Acquisition and Processing, 2020, 35(4): 739 – 744.
- [17] 宋泽明, 万建成, 朱波, 等. 碳纤维复合材料芯导线芯棒压接不同心问题研究[J]. 复合材料科学与工程, 2022(1): 79 – 85.
- SONG Zeming, WAN Jiancheng, ZHU Bo, et al. Research of aluminum conductor composite core crimping with non-concentricity [J]. Composites Science and Engineering, 2022 (1): 79 – 85.
- [18] 吕占杰. X射线数字成像技术在电力金具及导线检测中的应用研究[D]. 北京: 华北电力大学, 2015.
- [19] 赵启轩. 深度学习在电力设备耐张线夹缺陷检测中的应用研究[D]. 成都: 电子科技大学, 2020.
- [20] 李鹏吾, 刘荣海, 周静波, 等. 基于深度学习的耐张线夹压接缺陷X射线影像智能识别[J]. 南方电网技术, 2022, 16(3): 126 – 133.
- LI Pengwu, LIU Ronghai, ZHOU Jingbo, et al. X-ray image intelligent recognition of crimping defects of strain clamps based on deep learning [J]. Southern Power System Technology, 2022, 16(3): 126 – 133.
- [21] 国家电网有限公司科技部. 输电线路金具压接质量X射线检测技术导则: Q/GDW 11793—2017[S]. 北京: 国家电网有限公司, 2018.
- [22] 卢祖文. 基于X光图像与深度学习的耐张线夹缺陷识别[D]. 南昌: 南昌大学, 2022.
- [23] 中国电力企业联合会. 输变电工程架空导线(800 mm²以下)及地线液压压接工艺规程: DL/T 5285—2018[S]. 北京: 中国电力出版社, 2019.
- [24] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021 [EB/OL]. (2021 – 08 – 06) [2023 – 05 – 05] <https://arxiv.org/abs/2107.08430>.
- [25] HE K M, ZHENG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904 – 1916.
- [26] 邱志斌, 朱轩, 廖才波, 等. 基于目标检测的电网涉鸟故障相关鸟种智能识别[J]. 电网技术, 2022, 46(1): 369 – 377.
- QIU Zhibin, ZHU Xuan, LIAO Caibo, et al. Intelligent recognition of bird species related to power grid faults based on object detection [J]. Power System Technology, 2022, 46(1): 369 – 377.
- [27] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]//IEEE Conference on Computer Vi-

- sion and Pattern Recognition (CVPR), June 18 – 23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 8759 – 8768.
- [28] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]// Proceedings of the European Conference on Computer Vision (ECCV), September 8 – 14, 2018, Munich, Germany. Berlin: Springer, 2018: 3 – 19.
- [29] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22 – 29, 2017, Venice, Italy. New York: IEEE, 2017: 618 – 626.
- 收稿日期: 2023-10-07; 网络首发日期: 2024-04-22
- 作者简介:
- 李俊轩(1997), 男, 硕士研究生, 研究方向为输电线路图像识别与智能运维, 1139810826@qq.com;
- 邱志斌(1991), 男, 博士后, 副教授, 学士, 研究方向为输变电设备外绝缘、电力视觉与人工智能、电磁场数值计算, qiuzb@ncu.edu.cn;
- 石大寨(1997), 男, 硕士, 研究方向为输电线路图像识别与智能运维, 1424173242@qq.com。

(上接第 149 页 Continued from Page 149)

- [28] 宋绍漫. 连续波光腔衰荡光谱装置及痕量甲烷检测研究[D]. 长春: 中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2019.
- [29] 王振. 可调谐激光吸收光谱高灵敏度测量方法及应用研究[D]. 北京: 清华大学, 2020.
- [30] TANG Jing, LI Bincheng, WANG Jing. High-precision measurements of nitrous oxide and methane in air with cavity ring-down spectroscopy at 7.6 μm [J]. Atmosphere Measurement Techniques, 2019, 12(5), 2851 – 2861.
- [31] 唐靖. 基于光腔衰荡光谱的痕量气体高灵敏检测技术[D]. 成都: 电子科技大学, 2019.
- [32] 韩旭涛, 史天一, 王昊天, 等. 基于实体GIS设备试验的局部放电光学信号传播特性研究[J]. 广东电力, 2024, 37(3): 82 – 89.
- HAN Xutao, SHI Tianyi, WANG Haotian, et al. Study on propagation characteristics of partial discharge optical signals based on physical GIS equipment testing [J]. Guangdong Electric Power, 2024, 37(3): 82 – 89.
- [33] 宋绍漫, 颜昌翔. 基于光腔衰荡光谱技术的痕量甲烷检测[J]. 光谱学与光谱分析, 2020, 40(7): 2023 – 2028.
- SONG Shaoman, YAN Changxiang. Trace methane detection based on cavity ring-down spectroscopy [J]. Spectroscopy and Spectrum Analysis, 2020, 40(7): 2023 – 2028.
- [34] LI Zhe, YANG Shuang, ZHANG Zhirong, et al. High-sensitivity methane monitoring based on quasi-fundamental mode matched continuous-wave cavity ring-down spectroscopy [J]. Chinese Physics B, 2022, 31(9): 4207 – 4218.
- [35] JIANG Anhao, QIAN Wenchao, SONG Jinhai, et al. Wavelength-modulation cavity ring-down spectroscopy for SF_6 characteristic decomposition component H_2S sensing [C]//IEEE International Symposium on High Voltage Engineering (ISH), August 28-September 1, Glasgow, UK. New York: IEEE, 2023: 73 – 78.
- [36] 邹可园, 朱珉, 张潮海. 光腔衰荡光谱法检测 SF_6 以及 SF_6/N_2 混合载气下的痕迹 H_2S [J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2022, 39(S1): 113 – 119.
- ZOU Keyuan, ZHU Min, ZHANG Chaohai, et al. Detection of trace H_2S in SF_6 and mixed SF_6/N_2 carrier gas by optical cavity decay spectroscopy [J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2022, 39(S1): 113 – 119.
- 收稿日期: 2023-10-25; 网络首发日期: 2024-05-06
- 作者简介:
- 张欣冉(1999), 女, 硕士研究生, 研究方向为高压设备与智能诊断技术, xinran_zhang@nuaa.edu.cn;
- 吴芳芳(1979), 女, 高级工程师(教授级), 硕士, 研究方向为智能状态检测与诊断评估, 13819198545@163.com;
- 张潮海(1963), 男, 通信作者, 教授, 博导, 博士, 研究方向为特高压输变电技术(GIS/GIL)、智能状态检测与诊断评估、大功率能量变换技术和脉冲功率与等离子技术, zhangchaohai@nuaa.edu.cn。