

DOI: 10.19783/j.cnki.pspc.230852

基于密集连接网络的航拍绝缘子旋转目标精准定位方法

王道累, 张正刚, 张世恒, 朱瑞, 赵文彬

(上海电力大学计算机科学与技术学院, 上海 201306)

摘要: 为了实现架空线路巡检时绝缘子的精准定位和检测, 提出了一种基于 Dense-Block 密集连接块与旋转框改进 YOLOv5 的绝缘子检测模型。该模型针对绝缘子长宽比较大和方向多变的特点, 提出利用长边定义法为检测框增加角度信息, 实现目标旋转框检测, 有效提升绝缘子检测和定位的效果。同时为了增强特征的重新利用和传播, 利用 Dense-Block 对模型中的残差模块进行改进, 构建 YOLOv5-dense 检测模型。最后为了使 YOLOv5-dense 模型能够更加关注有效的特征信息, 在主干网络尾部加入 SimAM 注意力模块对模型进行改进。实验之前, 利用 Retinex 算法对输入绝缘子图像进行增强。实验结果表明, 相较于原始 YOLOv5 算法, 所提算法在平均准确率和每秒处理帧数方面都有提高。除此之外, 与水平框检测算法相比, 所提算法去除了检测结果中大量冗余的背景信息, 实现了绝缘子区域更加精准的定位。

关键词: 绝缘子; 目标检测; 数据增强; YOLOv5; 旋转框; 密集连接块

Accurate positioning method of insulator rotating target in aerial photography based on dense connection network

WANG Daolei, ZHANG Zhenggang, ZHANG Shiheng, ZHU Rui, ZHAO Wenbin

(College of Computer Science and Technology, Shanghai University of Electric Power, Shanghai 201306, China)

Abstract: In order to realize the accurate positioning and detection effect of insulators during circuit inspection, this paper proposes an improved YOLOv5 insulator detection model based on Dense-Block and rotating frame. Aiming at the characteristics of large length width ratio and changeable direction of insulator, this model proposes to use the long side definition method to add angle information to the detection frame, realize the target rotation frame detection, and effectively improve the effect of insulator detection and positioning. At the same time, in order to enhance the reuse and propagation of features, this paper uses dense block to improve the residual module in the model and build YOLOv5-dense detection model. Finally, in order to enable the YOLOv5-dense model to pay more attention to effective feature information, a SimAM attention module is added at the end of the backbone network to improve the model. Before the experiment, Retinex algorithm is used to enhance the input insulator image. The experimental results show that compared to the original YOLOv5 algorithm, the algorithm proposed has improved average accuracy and processing frames per second. In addition, compared with the horizontal frame detection algorithm, this algorithm removes a large amount of redundant background information in the detection results, and realizes more accurate positioning of the insulator area.

This work is supported by the National Natural Science Foundation of China (No. 61502297).

Key words: insulator; target detection; data enhancement; YOLOv5; rotating frame; dense connection block

0 引言

当今, 智能化巡检已成为输电线路巡检方式发展的新趋势。输电线路中绝缘子能够支撑导线起到

机械固定作用, 同时也可以防止电流回地^[1-2], 在我国电网中被广泛应用。因此绝缘子的定位也成为了输电线路巡检的一个重要的环节。近年来, 绝缘子的状态信息大多由无人机拍摄采集, 但面对大量的绝缘子航拍图片, 采用人工进行逐一识别的方法无疑是效率低下的。基于计算机技术的目标检测方法

基金项目: 国家自然科学基金项目资助(61502297)

为这一问题的解决提供了研究思路,利用目标检测的方法对绝缘子进行自动的识别定位,为后续航拍绝缘子缺陷诊断^[3]的研究奠定基础。

早期研究人员大多利用传统的目标检测方法对绝缘子进行定位,其主要通过梯度方向直方图(histogram of oriented gradient, HOG)^[4]、尺度不变特征变换(scale invariant feature transform, SIFT)^[5]、快速区域卷积神经网络^[6]等特征提取方法提取图像中绝缘子串的特征,并利用支持向量机(support vector machines, SVM)^[7]、自适应提升(adaptive boosting, Adaboost)^[8]、Mask R-CNN 算法^[9]、改进 U-net 和 CNN^[10]等机器学习的方法进行分类来达到目标检测的效果。文献[11]将绝缘子图片进行色调饱和度亮度(hue saturation intensity, HSI)空间转换,并利用最佳熵阈值分割 S 分量,最后通过连通区域标记的方法将绝缘子分割出来,此方法在定位效果方面还有待提升。文献[12]改进了传统最大间方差阈值分割算法并分割图像背景,根据绝缘子串近似直线的特点,通过检测直线对绝缘子进行粗定位,再运用 AdaBoost 分类算法对粗定位区域识别,实现绝缘子串的细定位,该方法大多适用于自下而上拍摄且背景简单的绝缘子图像,而对背景相对复杂的绝缘子图像定位效果并不十分理想。

近年来,随着深度学习理论的突破,卷积神经网络(convolutional neural networks, CNN)大幅提升了图像识别的准确率^[13],深度学习技术开始不断渗透到各个领域。基于深度学习的绝缘子定位方法也得到了迅速的发展,文献[14]采用多尺度融合的方法改进 Faster R-CNN 二阶段检测算法,并根据绝缘子形状特点改进锚框的比例,从而达到对绝缘子的精确定位。文献[15]在 YOLOv3 单阶段检测算法构建一个多尺度特征金字塔,将其与主干网络进行融合,可在提高检测准确率的同时满足实时性的检测要求。文献[16]通过在 YOLOv5 特征提取网络中嵌入非对称卷积模块,从而得到更加具备辨识性及鲁棒性的视觉特征。文献[17]使用单点多盒探测器(single shot multiBox detector, SSD)轻量化目标检测算法来代替传统的人工特征提取器,从而实现瓷质和复合两类绝缘子的定位。文献[18]基于 YOLOv5 网络结合通道注意机制和空间注意机制设计特征平衡网络,以通道权值和空间权值作为引导,实现检测网络不同层次特征之间语义信息和空间信息的平衡。

然而,这些方法通常很少对绝缘子串的形状特征进行考虑,存在绝缘子定位精度差的问题。因此,本文提出了一种绝缘子精准定位方法 YOLOv5-dense。在 YOLOv5 的基础上,增加了识别框角度

参数,实现绝缘子旋转框定位,提高模型特征提取及定位效果。同时,在特征融合模块中加入密集连接结构,在主干网络中添加 SimAM 注意力模块,提升模型针对绝缘子定位的整体性能。

1 图像增强算法

采集的图像通常存在颜色暗淡、对比度低的情况,导致有效识别的部分信息丢失,本文采用 Retinex 算法对训练集中的图像进行增强处理。该算法在 1963 年被 Edwin.H.Land 提出。物体通过反射红、绿和蓝光来确定色彩,而非反射光强来确定,光的不均匀性是固定不变的,并不会干扰物体的颜色。与传统的线性和非线性方法不同,Retinex 算法能够对不同类型的图像进行自适应增强,这主要依赖其提供的边缘增强、颜色恒定以及动态压缩的功能。图 1 为输电线路监控图像增强效果。

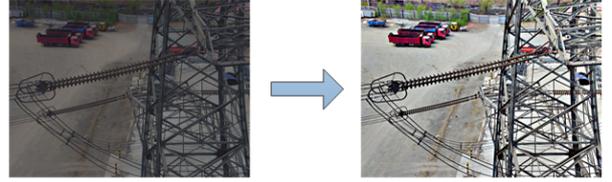


图 1 输电线路监控图像增强效果

Fig. 1 Enhancement effect of transmission line image

Retinex 理论的基本思想是在原始图像中提取出物体本身的反射图像,而尽可能减少光照图像的影响。初始图像 O 等于光照图像 E 乘以反射图像 R ,用公式表示为

$$O(x, y) = R(x, y) \cdot E(x, y) \quad (1)$$

式中, (x, y) 为图像的坐标。

Retinex 算法有单尺度(single scale retinex, SSR)算法和多尺度(multi-scale retinex, MSR)算法。SSR 算法首先将一张 RGB 彩色图像分解为 R、G、B 的数值图像,然后用中心环绕函数分别对每个通道的图像进行滤波,得到光照分量,如式(2)所示。

$$E_i(x, y) = O_i(x, y) * G(x, y) \quad (2)$$

式中: i 表示颜色通道($i = R, G, B$); E_i 表示第 i 个颜色通道的光照分量; O_i 表示第 i 个颜色通道的原始图像; “*” 表示卷积运算; $G(x, y)$ 为高斯环绕函数。然后在对数域中减去光照分量,最后将三通道路数据进行合并得到增强图像。其公式表示为

$$\log(R_i(x, y)) = \log\left(\frac{O_i(x, y)}{E_i(x, y)}\right) = \quad (3)$$

$$\log(O_i(x, y)) - \log(O_i(x, y) * G(x, y))$$

式中, R_i 表示第 i 个颜色通道的反射图像。

通过使用 SSR 算法处理图像, 可以显著提高整体亮度, 特别适用于原始图像亮度极低而导致细节丢失的情况。然而, 对于非极端情况下的图像, 处理后的图像可能会过于明亮, 同时也可能影响对比度, 导致图像偏白或偏灰。

MSR 算法是在 SSR 的基础上进一步发展的, 其优点在于保持图像的高保真度和动态范围压缩的同时, 能增强色彩、保持颜色恒定性, 并实现全局和局部动态范围压缩。该算法的核心思想是利用多个尺度不同的中心围绕函数的加权平均来估算光照分量。MSR 算法的公式表示为

$$\log(R_f(x, y)) = \sum_{k=1}^N \omega_k (\log(O_i(x, y)) - \log(O_i(x, y) \cdot F_k(x, y))) \quad (4)$$

式中: N 表示尺度个数, $N=1$ 即 SSR 算法, 为了同时发挥 SSR 算法中高尺度和低尺度的优点, MSR 算法通常选择尺度个数, 一般取 3。通过使用 3 个不同尺度的高斯滤波器对原始图像进行滤波处理, 可以获得较好的效果; ω_k 表示第 k 个尺度在进行加权时的加权系数, 满足式(5); $F_k(x, y)$ 表示在第 k 个尺度上的高斯滤波函数, 如式(6)所示。

$$\sum_{k=1}^N \omega_k = 1 \quad (5)$$

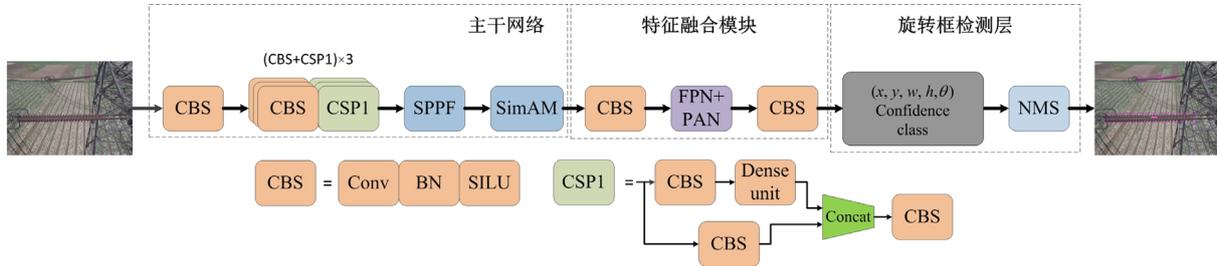


图 2 YOLOv5-dense 检测模型

Fig. 2 YOLOv5-dense detection model

主干网络对输入的样本图像进行特征提取, 本文将主干网络跨阶段部分连接(cross stage partial connections, CSP1)^[19]模块中的残差结构替换成了密集连接结构, 即 Dense unit^[20]。相较于残差结构, Dense unit 更加有利于绝缘子小数据集的训练, 能够更好地缓解梯度消失问题, 以及有效降低参数量, 提升模型的整体性能。这些特点让 Dense unit 在参数和计算成本更少的情形下实现比残差结构更优的性能。特征融合模块使用特征金字塔网络(feature pyramid network, FPN)、路径聚合网络(path aggregation network, PAN)^[21]结构对主干网络输出的不同尺度特征图进行特征融合, 增强特征图的信息表达。旋

$$F_k(x, y) = \frac{1}{\sqrt{2\pi}c_k} \exp\left(-\frac{x^2 + y^2}{2c_k^2}\right) \quad (6)$$

式中, c_k 为高斯环绕函数的尺度参数。

2 模型改进

2.1 YOLOv5 原理

YOLOv5 是一种基于深度学习的目标检测算法, 核心思想是将目标检测任务转化为一个回归问题, 并通过一个单一的神经网络同时进行目标的位置定位和分类。

在 YOLOv5 中的模型结构采用了轻量级的模型结构, 它由卷积层、池化层和上采样层构成, 没有使用传统的全连接层, 这样减少了参数数量和计算量。此外 YOLOv5 采用了多尺度检测策略, 可以在不同尺度的特征图上进行目标检测, 从而提高了对不同目标的检测能力。在损失函数上, 使用的是二元交叉熵损失函数, 且为每个特征层的损失增加了不同的权重。

2.2 YOLOv5-dense 网络结构

在航拍图像中绝缘子往往具有排列紧密且方向多变的特征, 针对此特征, 设计了 YOLOv5-dense 绝缘子定位模型, 如图 2 所示, 它主要由 3 个部分组成: 主干网络、特征融合模块以及旋转框检测层。

转框定位层是将模型最终目标分类和定位等信息进行分析输出, 本文针对绝缘子方向多变的特点, 在定位框信息中增加了角度参数, 有效地降低了特征提取时冗余背景信息含量, 同时能够更加精确地定位绝缘子的位置, 提升了模型的目标定位效果。最后通过非极大值抑制(non max suppression, NMS)^[22]去除重复定位框, 输出最终定位结果。

2.3 目标框定位方法改进

边框标注的方式有多种, 但标注方式越精准提供给网络训练的冗余信息就越少。同时, 充分的先验知识会减少网络的可学习方案数量, 从而约束网络的训练方向并减少收敛时间。借鉴文献[23]中的

遥感目标旋转框定位方法, 本文对 YOLOv5 模型进行了旋转框改进, 常见任意旋转框的定义方法主要分为 3 种: Open_CV 定义法、长边定义法和有序四边形定义法。相较于另外两种方法, 长边定义法运算更加简单, 计算损失值所面对的问题也相对较少。长边定义法需要 5 个标注框参数: x 、 y 、 w 、 h 、 θ 。 θ 是指识别框较长的边与 x 轴所成的夹角, θ 的范围为 $[-180^\circ, 0^\circ]$ 。但因为角度连续性, 角度在边界处会出现差值突增, 导致损失值突增和学习难度增大, 如图 3 所示。

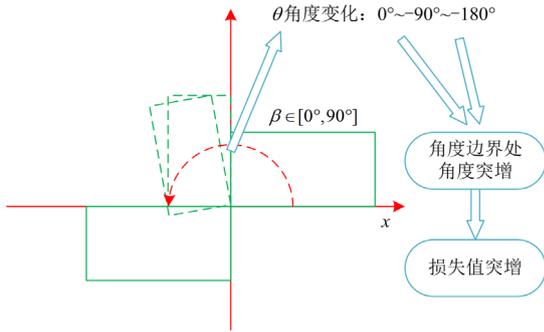


图 3 角度突增

Fig. 3 Sudden increase of angle

为解决此问题, 引入环形平滑标签(circular smooth label, CSL)^[24], 将回归问题转换为分类问题, 从而避免角度突变导致的损失值突变, 如图 4 所示。将连续化转化为离散化, 必定会存在一定的精度损失, 探究此方法的可行性, 需要计算出离散化带来的精度损失对最终定位结果的影响。

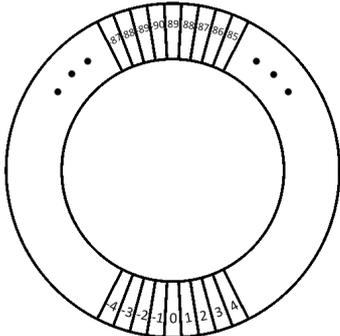


图 4 环形平滑标签示意图

Fig. 4 Schematic diagram of circular smooth label

当一度归为一类情况下的精度最大损失和精度平均损失分别为式(7)和式(8)。

$$\text{Max}(loss) = \frac{\omega}{2} \quad (7)$$

$$E(loss) = \int_a^b x \cdot \frac{1}{b-a} dx = \frac{\omega}{4} \quad (8)$$

式中, ω 代表整数度数, 也是看作度数为 ω 的一个类, b 和 a 均代表某一角度。

通过计算, 当 $\omega=2$ 时, 精度最大损失为 1, 平均损失为 0.5, 绝缘子串长宽比较大, 在标注时标注框的长宽比平均可以达到 1: 9。如果两个绝缘子标注框角度相差 0.25 和 0.5, 则预测框与真实框交并比计算时会下降 0.02 和 0.05 左右, 这对绝缘子定位效果的影响是很小的。所以此方法可以有效解决角度边界连续导致角度突增的问题。环形平滑标签的表达式为

$$C_{sl}(x) = \begin{cases} g(x), & \theta - r < x < \theta + r \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

式中: $g(x)$ 为窗口函数, 窗口半径由 r 来控制; θ 为当前边界框的角度。

YOLOv5 的损失函数主要由 3 部分构成, 分类损失、定位损失以及置信度损失。分类损失使用二元交叉熵损失, 具体损失函数公式为

$$\begin{cases} y_i = \text{Sigmoid}(x_i) = \frac{1}{1 + e^{-x_i}} \\ L_{\text{class}} = - \sum_{n=1}^{N_{\text{class}}} y_i^* \log(y_i) + (1 - y_i^*) \log(1 - y_i) \end{cases} \quad (10)$$

式中: Sigmoid 为激活函数的名称; N_{class} 为类别总个数; x_i 为当前类别预测值; y_i 为经过激活函数后得到的当前类别的概率; y_i^* 为当前类别的真实值(0 或 1); L_{class} 为分类损失。

定位损失使用了 GIoU_Loss 损失计算函数, 如式(11)所示。

$$\begin{cases} G_{\text{IoU}} = I_{\text{oU}} - \frac{|C - (B \cup B_{\text{gt}})|}{|C|} \\ L_{\text{GLoU}} = 1 - I_{\text{oU}} + \frac{|C - (B \cup B_{\text{gt}})|}{|C|} \end{cases} \quad (11)$$

式中: I_{oU} 表示真实框与预测框之间的交并比; B 表示预测框区域; B_{gt} 表示真实框区域; C 表示预测框与真实框的最小外接矩形。

置信度损失同样采用了交叉熵损失, 如式(12)所示。

$$L_{\text{conf}} = \sum_{i=0}^{s^2} \sum_{j=0}^B \ell_{ij}^{\text{obj}} [(C_i - \hat{C})^2] + \lambda_{\text{noobj}} \sum_{i=0}^{s^2} \sum_{j=0}^B \ell_{ij}^{\text{noobj}} [(C_i - \hat{C}_i)^2] \quad (12)$$

式中: s^2 表示预测框; C_i 为置信度得分; \hat{C} 为预测框与真实框的交叉部分, 当在一个单元格中有对象时, ℓ_{ij}^{obj} 取 1, 否则取 0, 即 ℓ_{ij}^{noobj} 取 0; λ_{noobj} 表示权

重系数, 可以减少无对象损失计算部分的权重。

由于增加了环形平滑标签, 需要对预测框角度部分进行损失计算。角度信息的加入对分类损失和置信度损失关联较小, 故只须对定位损失做出修改, 修改后的定位损失函数为

$$L = \frac{\lambda_1}{N} \sum_{n=1}^N obj_n \sum_{j \in \{x, y, w, h, \theta_{reg}\}} L_{reg}(v'_{nj}, v_{nj}) + \frac{\lambda_2}{N} \sum_{n=1}^{N_{anchor}} L_{CSL}(\theta'_n, \theta_n) + \frac{\lambda_3}{N} \sum_{n=1}^N L_{class}(p_n, t_n) \quad (13)$$

式中: N_{anchor} 为锚点的数量; obj_n 为二进制值, 对于正样本取 1, 对于负样本取 0; v_{nj} 为目标真值; v'_{nj} 为预测的偏移量; θ_n 为标注框的角度; θ'_n 为预测框的角度; t_n 为识别对象的种类标签; p_n 为通过 Sigmoid 函数计算得到识别对象标签值分布; λ_1 、 λ_2 、 λ_3 为超参数, 其中 $\lambda_1 = 1$ 、 $\lambda_2 = 0.5$ 、 $\lambda_3 = 1$; L_{reg} 表示回归损失; L_{CSL} 表示通过 Sigmoid 函数计算的交叉熵损失。

2.4 特征提取网络改进

由于网络开源绝缘子数据集较少, 网络在训练时容易产生过拟合现象, 严重影响模型的定位精度, 同时模型大量的参数也会使得定位速度变低。为此, 使用 Dense-Block^[20]对特征提取网络中 Res-Block^[25]进行改进。Res-Block 和 Dense-Block 的结构分别如图 5、图 6 所示。

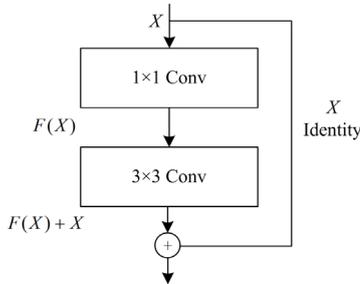


图 5 Res-Block 结构

Fig. 5 Res-Block structure

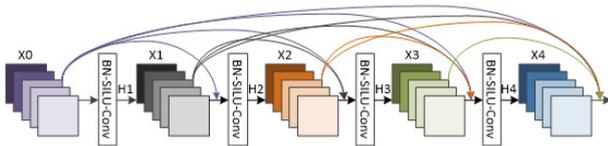


图 6 Dense-Block 结构

Fig. 6 Dense-Block structure

原网络中使用 Res-Block 残差模块将输入与输出进行相加作为下一层的输入, 解决了因网络加深而产生的网络退化问题。但针对小规模的绝缘子数

据集, 单层相加的残差模块表现性能较差。为此, 选择对特征进行更加密集融合的 Dense-Block 对其进行替换, 其表达式定义为

$$X_t = Ht([X_0, X_1, \dots, X(t-1)]) \quad (14)$$

其中 $[X_0, X_1, \dots, X(t-1)]$ 是将 $X_0, X_1, \dots, X(t-1)$ 层拼接后的特征图, $H_1, H_2, \dots, H_i, \dots, H_t$ 是特征图的拼接函数, 函数 $H_i (i = 1, 2, 3, 4)$ 由 BN 批量归一化、SiLU 激活函数以及 Conv 卷积组成。

Dense-Block 是在 Res-Block 残差连接的基础上发展而来的, 它的特点是每一层都与之前的所有层相连。这种设计使得信息在各层之间的流动达到最大化, 有效地缓解了梯度消失问题。同时, Dense-Block 每一次卷积输入输出的通道个数较少, 在模型参数量上也实现了一定的优化, 提升了网络对于绝缘子定位的精度和速度。

2.5 SimAM 注意力机制

用于目标检测中的注意力机制, 目的是寻找特征图中对定位有利的显著特征, 并通过调整权重的方式增加对其的关注度。

SimAM 注意力模块是基于神经科学理论提出的无参数化的 3-D 注意力模块, 它与通道注意力和空间注意力模块不同, 它无须向原始网络添加参数, 只须通过一个能量函数来计算注意力权重, 因此其具有轻量高效的优点, 结构图如图 7 所示。

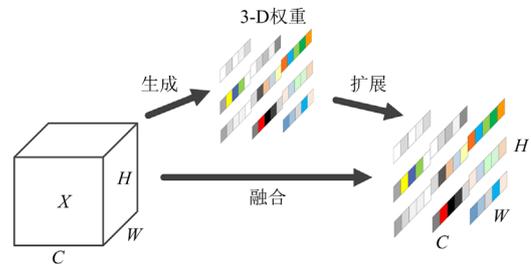


图 7 SimAM 注意力模块

Fig. 7 SimAM module of attention

SimAM 注意力模块通过度量神经元之间的线性可分性来评估每个神经元的重要性, 因此定义了如式(15)所示的能量函数。

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (15)$$

式中: t 为神经元; λ 为超参数; $\hat{\mu}$ 和 $\hat{\sigma}^2$ 表示形式如(16)、式(17)所示。

$$\hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i \quad (16)$$

$$\hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu})^2 \quad (17)$$

式中： x_i 为神经元 t 周围的神经元； M 为每个通道上值的数量， $M = H \times W$ ，其中 H 和 W 分别为图像的高和宽。最后对选择出的特征进行增强处理，处理过程如式(18)所示。

$$\hat{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (18)$$

式中， E 为 e_i^* 在所有通道和空间维度上的汇总。

与其他方式的注意力模块不同，SimAM 注意力模块能够在不增加网络参数数量的情况下，利用能量函数对网络中的每个单独神经元进行重要性评估，并根据评估结果对权重进行调整。将 SimAM 模块放入模型不同位置并进行实验，最终发现 SimAM 模块加在主干网络最后一层时效果最好。

3 实验结果与分析

3.1 数据集制作

本文所采用的数据集来源于无人机巡检和人工巡检所拍摄的图片，共收集绝缘子图片 1848 张。由于绝缘子图片较少，会影响模型的训练效果，故本文利用旋转、增加噪声、色彩抖动、调整亮度、增加掩膜、Retinex 算法等数据增强的方法对已有绝缘子数据集进行扩充，扩充效果如图 8 所示，最后获得绝缘子样本图片 4854 张。训练时将数据集按照 8:2 的比例分为训练集和验证集。



图 8 数据增强

Fig. 8 Data enhancement

3.2 实验环境

本文采用 PyTorch 深度学习框架和 Python 编程语言，测试使用 NVIDIA Tesla K80(16 G 显存)显卡，操作系统为 Ubuntu16.04，训练时输入网络的图片像素大小为 1024×1024 ；batch size 大小为 4；初始学习率设为 10^{-2} ，共训练 150 个 epochs。

3.3 网络训练

结合上述实验环境，对本文算法进行实验，实验各项损失图如图 9 所示。从图中可以看出，在迭代 100 次之后，总损失开始下降缓慢，在迭代 150 次之后总损失趋于平稳，此时即可对模型权重进行保存。

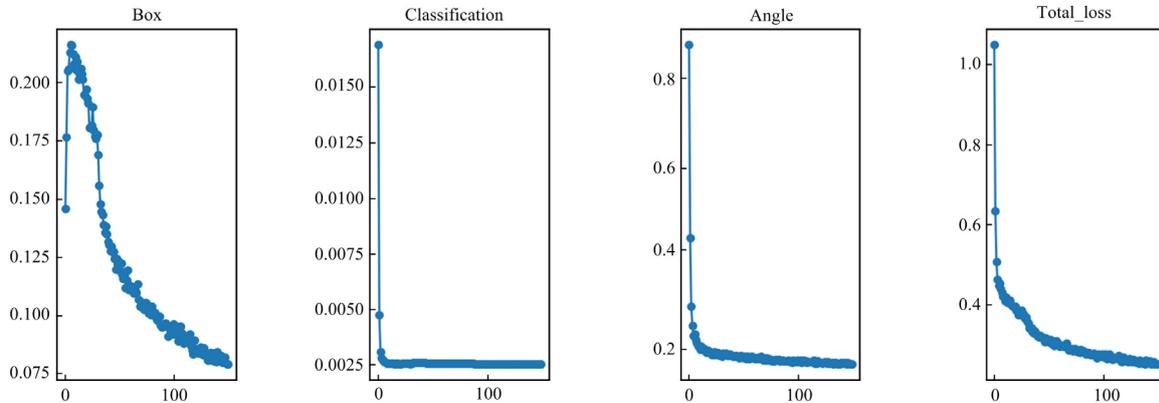


图 9 训练损失图

Fig. 9 Training loss chart

3.4 实验结果分析

3.4.1 不同模型对比试验

利用制作的数据集对本文算法和 YOLOv5 算法进行定位对比，定位效果如图 10 所示。从图中可以看出，YOLOv5 算法在检测中出现了漏检以及绝缘子定位不全的问题，相比之下，本文算法可以精确定位绝缘子，同时由于加入了角度信息，对图中绝缘子区域定位更加准确，有助于后续的人工判别

以及对绝缘子缺陷识别的深入研究。



(a) YOLOv5检测效果



(b) YOLOv5-dense检测效果

图 10 定位效果对比

Fig. 10 Comparison of test results

另外加入一些常用的目标检测算法, 如单阶段目标检测算法 YOLOv3、EfficientDet, 两阶段目标检测算法 Faster R-CNN 以及 anchor free 目标检测算法 CenterNet、YOLOX、YOLOv6^[26], 还有 Transformer 目标检测系列算法中的 DN-DERT^[27]模型, 此外还有目前常用的旋转框算法 SCRDet^[23]模型, 与本文算法进行多元对比分析。各算法训练结

果如表 1 所示。

在网络模型训练过程中, 希望模型可以同时拥有较高的精确率和召回率, 但由于它们的计算方式不同, 导致两者结果会相互制约, 而平均准确率 (mAP) 可以兼顾精确率和召回率, 并给出调和结果。故本文将采用平均准确率作为不同模型性能之间对比的评价指标。

由表 1 数据可知, 本文提出的改进 YOLOv5 算法的平均准确率高其他对比算法, 相比于原始 YOLOv5 算法, mAP 提高了 4.1%, 同时 FPS(每秒内可处理图片数量)也提高了 17.9%。Faster R-CNN 由于采用了两阶段的定位方式, 利用 Anchor 提前生成候选区域, 所以在定位准确率方面和本文算法接近, 但两阶段定位的设计大大增加了网络运算的参数数量, 导致其定位速度大大降低, 具体 FPS 可参照表 1, 所以综合考虑, 本文算法较 Faster R-CNN 更适用于实际应用。

表 1 实验数据对比表

Table 1 Comparison table of experimental data

模型	主干网络	输入大小	mAP-50/%	FPS/(帧/s)	参数量
YOLOv3	DarkNet53	640×640	90.2	13.1	235M
YOLOX	DarkNet53	640×640	94.1	18.9	57.6M
EfficientDet	EfficientNet-B0	640×640	82.5	14.4	15.1M
CenterNet	ResNet50	640×640	92.7	16.3	125M
DN-DERT ^[27]	Cross-Attention	640×640	94.9	11.5	65M
YOLOv5	CSPdarkent53	640×640	92.8	19.6	54.4M
YOLOv6 ^[26]	CSPStackRep	640×640	95.1	20.3	58.6M
Faster R-CNN	ResNet50	640×640	96.6	3.3	315M
SCRDet	ResNet50	640×640	94.8	4.5	287M
本文算法	改进 CSPdarkent53	640×640	96.9	23.1	42.7M

3.4.2 不同注意力模块消融试验

为了验证与其他注意力模块相比, SimAM 注意力模块的高效和轻量性, 本文在其他改进方法不变的情况下, 在模型主干网络尾部分别加入卷积注意力模块(convolutional block attention module, CBAM)、挤压和激励注意力模块(squeeze and excitation, SE)、有效的信道注意力机制(efficient channel attention, ECA)和 SimAM 注意力模块构建出不同的 4 组实验进行对比, 实验结果如表 2 所示。

表 2 不同注意力模块对比实验

Table 2 Comparative experiment of different attention modules

注意力模块	mAP-50/%	FPS/(帧/s)	参数量
CBAM	96.2	20.8	48.2M
SE	95.3	21.5	47.8M
ECA	95.6	22.7	43.1M
SimAM	96.9	23.1	42.7M

由表 2 可知, 加入 SimAM 注意力模块后的模型对于绝缘子的定位精度均优于其他 3 组实验模型, 同时由于 SimAM 注意力模块的加入并不会带来参数数量的增加, 因此在模型轻量化方面, 该方法的表现更加突出。

3.4.3 模型改进消融试验

为了探究不同改进方法对模型性能的影响, 本文分别设置 4 组实验进行对比, 实验 1 为原始 YOLOv5 网络, 实验 2、3、4 依次在原始网络的基础上加入旋转框改进、Dense-Block 改进以及 SimAM 注意力模块改进。4 组实验分别在所构建绝缘子数据集上以相同参数设置进行训练实验, 结果如表 3 所示。

实验 2 是在 YOLOv5 定位框中增加了定位框角度参数, 实现多角度的旋转框定位方法, 改进后的 mAP 比原始网络提高了 2.5%, 但参数的增加导致 FPS

表 3 消融实验结果

Table 3 Results of ablation experiment

模型	旋转框	Dense-Block	SimAM	mAP-50/%	FPS/(帧/s)	参数量
实验 1				92.8	19.6	54.4M
实验 2	✓			95.3	18.4	55.8M
实验 3	✓	✓		96.5	23.2	42.7M
实验 4	✓	✓	✓	96.9	23.1	42.7M

定位速度降低了 6.1%。实验 3 在实验 2 的基础上将 Res-Block 替换成了 Dense-Block，相较于实验 2，mAP 提升了 1.2%，速度提升了 26%，主要由于 Dense-Block 使用了更加密集的连接方式，增强了特征重用与特征传播，提高了网络定位精度，同时减少每层的通道数，降低了网络参数量。实验 4 在实验 3 的基础上增加了 SimAM 注意力模块，在不增加网络参数量的情况下提升了网络对绝缘子目标的定位精度，可以看出改进后的 mAP 增加了 0.4%，检测速度与参数量变化不大。通过表 2 可知，本文提出的 3 种改进方法均不同程度地提升了模型的定位精度，优化了模型针对绝缘子定位的性能。

4 结论

本文针对无人机航拍输电线路图像中绝缘子自动识别和定位的算法进行了研究，通过分析绝缘子串所具有的独特形状特征，对 YOLOv5 模型进行改进，引入定位框角度参数，精确提取了绝缘子特征信息，mAP 相较之前提升了 2.5%。同时利用 Dense-Block 密集连接结构对特征提取模块进行改进，增加各特征层间的信息流动，丰富特征信息含量，其 mAP 比之前提高了 1.2%，同时定位速度也提升了 26%。最后在模型中添加 SimAM 注意力模块，使模型更加关注有利于定位的特征信息，mAP 提升了 0.4%，最终模型针对绝缘子的平均定位精度达到 96.9%，定位速度达到 23.1 帧/s。实验结果表明，本文所提改进算法能够在绝缘子定位领域取得较好的效果，说明了利用深度学习简化电力巡检过程的可行性。

参考文献

- [1] 文劲宇, 周博, 魏利岫. 中国未来电力系统储电网初探[J]. 电力系统保护与控制, 2022, 50(7): 1-10.
WEN Jinyu, ZHOU Bo, WEI Lishen. Preliminary study on an energy storage grid for future power system in China[J]. Power System Protection and Control, 2022, 50(7): 1-10.
- [2] 黄雄峰, 颜城, 姜岚, 等. 特高压输电线路新型碳纤维更换绝缘子闭式卡具力学性能研究[J]. 高压电器, 2021, 57(4): 172-180.
- [3] HUANG Xiongfeng, YAN Cheng, JIANG Lan, et al. Study on mechanical properties of new carbon fiber replacement insulator closed clamps for UHV transmission lines[J]. High Voltage Apparatus, 2021, 57(4): 172-180.
- [3] 何宁辉, 王世杰, 刘军福, 等. 基于深度学习的航拍图像绝缘子缺失检测方法研究[J]. 电力系统保护与控制, 2021, 49(12): 132-140.
- [4] HE Ninghui, WANG Shijie, LIU Junfu, et al. Research on infrared image missing insulator detection method based on deep learning[J]. Power System Protection and Control, 2021, 49(12): 132-140.
- [4] KIM S, CHO K. Efficient pedestrian detection using multi-scale HOG features with low computational complexity[J]. IEICE Transactions on Information & Systems, 2014, 97(2): 366-369.
- [5] 方路平, 何杭江, 周国民. 目标检测算法研究综述[J]. 计算机工程与应用, 2018, 54(13): 11-18.
- [5] FANG Luping, HE Hangjiang, ZHOU Guomin. Research overview of object detection methods[J]. Computer Engineering and Applications, 2018, 54(13): 11-18.
- [6] 魏业文, 李梅, 解园琳, 等. 基于改进 Faster-RCNN 的输电线路巡检图像检测[J]. 电力工程技术, 2022, 41(2): 171-178.
- [6] WEI Yewen, LI Mei, XIE Yuanlin, et al. Transmission line inspection image detection based on improved Faster-RCNN[J]. Electric Power Engineering Technology, 2022, 41(2): 171-178.
- [7] MABROUK O, HLAOUA L, OMRI M N. Exploiting ontology information in fuzzy SVM social media profile classification[J]. Applied Intelligence, 2020(1): 3757-3774.
- [8] ZHOU H, YU G. Research on fast pedestrian detection algorithm based on autoencoding neural network and Ada-Boost[J]. Complexity, 2021(6): 1-17.
- [9] 绳飞, 曹留, 刘玉龙, 等. 基于改进 Mask R-CNN 的复合绝缘子憎水性状态评估方法[J/OL]. 电测与仪表: 1-9 [2023-8-13]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20221019.1708.018.html>.
- [9] SHENG Fei, CAO Liu, LIU Yulong, et al. Evaluation method of hydrophobicity of composite insulators based on improved Mask R-CNN[J/OL]. Electrical Measurement & Instrumentation: 1-9[2023-08-13]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20221019.1708.018.html>.
- [10] 李俊, 任景, 王晔琳, 等. 基于改进 U-net 和 CNN 的绝缘子自爆检测方法研究[J]. 智慧电力, 2021, 49(8): 98-103.
- [10] LI Jun, REN Jing, WANG Yelin, et al. Insulator self-explosion detection method based on improved U-net and

- CNN[J]. Smart Power, 2021, 49(8): 98-103.
- [11] 黄宵宁, 张真良. 直升机巡检航拍图像中绝缘子图像的提取算法[J]. 电网技术, 2010, 34(1): 194-197.
HUANG Xiaoning, ZHANG Zhenliang. A method to extract insulator image from aerial image of helicopter patrol[J]. Power System Technology, 2010, 34(1): 194-197.
- [12] ZHANG N, TIAN Y, JIA H. Research and application of insulator detection method based on information fusion of inspection characteristic quantity[J]. DEStech Transactions on Engineering and Technology Research, 2017: 1-5.
- [13] 蒲天骄, 乔骥, 韩笑, 等. 人工智能技术在电力设备运维检修中的研究及应用[J]. 高电压技术, 2020, 46(2): 369-383.
PU Tianjiao, QIAO Ji, HAN Xiao, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. High Voltage Engineering, 2020, 46(2): 369-383.
- [14] ZHAO Z, ZHEN Z, ZHANG L, et al. Insulator detection method in inspection image based on improved faster R-CNN[J]. Energies, 2019, 12(7).
- [15] 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): 132-139.
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): 132-139.
- [16] 杨乐, 郭一鸣, 霍勇博, 等. 改进 YOLOv5 在电力生产违规穿戴检测中的应用[J]. 电力系统保护与控制, 2023, 51(14): 160-168.
YANG Le, GUO Yiming, HUO Yongbo, et al. Application of improved YOLOv5 for illegal wearing detection in electric power construction[J]. Power System Protection and Control, 2023, 51(14): 160-168.
- [17] TAN J. Automatic insulator detection for power line using aerial images powered by convolutional neural networks[J]. Journal of Physics: Conference Series, 2021, 1748(4): 042012.
- [18] 张焕龙, 齐企业, 张杰, 等. 基于改进 YOLOv5 的输电线路鸟巢检测方法研究[J]. 电力系统保护与控制, 2023, 51(2): 151-159.
ZHANG Huanlong, QI Qiye, ZHANG Jie, et al. Bird nest detection method for transmission lines based on improved YOLOv5[J]. Power System Protection and Control, 2023, 51(2): 151-159.
- [19] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[J]. arXiv e-prints, 2020.
- [20] HUANG G, LIU Z, LAURENS V, et al. Densely connected convolutional networks[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA.
- [21] WEN P, TONG M, DENG Z, et al. Improved helmet wearing detection method based on YOLOv3[J]. Artificial Intelligence and Security, 2020: 670-681.
- [22] NEUBECK A, GOOL L J V. Efficient non-maximum suppression[C] // 18th International Conference on Pattern Recognition (ICPR'06), August 20-24, 2006, Hong Kong, China.
- [23] YANG X, YANG J, YAN J, et al. SCRDet: towards more robust detection for small, cluttered and rotated objects[C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, South Korea.
- [24] YANG X, YAN J, HE T. On the arbitrary-oriented object detection: classification based approaches revisited[J]. International Journal of Computer Vision, 2020: 1340-1365.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [26] LI C, LI L, JIANG H, et al. YOLOv6: a single-stage object detection framework for industrial application[J]. arXiv e-prints arXiv.2209.02976, 2022.
- [27] LI F, ZHANG H, LIU S, et al. DN-DETR: accelerate DETR Training by Introducing query denoising[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-24, 2022, New Orleans, LA, USA.

收稿日期: 2023-07-05; 修回日期: 2023-09-24

作者简介:

王道累(1981—), 男, 博士, 教授, 主要研究方向为计算机视觉、图像处理; E-mail: alfredwdl@sheip.edu.cn

张正刚(1998—), 男, 硕士研究生, 主要研究方向为深度学习、目标检测;

赵文彬(1977—), 男, 通信作者, 博士, 副教授, 主要研究方向为故障诊断、深度学习。E-mail: zhaowenbin@shiep.edu.cn

(编辑 姜新丽)