DOI: 10. 13382/j. jemi. B2206075

# 基于双特征融合的改进 R-CNN 电力小金具缺陷 检测方法研究 \*

叶 飞<sup>1</sup> 骆星智<sup>1</sup> 宋永春<sup>1</sup> 丁国成<sup>1</sup> 杨孝志<sup>1</sup> 谭守标<sup>2</sup> (1. 国网安徽省电力有限公司 合肥 230041;2. 安徽大学 合肥 230601)

摘 要:电力金具作为输电线路中的不可缺少的关键部件,对电力稳定传输提供了保障,一旦电力金具出现缺陷,就会带来巨大的隐患,造成输电设施的损坏甚至大面积停电事故,影响人们的生产和生活。传统的输电线路检修主要依靠人工现场进行巡检,不仅危险程度高,辨识难度也比较大。人工智能识别技术的不断进步,为电力金具的缺陷识别提供了更好的方法。目前Faster-RCNN算法的目标识别准确率高,但对于螺钉等小金具目标物体的识别率相对较低。本文首先通过双特征融合算子提取特征并进行标记后,输入引进混合注意力机制改进的Faster R-CNN模型中,进行特征再提取,融合重合度较高的特征,并进行缺陷的分类和识别,能够对电力小金具中的螺钉进行高效的辨识。实验结果表明,本文双特征融合的改进Faster R-CNN模型相较于传统的Faster R-CNN模型和YOLO模型的提升效果明显,模型的平均准确率提升了5%,平均精度提升了11%,在保障算法实时性的同时对螺钉等电力小金具具有较好的检测效果。

关键词: 电力小金具缺陷识别;深度学习算法;卷积神经网络;Faster R-CNN;特征提取;目标检测

中图分类号: TH865; TN98

文献标识码: A 国家标准学科分类代码: 520.2

# Research on defect inspection of power small fittings based on improved R-CNN and double feature fusion

Ye Fei<sup>1</sup> Luo Xingzhi<sup>1</sup> Song Yongchun<sup>1</sup> Ding Guocheng<sup>1</sup> Yang Xiaozhi<sup>1</sup> Tan Shoubiao<sup>2</sup>
(1. State Grid Anhui Electric Power Co., Ltd., Hefei 230041, China; 2. Auhui University, Hefei 230601, China)

**Abstract:** As an indispensable key component of power transmission lines, power fittings provide a guarantee for stable power transmission. Once the electric power fittings have defects, it will bring huge hidden dangers, causing damage to transmission facilities or even large-scale power failure, affecting people's production and life. The traditional power transmission line maintenance mainly depends on manual on-site maintenance, which is not only dangerous, but also difficult to detect. The continuous progress of AI recognition technology provides a better method for the defect recognition of electric power fittings. At present, the target recognition accuracy of Faster R-CNN is high, but it is relatively low for small target objects such as screws. Firstly, the features are extracted and marked by the double feature fusion operator, then input into the improved Faster R-CNN model with the introduction of mixed attention mechanism for feature re extraction. The features with high coincidence degree are fused, and the defects are classified and recognized, which can effectively identify the screws in the small power fittings. The experiment shows that the improved Faster R-CNN based on dual feature fusion in this paper has obvious improvement effect compared with the traditional Faster R-CNN and YOLO. The average accuracy of the model is improved by 5%, and the average accuracy is improved by 11%, which also ensures the real-time performance of the algorithm identification. It has a good detection effect on small electrical fittings such as screws.

**Keywords**: defect identification of small electric power fittings; deep learning algorithm; convolution neural network; Faster R-CNN; feature extraction; object detection

# 0 引言

电力基础设施的建设和运行是保障电力稳定供应的重要前提。输电是电力基础设施最为关键和繁杂的一环,保障输电线路中基础设施的可靠是稳定输电的必要条件。当前,输电线路的管理和维护是建立在人工巡检的基础上,已经形成了较为完善的巡检制度,虽然能够保障电网输电线路的稳定运行,但由于我国输电线路距离长,人工巡检难度和成本大,效果日益降低[1]。

随着智能化技术在电力系统中的应用日益广泛,输电线路中关键部件和金具的缺陷识别成为主要研究方向。紧固螺钉作为电力金具的一种,是输电线路中使用最多,数量最大,也是故障最为密集的连接部件,由于其体积小,多分布在高空输电线路,不利于缺陷的巡检和管理,导致事故频发<sup>[2]</sup>。因此,本文选取紧固螺钉作为电力小金具进行缺陷的检测和识别研究。一般来说,紧固螺钉的结构大致包括螺钉、螺母、垫片以及卡销,常见故障主要有部件缺失、部件裂痕以及部件锈蚀等,原因多与安装人为因素和自然因素有关,从而使得输电中的事故出现,造成不利影响。

目前的检测手段主要是通过无人机等对输电线路中 的各关键金具进行拍摄,提取图像中的金具部件,通过深 度学习算法进行特征提取并分类识别,具有很好的适用 性[3]。但由于拍摄图像的像素、检测目标的体积、特征提 取方法以及深度学习算法的选择,会导致识别结果存在 不同程度的误差,尤其小目标的识别精度目前仍是研究 的重点。早期的典型物体检测算法是在卷积网络中引入 残差模块,缓解了模型的过拟合问题[4-5];后来 Girshick 等[6] 在传统卷积神经网络基础上进行改进的 R-CNN 算 法,具有较好的特征提取能力和分类识别能力;为了解 决 R-CNN 算法的处理时间效率不高的问题, Girshick 等[7]在此基础上提出了 Fast R-CNN 算法,在实际解决 问题中具有更高的效率,但在候选区提取与特征分类 的时间消耗上不相匹配,无法满足检测中高效分类的 需求。Faster R-CNN 算法[8] 的提出不仅提高了算法的 效率也提升了算法的性能,但此算法无法保证小物体 目标识别准确率。鉴于此,薛阳等[9]提出对图像的像 素增强和扩充数据集后,再进行卷积神经网络的识别, 可以识别高空中拍摄的电力小金具,但整体检测效果 仍不太理想。

本文研究在 Faster R-CNN 网络中融合 HOG 和 LBP 双特征,并引入残差网络和混合注意力机制,突出特征图中的关键信息,丰富全局信息,较为显著的提高了电力小金具的识别准确率。

## 1 双特征融合

#### 1.1 HOG 特征算子

HOG 即为方向梯度直方图 (histogram of oriented gradient, HOG)特征算子[10-11],是目前使用较多的处理图像、识别目标的特征算子,由基本的连通区域为最小单元,4个最小单元构成块,块的基本功能是在检测窗口中有序移动以便完成块内的方向梯度直方图。其中,最小单元的像素为8×8,块的像素则为16×16。其一般原理主要是:

- 1)对原始样本预处理,选择样本的目标窗口;
- 2)对窗口进行标准化、归一化处理,降低外在环境对 样本的影响。标准化处理公式如式(1)所示:

$$G_2(x,y) = G_1(x,y)^{\alpha} \tag{1}$$

其中, $G_1(x,y)$ 为点(x,y)在标准化前的灰度值大小, $G_2(x,y)$ 为标准化后的灰度值大小, $\alpha$ 为标准化系数值,主要是对样本图像的对比度、亮度进行调整,取值范围为[0.1,10]。

3)标准化完成后,对样本图像的各像素点进行梯度 计算,主要是得到样本图像的梯度幅值、梯度方向,公式 分别如式(2)、(3)所示:

$$M(x,y) = \sqrt{(G(x+1,y) - G(x-1,y))^2 + (G(x,y+1) - G(x,y-1))^2}$$
(2)

$$\theta(x,y) = \arctan\left(\frac{(G(x,y+1) - G(x,y-1))}{(G(x+1,y) - G(x-1,y))}\right)$$
(3)

其中,G(x,y)为点(x,y)的灰度值大小,M(x,y)为点(x,y)的梯度幅值, $\theta(x,y)$ 为梯度方向。

- 4)对通过步骤 3)得到的各像素点的梯度方向进行 投影,并选取幅值作为权值,遍历统计出最小单元的 HOG 特征,然后统计块的 HOG 特征;
- 5) 串联样本图像中的各块的 HOG 特征,得出目标窗口的 HOG 特征。

# 1.2 LBP 特征算子及改进

LBP 特征算子(local binary pattern,LBP)是广泛使用在图像纹理特征提取的高效算子<sup>[12]</sup>,其基本原理是首先将样本图像各像素分成 3×3 的窗口区域,以样本图像中心区域作为参照值,将其余 8 pixels 的灰度值分别与参照值进行对比,比对结果中各像素灰度值大于参照值,则记该点像素为 1,同理,反之记为 0。样本图片各像素标记完成后,会产生 8 位二进制数,转化为十进制,即可计算样本图像中心区域的 LBP 特征值。但由于 LBP 算子会随着采样点的增加,二进制种类会出现指数级的爆发增

长,影响对图像纹理特征的提取和识别,因此,需要对 LBP 算法进行改进降维以提高算子的适用性。

在样本图像中,LBP 所对应的二进制数会在 0~1 进行跳变,若跳变次数在 2 次内,记为等价跳变,否则归为其他跳变。以样本图像参照值为中心设置邻域圆,r 记为半径,N 记为邻域内像素点的个数。则其他跳变的 LBP 值为 N+1,等价跳变的 LBP 计算如式(4) 所示。

$$L = \sum_{N=0}^{N-1} s(G_N - G_C)$$
 (4)

其中, $G_c$  为参照点的灰度值, $G_N$  为邻域像素点的灰度值,当  $G_N \ge G_c$  时, $s(G_N - G_c)$  值为 1,否则为 0。并累计求和计算得出 LBP 特征值。

#### 1.3 双特征融合

结合 HOG 特征算子和 LBP 算子在特征提取上的不变性特征,受到输电线路户外因素影响较小,将两种特征算法进行融合对本文小金具目标的提取具有较高的适用性。双特征融合的一般步骤如下:

- 1)选取原始样本图像 P,并进行标准化处理,形成  $K \times K$  个标准区域,保持图像的大小一致;
- 2)将样本图像进行网格划分,分为 *T×T* 个像素区域,每个区域像素大小相等;
- 3)记 P(x,y)为第 x 行中第 y 个区域,在每个 P(x,y) 像素区域中利用 HOG 特征算子和 LBP 特征算子进行计算,分别得出特征值,并进行统计得到直方图;
- 4) 串行连接特征图,并去除噪声,形成融合特征 *M* 及特征图,作为卷积神经网络的输入。

# 2 算法概述

#### 2.1 Fast R-CNN 算法

Fast R-CNN 是在卷积神经网络的基础上做了改进, 使得日常的识别效率更高<sup>[6]</sup>。Fast R-CNN 算法的一般 流程主要包括 4 大部分,具体如下。

- 1)输入待识别的样本图像,确定样本图像的目标建议区域。
- 2)特征图获取,将要识别的图像输入至 CNN 中,得 到输出的特征图。
- 3)将所有的目标建议区域,通过感兴趣区域池化层 (region of interest, ROI)<sup>[13]</sup> 进行池化,得到 ROI 特征模块。
- 4)将特征模块通过全连接层,分别得到分类器输出和分类修正的偏差值。

Fast R-CNN 算法的基本结构如图 1 所示。

由于 Fast R-CNN 算法在候选区提取与特征分类的时间消耗上非常不匹配,无法满足检测中的需求。后来有学者在此基础上做了改进,提出了当前物体检测使用

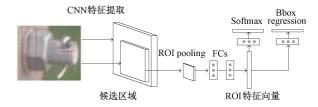


图 1 Fast R-CNN 算法的基本结构

Fig. 1 The basic structure of the Fast R-CNN

较为广泛的 Faster R-CNN 算法。Faster R-CNN 算法对网络进行了优化,将目标建议框的生成、特征提取、分类及修正都融合于同一网络中,使用区域建议网络(region proposal network,RPN)结构生成候选框<sup>[14]</sup>,其算法的流程均由神经网络来实现,极大地提高了算法的运算效率和准确率。

#### 2.2 算法改进

一般来说 Faster R-CNN 选择 VGG16 来进行特征提取,对于池化层,会将样本图像的尺寸不断缩减,使得特征图的大小逐渐减小,仅为原图的几十分之一甚至百分之一<sup>[15]</sup>,这就使得算法对小目标物体的识别有一定的局限性,在识别过程中会丢失大量细节信息,影响识别的结果。本文基于以上问题,对 Faster R-CNN 提取两点改进,分别是引入残差网络作为特征提取算法,同时引入注意力机制,增强算法的识别效果。

#### 1)基于残差网络的特征提取

残差网络的引入可以更好的提取图像的深层信息,使得识别准确度更高。本文选取 ResNet-50 作为算法的特征提取网络,ResNet-50 可以通过快捷连接进行跳层操作,将数据可以直接传递给后面的层,不会增加网络的参数和复杂度<sup>[16]</sup>。新增的连接会通过恒等映射,跳到叠加层的输出中,可以使得网络仍保持性能最优状态。残差网络基本结构如图 2 所示。

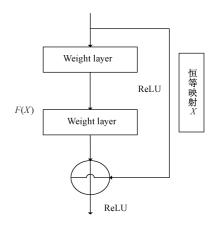


图 2 残差网络基本结构

Fig. 2 The basic structure of the ResNet

残差计算如式(5)所示:

$$S_{c} = S_{r} + F(S_{r}, J_{r}) \tag{5}$$

式中:  $S_r$  为输入特征值;  $S_c$  为输出特征值;  $F(S_r, J_r)$  为残 差函数。

对于一个更深层的d,与r层的关系如式(6)所示:

$$S_d = S_r + \sum_{n=1}^{d-1} F(S_n, J_n)$$
 (6)

记损失函数为 $\alpha,\alpha$ 关于S, 的梯度如式(7)所示:

$$\frac{\partial \alpha}{\partial S_{r}} = \frac{\partial \alpha}{\partial S_{d}} \frac{\partial S_{d}}{\partial S_{r}} = \frac{\partial \alpha}{\partial S_{d}} \left[ 1 + \frac{\partial}{\partial S_{r}} \sum_{n=1}^{L_{n}-1} F(S_{n}, J_{n}) \right]$$
(7)

ResNet 网络中,通过卷积层可以不断地提升网络性能。适时调整网络维度,使得其在不断增加深度的同时,减少了网络的参数和复杂度,最终提高效率。

#### 2)注意力机制

注意力机制是启发于人的视觉辨识,人们对于视觉中的物体是有选择性的关注,对于关注对象外的物体会选择无视<sup>[17]</sup>。这种启发运用在图像样本中,就可以选择关注图像的关键信息,忽略样本中的无关信息,能够快速识别重点信息。注意力机制一般按照其关注的区域不同可分为3类;通道注意力、空间注意力以及混合注意力。

通道注意力主要是对特征图中通道维度进行计算,一般是使用池化操作生成一个向量表示特征图的不同通道信息的重要性,然后通过全连接层实现对特征信息的缩放;而空间注意力主要是对特征图的二位空间像素点进行运算,一般使用卷积操作生成一个二维特征向量来表示不同位置上信息的重要性,也可以通过池化操作对特征进行降维,然后再使用卷积操作获取特征信息;混合注意力机制,就是将通道注意力机制和空间注意力机制相结合,可以同时兼有注意力机制在空间和通道维度上的优势,使得网络可以更加关注待识别的目标对象,尤其适合目标较小,干扰较多的小目标物体的识别。因此本文引入混合注意力机制,融合到 Faster R-CNN 的 ResNet-50 网络结构中,通过计算权重矩阵改变残差学习块的输出,使得网络的注意力更加集中在螺钉等小目标物体,更加突出了特征图中的关键信息,也丰富了其他相关信息。

如图 3 所示,混合注意力机制包含了通道注意力机制和空间注意力机制,需要先后完成两个机制模块的计算,记输入特征为  $t \in R^{C \times W \times H}$ ,混合注意机制依次得到一维的通道注意矩阵  $M_c \in R^{1 \times 1 \times C}$  和二维的空间注意矩阵  $M_s \in R^{1 \times W \times H}$ ,如式(8)和(9)所示:

$$a = \mathbf{M}_{c}(x) \otimes x \tag{8}$$

$$b = \mathbf{M}_{s}(a) \otimes a \tag{9}$$

式中:x 为输入特征,a 为输入模块的特征,b 为经过混合机制最终输出的特征, $M_c(x)$  为通道注意力模块的权重系数矩阵, $M_c(x)$  为空间通道模块的权重系数矩阵。

选择对模型输出结果影响较大的通道,侧重点在于

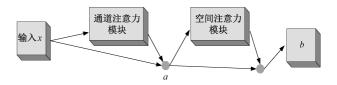


图 3 混合注意力机制结构

Fig. 3 The structure of mixed attention mechanism

样本图像的内容特征上,并对输入特征进行池化操作(包括最大池化和平均池化操作),然后将输出的特征经过分类器识别后进行输出。 $M_c(x)$  计算如式(10)所示。

$$M_{e}(x) = sg(N_{m}(p_{v}(x) + p_{m}(x))$$
 (10)  
式中: $sg$  为激活函数, $N_{m}$  为多层感知网络, $P_{v}(x)$  为平均  
池化操作, $P_{m}(x)$  为最大池化操作。

空间注意力模块主要侧重于样本图像中关键点的位置信息,并在图像中突出关键部分。空间注意力模块首先将一维的通道特征输入进行池化操作后,融合通道,并使用卷积模型计算得出空间注意力的权重系数矩阵,如式(11)所示。

$$M_s(a) = sg(f(p_v(a), p_m(a)))$$
 (11)  
式中:f 为卷积操作。

## 3)改进后的网络

引入注意力机制可使得模型能够感知样本图像各区域的特征权重,同时增强有效权重,缩小无效特征。对于小目标的螺钉,模型的检测关注点就会更加快速精准的定位目标,提高了模型的检测效果。

改进后的 Faster R-CNN 算法的基本结构如图 4 所示,其一般的步骤如下。

- (1)将输入的图像进行均一化和灰度化处理,使得 图像的尺寸和颜色保持一致,避免由于图片的色差和尺寸对图片的识别造成干扰。
- (2)将归一化的图片输入到双特征融合特征算子中,进行特征的提取和计算处理,生成特征图,并将特征 在样本图像中进行标记;
- (3)将带有标签的样本图像输入到本文引入了注意 力机制的 ResNet-50 特征提取网络中进行卷积和池化操 作生成特征图,由于本文 ResNet-50 网络有 4 组模块,因 此,每组模块均放置混合注意力模块;

将输出的特征图与标签进行重合对比对,去除噪声,融合特征后,作为 RPN 的输入,并经滑动窗口形成特征集合,进而进入全连接层进行分类和修正;同时,将生成的特征图与目标建议输入到 ROI 池化层,以输出统一大小的特征图像,再通过损失函数进行分类和修正,最后生成预测结果。Faster R-CNN 算法的基本结构如图 4 所示。

在实际的图像特征提取中,由于图像的颜色、像素等

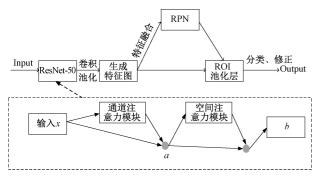


图 4 Faster R-CNN 算法的基本结构

Fig. 4 The basic structure of the Faster R-CNN

因素影响,提取的特征的深度和清晰度也不相同。因此,本文旨在将生成不同深度的特征进行融合,然后再次进行特征提取和检测,这就进一步提高了模糊目标的识别度。保证图片在经过不断特征提取和池化操作后,仍能识别较小的电力金具目标,检测范围有了较大提高。

# 3 实验和结果

#### 3.1 数据集获取

本文主要是对电力小金具螺钉的缺陷进行检测,检测对象仅为金具上的连接螺钉,不含其他螺钉。由于螺钉目前可选的样本较少,没有开源的可选数据集,所以需要参考安徽某地变电站的无人机采集图像,并参考《架空输电线路的缺陷影像标注规范》<sup>[18]</sup>,建立数据集,数据集去除无效样本,共计1322个样本图像,将螺钉缺陷分为3类,包括螺钉部件缺失、螺钉部件裂痕以及螺钉锈蚀,按照类别进行标记,图像的像素大小为3840×2160,标记目标数为1131个,其中涉及螺钉部件缺失的有627个、裂痕螺钉33个,锈蚀螺钉471个。模型的基本参数设置为:初始学习率为0.001,迭代次数为20,参数个数为1,使用随机梯度下降优化。本文运用Python进行实验的仿真。样本图片标记如图5所示。

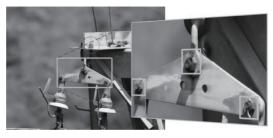


图 5 样本图片标记图 Fig. 5 Marking diagram of samples

在1322个样本图像中,依据不同训练样本下的模型识别率和误报率综合选定训练集和测试集的个数,识

别结果如表1所示。

表 1 不同训练样本下的模型识别结果表
Table 1 Comparison table of model recognition
results under different training samples

训练样	异常训练样本数量			正常训	总体识	
本总量	螺钉部	裂痕	锈蚀	练样本		误报率
平心里	件缺失	螺钉	螺钉	数量	别率	
800	380	20	285	115	88. 38	2. 19
850	403	21	302	124	88. 94	1. 93
900	427	23	320	130	91.11	1.69
950	451	23	338	138	92. 21	1.60
1 000	474	25	356	145	94. 50	1.40
1 050	498	26	374	152	94. 38	1.45
1 100	522	28	392	158	94. 45	1. 49

由表 1 可以看出,在选定训练样本数量在 1 000 时,总体识别率较高,且误报率均处于较低水平,在超过 1 000 时,总体识别率和误报率逐渐趋于稳定水平,稳中有降。因此,本文选取训练集数量为 1 000,测试集数量为 322,具有理想的识别效果。此时,螺钉部件缺失样本个数为 474,裂痕螺钉样本个数为 25,锈蚀螺钉样本个数为 356,正常图片样本个数为 145。

#### 3.2 算法精度分析

本文使用准确率(accuracy, ACC)<sup>[19]</sup>、平均精度(average precision, AP)以及平均精度均值(mean average precision, MAP)<sup>[20]</sup>来衡量本文算法的有效性,其公式如下所示:

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \tag{12}$$

$$AP = \int_{0}^{1} PR_{i}(RE_{i}) \, \mathrm{d}RE \tag{13}$$

$$MAP = \frac{\sum_{i=1}^{\text{num}} \int_{0}^{1} PR_{i}(RE_{i}) \, dRE}{\text{num}}$$
(14)

其中,TP 为预测值与实际值均为正;TN 为预测值与实际值均为负;FP 为预测值为正,实际值为负;FN 为预测值为负,实际值为正;num 为检测样本的总数。

本文将双特征融合的改进 Faster R-CNN 模型与传统的 Faster R-CNN 模型、YOLO v5 模型以及 Cascade R-CNN 模型进行缺陷识别效果对比,对比的指标主要包括:模型的平均精度、整体的准确率以及平均精度均值。不同特征网络的模型检测结果对比如表 2 所示。

由表 2 可知,本文提出的双特征融合的改进 Faster R-CNN 模型相比较传统的 Faster R-CNN 模型、YOLO v5 模型、Cascade R-CNN 模型的平均精度均值分别提高了 0.16%、0.11%、0.07%,其中,螺钉部件缺失类识别平均精度提升了 0.09%,螺钉部件裂痕平均精度提升了

表 2 不同特征网络的模型检测结果对比
Table 2 Comparison of model detection results
of different feature networks

		AP			
模型名称	螺钉部	螺钉部	螺钉部	ACC/%	MAP/%
	件缺失	件裂痕	件锈蚀		
Faster R-CNN	82. 75	81. 16	79. 91	90.06	81. 27
YOLO v5	88. 22	84. 35	82. 13	92. 55	84. 90
Cascade R-CNN	91.11	89. 93	84. 14	95. 34	88. 39
本文算法	95.09	94. 38	93. 15	97. 20	94. 21

0.11%,螺钉部件锈蚀平均精度提升了 0.14%,均存在不同程度的提高。改进后的模型的准确率相较于其他 3 个模型平均提升了 0.05%,尤其相比较于单一的卷积网络算法提升较为明显。由此可见,本文提出的双特征改进Faster R-CNN 模型对于检测小金具的螺钉是比较有效的。

#### 3.3 时间效率分析

深度学习网络检测表现是否优异的第 2 个评价维度就是网络的时间效率,本文选用改进 Faster R-CNN 模型与传统的 Faster R-CNN 模型、YOLO v5 模型以及 Cascade R-CNN 模型网络进行检测效率的对比,不同特征网络的时间比对结果如表 3 所示。

表 3 不同模型的时间比对结果

Table 3 Time comparison results of different feature networks

序号	模型名称	训练时间/s	平均检测时间/s
1	Faster R-CNN	10 864	0. 166
2	YOLO v5	8 327	0. 182
3	Cascade R-CNN	12 480	0.310
4	本文算法	13 031	0. 306

从表 3 可以看出,随着算法网络的复杂度不断提高, 算法的平均检测时间也有所提高。在经过有效的训练 后,本文双特征融合的改进 Faster R-CNN 模型的训练时 间相较于其他模型有略微的增加,但并不影响模型的性 能效率。与其他网络相比,平均检测时间增加不到 0.2 s,实时性仍较高。同时,检测的精度提升较明显。综 上所述,本文双特征融合的改进 Faster R-CNN 模型具有 较高的识别和检测效率。

# 4 结 论

电力金具作为如今输电线路中使用最多,作用最为 广泛的部件,承载着电力输电线路传输的稳定和安全。 电力金具一旦出现异常,就会严重损害电力输电线路 的运行,给人们的生活带来不利影响。机器学习算法 的不断研究和发展也给电力金具的缺陷预测提供了 参考。

本文通过对卷积神经网络进行研究,提出了一种基于双特征融合的改进 Faster R-CNN 模型。主要贡献在于两个方面:一是选择双特征提取算子分别对初始样本图像进行特征提取并进行融合,进一步提高特征提取的辨识度;二是对传统的 Faster R-CNN 进行改进,引入残差网络,并融入混合注意力机制,更加突出了特征图中的关键信息,也丰富了全局信息,提高了电力小金具的识别准确率。实验表明,本文双特征融合的改进 Faster R-CNN 模型相较于传统的 Faster R-CNN 模型和 YOLO 模型的提升效果明显,模型的平均准确率提升了 0.05%,平均精度提升了 0.11%,同时,检测时间也不足 0.5 s,实时性较高。

在今后的研究中需进一步改进模型,提升模型的时间效率,使缺陷检测可以更好地服务于小目标的电力金具,更好地降低电力工人的工作难度和工作量。

#### 参考文献

- [1] 肖峰,高正平,朱海峰,等. 虚拟现实技术在输电线路 大跨越高塔组立模拟系统中的应用[J]. 电网与清洁 能源, 2018, 34(2): 86-92. XIAO F, GAO ZH P, ZHU H F, et al. Application of
  - XIAO F, GAO ZH P, ZHU H F, et al. Application of virtual reality technology in simulation system of erecting large-span towers of transmission lines [J]. Power Grid and Clean Energy, 2018, 34 (2): 86-92.
- [2] 范怡敏,罗云飞,沈克永,等. 配备小型紫外光传感器的无人机电力巡视设计与测试[J]. 电子测量与仪器学报,2018,32(5):188-194.
  - FAN Y M, LUO Y F, SHEN K Y, et al. Design and test of unmanned aerial vehicle power patrol with small ultraviolet sensor[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(5): 188-194.
- [3] 李鑫,刘帅男,杨桢,等. 基于改进 Cascade R-CNN 的 输电线路多目标检测[J]. 电子测量与仪器学报, 2021,35(10):24-32.
  - LI X, LIU SH N, YANG ZH, et al. Multi-target detection of transmission lines based on improved Cascade R-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10); 24-32.
- [4] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

  Las Vegas, NV, USA: IEEE, 2018: 770-778.
- [5] 金旺, 易国洪, 洪汉玉,等. 基于卷积神经网络的实时车辆检测[J]. 计算机工程与应用, 2021, 57(5): 222-228.

- JIN W, YI G H, HONG H Y, et al. Real time vehicle detection based on convolutional neural networks [J]. Computer Engineering and Applications, 2021, 57(5): 222-228.
- [ 6 ] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [ C ]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014:580-587.
- [7] GIRSHICK R. Fast R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision. Santiago, Chile; IEEE, 2015; 1440-1448.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN:
  Towards real-time object detection with region proposal
  networks[J]. IEEE Transactions on Pattern Analysis and
  Machine Intelligence, 2015, 39(6): 1137-1149.
- [9] 薛阳, 吴海东, 张宁, 等. 基于改进 Faster R-CNN 输电线穿刺线夹及螺栓的检测[J]. 激光与光电子学进展, 2020, 57(8): 84-91.

  XUE Y, WU H D, ZHANG N, et al. Based on the improved Faster R-CNN transmission line piercing clamp and bolt detection [J] Progress in Laser and Optoelectronics, 2020, 57(8): 84-91.
- [10] 董美琳,任安虎. 基于深度学习的高速公路交通事件 检测研究[J]. 国外电子测量技术,2021,40(10): 108-116. DONG M L, REN AN H. Research on expressway traffic incident detection based on deep learning[J]. Foreign Electronic Measurement Technology, 2021, 40(10): 108-116.
- [11] 王瀛,徐奔,左方. 基于 HOF-CNN 和 HOG 特征的视频 动作 识别 系统 [J]. 计算 机 仿 真, 2022, 39 (6): 179-182.
  WANG Y, XU B, ZUO F. A video action recognition
  - system based on HOF-CNN and HOG features [J]. Computer Simulation, 2022, 39(6): 179-182.

赵泊林,张晓龙. 基于感兴趣区域聚集层的强化学习

[12] SHETTY A B, REBEIRO J. Facial recognition using Haar cascade and LBP classifiers[J]. Global Transitions Proceedings, 2021, 2(2): 330-335.

[ 13 ]

- 算法的目标检测[J]. 东北师大学报:自然科学版, 2021, 53(2): 73-80.

  ZHAO B L, ZHANG X L. Target detection based on reinforcement learning algorithm of region of interest aggregation layer [J]. Journal of Northeast Normal University: Natural Science Edition, 2021, 53(2): 73-80.
- [14] 储开斌,叶托,张继. 基于改进 Faster R-CNN 的头盔检

- 测算法研究[J]. 国外电子测量技术, 2022, 41(6): 86-92.
- CHU K B, YE T, ZHANG J. Research on helmet detection algorithm based on improved Fast R-CNN[J]. Foreign Electronic Measurement Technology, 2022, 41 (6): 86-92.
- [15] 顾超越,李喆,史晋涛,等. 基于改进 Faster-RCNN 的无人机巡检架空线路销钉缺陷检测[J]. 高电压技术, 2020,46(9);3089-3096.

  GU CH Y, LI ZH, SHI J T, et al. Detection of pin defects of UAV patrol overhead line based on improved Faster-RCNN[J]. High Voltage Technology, 2020, 46
- [16] 张利军,段礼祥,万夫,等. 往复压缩机故障的残差网络诊断方法[J]. 电子测量与仪器学报,2021,35(5): 38-46.

(9): 3089-3096.

[ 17 ]

ZHANG L J, DUAN L X, WAN F, et al. Residual network diagnosis method for reciprocating compressor fault [ J ]. Journal of Electronic Measurement and Instrumentation, 2021, 35(5): 38-46.

梁继然,陈壮,董国军,等.结合注意力机制和密集连

- 接网络的车辆检测方法[J]. 电子测量与仪器学报, 2022,36(3):210-216.

  LIANG J R, CHEN ZH, DONG G J, et al. Vehicle detection method combining attention mechanism and dense connection network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (3): 210-216.
- [18] 中国电力企业联合会. T/CEC 509-2021 架空输电线路 巡检影像标注规范[S]. 北京:中国标准出版社,2021. China Electricity Enterprise Federation. T/CEC 509-2021 Specification for aerial transmission line patrol inspection image labeling[S]. Beijing: China Standards Press, 2021.
- [19] 姜建,刘海琼,李衡,等. 基于 XGBoost 的配电网线路峰值负荷预测方法[J]. 电力系统保护与控制,2021,49(16):119-127.

  JIANG J, LIU H Q, LI H, et al. Distribution network line peak load forecasting method based on XGBoost[J]. Power System Protection and Control, 2021,49(16): 119-127.
- [20] 李雅雯, 孙浩然, 胡跃明. 基于注意力机制与多尺度特征融合的电极缺陷 YOLO 检测算法[J]. 控制与决策, 2022, 36(14):1-9.
  LI Y W, SUN H R, HU Y M. Electrode defect YOLO

detection algorithm based on attention mechanism and multi-scale feature fusion [J]. Control and Decision,

2022, 36(14): 1-9.

#### 作者简介



叶飞,2009年于武汉大学获得硕士学位,现为国网安徽电力公司高级经济师,主要研究方向为物资管理、大数据、数据分析。 E-mail; 654652229@qq.com

Ye Fei received his M. Sc. degree from Wuhan University in 2009. He is now a senior

economist at State Grid Anhui Electric Power Co., Ltd. His main research interests include material management, big data, data analysis and so on.



**谭守标**(通信作者),2004 年于中国科技大学获得博士学位,现为安徽大学教授,主要研究方向为计算机视觉。

E-mail: starry226@ ahu. edu. cn

Tan Shoubiao (Corresponding author) received the Ph. D. degree in 2004 from

University of Science and Technology of China. Now he is a professor at Anhui University. His main research interests include computer vision and pattern recognition.