

# 一种高精度优化 Faster-RCNN 变电站安全帽检测方法

张彦凯<sup>1</sup>,余飞鸿<sup>2,3</sup>,夏岩<sup>2,3</sup>,刘勇<sup>2,3</sup>,张蕊<sup>2,3</sup>

(1. 兰州陇能电力科技有限公司,甘肃 兰州 730000;2. 四川轻化工大学自动化与信息工程学院,四川 宜宾 644000;3. 智能电网四川省重点实验室,四川 成都 610095)

**摘要:**针对传统变电站人工视频安全帽检测效率低和错误率高的问题,文中提出了一种优化的高精度 Faster-RCNN 安全帽检测方法。首先,以 RPN 为主干网络引入特征金字塔,增强检测算法浅层和深层信息表征能力;接着,引入 K-Means++ 聚类算法优化 Anchor 参数,提升网络对小目标的检测能力;然后,以 ROI Align 代替 RoI 池化,消除量化误差和原始图片与特征图的映射偏差,从而提高检测精度;最后,采用开源安全帽数据集对改进的网络进行训练与测试,并将该模型与 YOLOv3、RFBnet 和传统 Faster-RCNN 进行了对比。实验结果表明:优化的 Faster-RCNN 相比 RFBnet、YOLOv3 和传统 Faster-RCNN 模型,将 mAP 值分别提高了 6.81%、9.57% 和 5.09%,达到了 92.43%;检测速度为 18 frame/s,同时增强了变电站安全帽高精度识别能力。

**关键词:**变电站;目标检测;Faster-RCNN;K-Means++聚类;ROI Align

**中图分类号:**TB 115 **文献标志码:**A **文章编号:**1003-6954(2023)01-0062-07

**DOI:**10.16527/j.issn.1003-6954.20230112

## A Detection Method for Safety Helmet in Substation Based on Improved High-precision Faster-RCNN

ZHANG Yankai<sup>1</sup>, YU Feihong<sup>2,3</sup>, XIA Yan<sup>2,3</sup>, LIU Yong<sup>2,3</sup>, ZHANG Rui<sup>2,3</sup>

(1. Lanzhou Longneng Electric Power Science & Technology Ltd., Lanzhou 730000, Gansu, China;  
2. School of Automation and Information Engineering, Sichuan University of Science & Engineering,  
Yibin 644000, Sichuan, China; 3. Intelligent Electric Power Grid Key Laboratory of Sichuan  
Province, Chengdu 610095, Sichuan, China)

**Abstract:** Aiming at low efficiency and a high error rate of safety helmet detection in substations by the traditional manual video detection method, a helmet detection method based on the improved high-precision Faster-RCNN is proposed. Firstly, the feature pyramid network module is introduced into the RPN backbone network, so that the representation ability of shallow semantic information and deep semantic information are enhanced. Secondly, the K-Means++ clustering algorithm is introduced to improve the anchor parameters, so that the ability to detect small targets is enhanced. And then, RoI pooling is replaced by ROI Align to eliminate the quantization error and the mapping deviation between original image and feature map, thereby improving the detection accuracy. Finally, the open source dataset of safety helmet is used to train and test the improved network, and the model is combined with YOLOv3, RFBnet and traditional Faster-RCNN. The results show that compared with RFBnet, YOLOv3 and traditional Faster-RCNN models, the improved Faster-RCNN increases the mAP value by 6.81%, 9.57% and 5.09%, which reaches 92.43%, and the detection speed is 18 frame/s, which can enhance the high-precision recognition ability of safety helmets in substations.

**Key words:** substation; edge detection; Faster-RCNN; K-Means++ clustering; ROI Align

## 0 引言

变电站巡检、输电线路巡检有很多繁杂、重复的

工作,线路、设备运行维护检修工作量大<sup>[1]</sup>。电力系统的稳定性和安全性直接受变电站的影响,随着电力行业的不断发展,电力现场作业人员面临着越来越复杂的安全隐患。操作人员在变电站事故中受伤常见原因之一是未佩戴安全帽,GB 26860—2011

《电力安全工作规范发电厂和变电站电气部分》<sup>[2]</sup> 中明确指出“采用绝缘手套作业法或绝缘操作杆作业法时,应当根据作业方法选用人体绝缘防护用具,使用绝缘安全带、绝缘安全帽”。检测安全帽佩戴安全,传统的人工视频检测不仅费时费力,而且极可能存在漏检的情况,在监控视频中对安全帽的佩戴情况进行实时检测是目前研究热点。

传统的基于目标图像特征提取的方法,泛化能力较差<sup>[3]</sup>,对于不同情况需要重新分析,鲁棒性较差,难以满足高性能目标检测的需求。

近年来,得益于人工智能的发展,产生了一大批优秀的目标检测方法。目前基于卷积神经网络(convolutional neural network, CNN)的目标检测算法分为单阶段检测法和双阶段检测法<sup>[4]</sup>。单阶段法基于回归策略的目标检测网络,省略了候选框生成阶段,将输入图像直接经过深度神经网络,提取特征进行预测目标的位置与类别。这种算法的特点是检测速度快,但是检测精度不高,其代表算法有 YOLO<sup>[5]</sup>、SSD<sup>[6]</sup> 等;双阶段法是基于候选框区域(region proposal)的目标检测算法,其分为两个阶段,第一个阶段生成预选框,第二个阶段对生成预选框进行分类和回归,最后确定检测目标。这种算法的特点是检测精度高,但是检测速度较慢,其代表是有 RCNN<sup>[7]</sup>、Fast-RCNN、Faster-RCNN 等。但是无论是单阶段检测方法还是双阶段检测方法,都对小目标检测存在困难。文献[8]提出一种基于改进 YOLOv3 的安全帽佩戴检测算法 YOLOv3-WH,在 YOLOv3 算法的基础上改进网络结构,该算法在提升了安全帽佩戴检测速率的同时提升了检测的准确率,对安全帽佩戴检测具有一定的实用性;文献[9]基于 Faster-RCNN 架构引入对手生成和多尺度训练策略对测试样本进行检测,但是数据集拍摄环境较为理想,缺少缺陷绝缘子图像。总的来说,基于深度学习的改进方法能够很好地增强传统方法在复杂环境下的鲁棒性,已经在目标检测中取得了一定的效果。

由于变电站中绝缘安全帽在电力作业环境中的重要性,但采用单阶段检测算法对绝缘安全帽进行目标检测可能会出现漏检的现象,所以检测精度比起检测速度更为重要。为了综合目标检测的检测精度与检测速度,提高对小目标的检测能力,提出一种优化的高精度 Faster-RCNN 变电站安全帽检测方法。首先,在 Faster-RCNN 算法架构上改进主干网

络添加特征金字塔,使主干网络结合底层特征与高层特征,增强底层特征语义信息;其次,使用 K-Means 聚类算法优化 Anchor 参数;最后,用 ROI Align 代替 RoI 池化,取消量化误差。通过实验对比,证明优化的 Faster-RCNN 网络对小目标安全帽能有效识别,且模型收敛速度较快,能满足智能变电站实时检测的要求。

## 1 Faster-RCNN 网络

Faster-RCNN 网络是在 Fast-RCNN<sup>[10]</sup> 的基础上对模型识别精度和速度的改进,如图 1 所示。该算法将传统选择性搜索算法替换为区域建议网络(regional proposal network, RPN),RPN 生成的特征图与神经网络结构的其余部分共享,这样加快了检测框的生成速度。

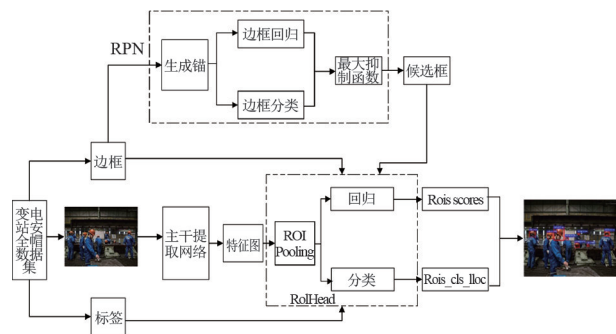


图 1 Faster-RCNN 的整体架构

### 1.1 主干提取网络

主干提取网络利用卷积层提取出整个图片的特征图,原始 Faster-RCNN 的主干提取网络可以是 VGG-16、ResNet-101 或定制网络。这里使用 VGG-16,网络结构包括 13 个卷积层、3 个全连接层、5 个池层。与其他网络相比,VGG-16 中包含的 13 个卷积层所使用的卷积核是一个中等大小的  $3 \times 3$  矩阵。卷积核数由第一层的 64 个逐渐增加到 128 ~ 256 个,最后增加到 512 个。池化层的卷积核的大小为  $2 \times 2$ ,步长为 2。与  $5 \times 5$  的网络相比,该网络提取的特征图更优。

### 1.2 RPN

RPN 主要由 CNN、一组锚和一个 region proposal layer 组成,取代 Fast-RCNN 算法中的选择性搜索方法,生成候选框区域,它用于生成可能包含对象的感兴趣区域,RPN 结构如图 2 所示。利用 RPN 来获得区域建议可以更快速有效地利用 CNN 网络。主要可分为两个步骤:首先,RPN 在生成区域建议时生

成锚点,最大抑制函数确定锚点是否为前景,softmax 二分类与真实数据进行对比来确定时前景还是背景;然后,通过边界回归调整锚点,得到准确的区域。最大抑制函数不会损害最终检测的准确性,而且会大幅减少建议的数量。




图 2 RPN 结构

### 1.3 Anchor 定义

锚是一个不同大小的盒子,帮助检测不同大小的物体。在 Faster-RCNN 的默认配置中,有 3 个不同的大小和 3 个不同的比率,共有 9 个锚,计算  $p^*$  的值来检查这些锚点与真实边界盒的重叠程度。如果  $I_{ou}$  (测量真实和预测之间的相关度) 大于 0.7,则锚点被标记为正的;如果  $I_{ou}$  小于 0.3,则锚点被标记为负的。

### 1.4 损失函数

多任务损失函数将分类损失和回归损失结合起来,其损失函数<sup>[11]</sup>为

$$L\{(p_i), (t_i)\} = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

式中:  $p_i$  为预测框是前景的概率;  $p_i^*$  为预测框预测正确的概率;  $t_i$  为预测框的边界参数;  $t_i^*$  为前景目标的真实标注框边界参数;  $N_{cls}$  和  $N_{reg}$  分别为分类的个数和回归区域的个数;  $i$  为锚点的编号;  $\lambda$  为平衡两个损失函数在训练的总损失函数中的比例;  $L_{cls}$  为分类损失函数,其表达式如式(2)所示;  $L_{reg}$  为回归损失函数,其表达式如式(3)所示。

$$L_{cls}(p_i, p_i^*) = -\lg[p_i^* p_i + (1 - p_i^*)(1 - p_i)] \quad (2)$$

$$L_{reg}(u_i, t_i^*) = \sum_{i \in \{x, y, w, h\}} S_{L_1}(t_i, t_i^*) \quad (3)$$

$$S_{L_1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (4)$$

式(4)  $S_{L_1}(x)$  为平滑方程。  $i \in \{x, y, w, h\}$  分别表示安全帽候选框的中心坐标、高和宽。网络最后通过 RoI 池化层处理不同大小的特征映射输入到全连通层网络,分类层负责判断对象属于哪个类,而回归层

对感兴趣区域的位置进行精细调整,得到最终的目标检测结果。

## 2 优化的高精度 Faster-RCNN 变电站安全帽检测方法

### 2.1 特征金字塔

RPN 设计中,一个检测框在单尺度卷积特征映射的基础上,在密集的  $3 \times 3$  滑动窗口上进行评估,执行目标/非目标二分类和回归,通过一个  $3 \times 3$  的卷积层和两个  $1 \times 1$  的分类与回归的卷积来实现的,其结构如图 3 所示的原 RPN 结构。RPN 生成包含背景的区域,而不是目标实例,多次下采样后得到的是拥有高层特征的语义信息,而前几次下采样中的低层高分辨率信息被忽略;采用 Anchor 锚机制时候选框设置的尺度不适用于所有目标,所以在处理非常大或者有形状的目标时效果不好,尤其对小目标检测效果不好。

为了使检测方法更精确,构建一个具有高级语义的特征金字塔,拟引入 FPN 来调整 RPN。在特征金字塔的每一层都附加了一个相同的  $3 \times 3$  卷积和两个  $1 \times 1$  卷积,如图 3 所示。因为顶部在所有金字塔级别的所有位置上密集滑动,所以不需要在特定级别上有多尺度锚,而是给每个级别分配一个单一级别的锚,将金字塔上的锚增加到 15 个,增强检测算法浅层和深层信息表征能力。




图 3 特征金字塔

### 2.2 K-Means++ 聚类优化

由于绝缘安全帽的大小不一,传统 Faster-RCNN 检测算法尤其对小目标安全帽检测不佳。故采用 K-Means++ 算法模型<sup>[11]</sup>,将获取图片的真实框的长度和宽度送入 K-Means++ 算法模型中,聚类中心数量设置为 4~7,并进行聚类运算,对聚类效果图进行比较后确定最后的修改预选候选框参数,从而提高



对小目标的检测能力,采用 CH 指标<sup>[12]</sup>作为评估 K-Means++ 算法的最佳聚类数指标,其定义为

$$C_H(k) = \frac{B}{k-1} / \frac{W}{N-k} \quad (5)$$

式中: $B$ 为类间离散度矩阵的迹; $W$ 为类内离散度矩阵的迹; $k$ 为当前的类; $N$ 为聚类的数量,即总记录数。从式(5)可以看出, $C_H$ 值越大,簇与簇之间就越分散,其聚类效果越好。不同  $k$  值聚类结果用于评估如表 1 所示。由表 1 可知,当  $k$  值等于 6 时, $C_H$  指标最大,簇与簇之间就越分散,聚类效果最好。因此 (23.37, 29.39)、(42.81, 53.65)、(69.21, 86.92) 小尺寸特征图的感受野面积较大,故可以检测较大的安全帽目标;(104.52, 129.69)、(160.38, 197.53)、(258.92, 309.23) 大尺寸特征图的感受野面积较小,故可以检测较小的安全帽目标。

表 1 不同  $k$  值聚类结果

$k$ 值	中心点坐标	$C_H$ 指标
4	(61.53, 77.15) (28.61, 35.89)	6 376.2
	(212.62, 258.23) (117.24, 145.22)	
5	(257.63, 308.47) (90.64, 113.21)	7 832.4
	(50.20, 63.04) (155.07, 190.57)	
6	(258.92, 309.23) (42.81, 53.65)	8 932.8
	(69.21, 86.92) (23.37, 29.39)	
7	(160.38, 197.53) (104.52, 129.69)	8 632.7
	(173.67, 213.49) (267.07, 318.52)	
	(36.56, 45.62) (20.82, 26.31)	
	(84.43, 105.16) (122.68, 152.45)	
	(55.40, 69.70)	

### 2.3 引入 ROI Align

传统的 Faster-RCNN 模型不限制任何图片输入大小,原因是候选框区域经过 RoI 池化层会被映射成固定大小的特征图。RoI 池化层采用近邻插值法对特征进行池化<sup>[13]</sup>,经过两次将浮点数量化取整,这些量化在 RoI 和提取的特征之间引入了差异,造成精度损失,最后造成回归定位不准确,对于小目标检测影响更大。ROI Align 理论<sup>[14]</sup>利用双线性插值法进行插值,取消取整量化,而保留浮点数,避免取整带来的精度损失,以提高空间对称性带来的量化偏差,保证提取的特征与输入特征对齐。在图 4 中,图中实线表示 RoI (2×2 个 bins),点表示每个 bin 中的 4 个采样点,其中每个采样点的值都是通过双线性插值从特征图上的邻近网格点计算的,不对 RoI、bins 或采样点涉及的任何坐标进行量化,使得候选区域信息得到全部利用,从而提高检测精度。

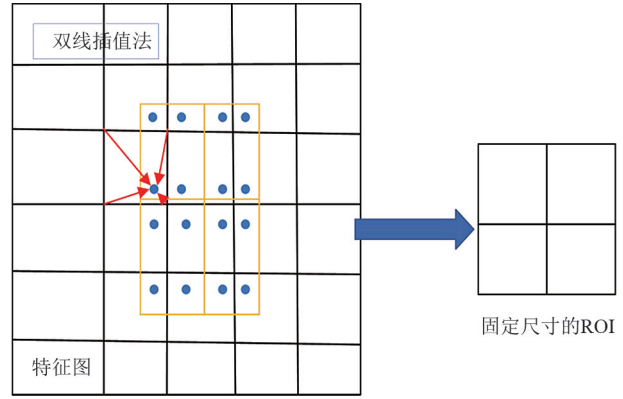


图 4 ROI Align

## 3 算例分析

### 3.1 实验环境与数据集处理

本实验编程语言为 Python3.6,使用 Anaconda3、CUDA 和 Pycharm 等软件在高性能服务器上搭建实验环境,服务器搭载的高性能 GPU 可以最大程度地缩短实验训练时间,深度学习开发框架选用 TensorFlow,操作系统为 64 位 Windows10 专业版,更多硬件配置如表 2 所示。

表 2 服务器硬件配置

类别	数量	型号
主板	1	超微 XODRG-Q
内存	1	镁光 256GB
硬盘	1	2TB
CPU	1	Inter Xeon
GPU	4	Nvidia TITAN XP

实验数据是深度学习的基础,本实验数据集为 Github 开源安全帽图片<sup>[15]</sup>,选取 3174 张各种场景的图片,使用 Github 开源标记工具 Labelimg 对每张图片标注出安全帽区域及其标签,生成 XML 文件。标注数据信息如下:按安全帽的颜色分别进行标注为 red、yellow、white 和 blue;未佩戴安全帽标注为 none。将标注完成的数据集分为互斥的训练集、验证集和测试集,其比例为 7:1:2,如表 3 所示。其中 2219 张是训练集,317 张是验证集,638 张是测试集。在整个标记过程中,标记目标总数为 10 307 个,其中 red 目标有 3578 个,yellow 目标有 3274 个,white 目标有 2193 个,blue 目标有 2253 个,none 目标有 1262 个。

在实验之前,为了避免数据不足出现模型过拟合的情况,对实验数据进行图片镜像变换、旋转等处

表 3 数据集分配

标记名称	标记总数	训练集标记数	验证集标记数	测试集标记数
red	3578	2804	357	417
yellow	3274	2289	413	572
white	2193	1245	355	593
blue	2253	1475	402	376
none	1126	743	165	354

理。实验参数设置如下:初始学习率设置为 0.001,采用  $\gamma = 0.1$  的 Steps 学习率调整方法;权重衰减设置为 0.000 5;动量为 0.9;批训练数据量为 256;最大迭代次数为 40 000。模型训练时间大约 7 h,直到训练误差收敛。为验证所提算法模型的可靠性和有效性,在同样的实验环境训练 RFBnet<sup>[16]</sup>、YOLOv3<sup>[17]</sup> 和传统 Faster-RCNN 网络,便于后面在测试集上与优化的 Faster-RCNN 进行对比。

### 3.2 模型评估方法

本实验采用平均精确度均值<sup>[18]</sup> (mean average precision, mAP) 和检测速度<sup>[19]</sup> (frame per second, FPS) 作为评价模型性能指标, mAP 和 FPS 越大分别表示模型的精度越高、实时性能越好。其中 mAP 为表 3 中 5 个类别的平均精度 (average precision, AP), 而  $A_p$  是精确率 ( $P$ ) - 召回率 ( $R$ ) 曲线 ( $P(R)$ ) 与坐标轴所围成区域的面积,其表达式为:

$$P = \frac{T}{T + F} \quad (6)$$

$$R = \frac{T}{T + M} \quad (7)$$

$$A_p = \int_0^1 P(R) dR \quad (8)$$

$$m_{AP} = \frac{\sum_{i=1}^N A_{p_i}}{N} \quad (9)$$

式中:  $T+F$  为检出安全帽总数;  $T+M$  为真实安全帽总数;  $T$  为正确检测出安全帽的个数;  $N$  为类别数。后续工作都是以此为基础进行的。

### 3.3 实验结果与对比

首先,选取 4 张具有代表性的测试图片分别输入到 RFBnet、YOLOv3、传统 Faster-RCNN 和所提优化的 Faster-RCNN 模型中进行检测,将检测结果进行对比,如图 5 所示。在图 5(a) 中安全帽存在环境较为清晰,RFBnet 和优化的 Faster-RCNN 模型检测结果都比较理想,而 YOLOv3 的检测结果不佳,漏检 3 个对象(如图中黄色箭头指向处,下同),传统 Faster-RCNN 将一个红色物体错检为红色安全

帽。在图 5(b) 场景复杂,存在遮挡、重叠的现象,RFBnet 和 YOLOv3 都出现了漏检 2 个对象的情况,传统 Faster-RCNN 在遮挡、重叠的场合漏检 2 个未佩戴安全的工人,而优化的 Faster-RCNN 检测结果比较理想,这表明在一定程度上优化的 Faster-RCNN 的模型提高了对遮挡、重叠的复杂场景的适应力。在图 5(c) 中存在一些小目标安全帽目标,RFBnet、YOLOv3 和传统 Faster-RCNN 都出现了不同程度的漏检,而优化的 Faster-RCNN 检测出全部小目标,检测效果理想,这表明 K-Means++ 聚类算法的引入提高了对小目标的检测能力。在图 5(d) 中场景有着一定的虚化,对检测带来一定的干扰,RFBnet 和优化的 Faster-RCNN 检测结果理想,YOLOv3 和传统 Faster-RCNN 存在漏检。

为了更进一步说明优化的 Faster-RCNN 模型的检测效果,最后使用上述安全帽数据集选出的 638 张测试集对以上 4 种方法分别进行测试,从  $P$ 、 $R$ 、mAP、FPS 和模型参数量等方面来论述改进效果,指标测试结果如表 4 所示。


表 4 指标测试结果

模型类型	测试集	$P/\%$	$R/\%$	mAP/ %	FPS/ (frame · s <sup>-1</sup> )	参数量/ MB
RFBnet		91.32	86.84	85.62	14	137
YOLOv3		90.78	83.63	82.86	21	246
传统 Faster-RCNN	638	91.56	88.74	87.34	15	131
所提算法		91.90	92.52	92.43	18	128

在 mAP 上,优化的 Faster-RCNN 优于 RFBnet、YOLOv3 和传统 Faster-RCNN 模型,分别将 mAP 值提高了 6.81%、9.57% 和 5.09%;在检测速度方面,优化的 Faster-RCNN 比 RFBnet 和传统 Faster-RCNN 分别提高了 28% 和 20%,且所提算法具有良好的  $P$  和  $R$  指标,但是相比于 YOLOv3 降低了 16%。另外,本模型的参数量最低,可以节省大量的内存空间,其原因一方面为 Faster-RCNN 的优化模型提高了对遮挡、重叠的复杂场景的适应力;另一方面为 K-Means++ 聚类算法改进锚的参数对小目标的检测起了一定的作用。最后,优化的 Faster-RCNN 相较于传统的 Faster-RCNN 提高了检测精度和检测的实时性。

## 4 结 论

为了提高智能变电站安全帽的检测能力,提出



(a) RFBnet检测结果

(b) YOLOv3检测结果

(c) 传统Faster-RCNN检测结果

(d) 优化的Faster-RCNN检测结果

图5 部分测试结果

了优化 Faster-RCNN 变电站安全帽的检测方法。通过构建特征金字塔模块,引入 K-Means++ 聚类算法和 ROI Align,提高了模型对作业环境中安全帽遮挡严重、重叠和图像背景虚化等的识别准确率。经过实验验证,优化后的检测算法 mAP 值达 92.43%,检测速度 18 frame/s,有效地提高了检测精度和对小目标的检测能力,并降低了参数量,增强了智能变电站的态势感知能力。此外,提高所提出的优化 Faster-RCNN 的检测速度,是后续的研究目标。

#### 参考文献

- [1] 张凌浩,潘文分,庞博,等.适用于电力场景的人工智能中台技术与探索[J].四川电力技术,2022,45(3):16-22.
- [2] 全国高压电气安全标准化技术委员会.电力安全工作规程 发电厂和变电站电气部分:GB 26860—2011[S].北京:水利水电出版社,2011.
- [3] 储岳中,黄勇,张学锋,等.基于自注意力的 SSD 图像目标检测算法[J].华中科技大学学报(自然科学版),2020,48(9):70-75.
- [4] 许德刚,王露,李凡.深度学习的典型目标检测算法研究综述[J].计算机工程与应用,2021,57(8):10-25.
- [5] REDMON J, DIVVALA S, GIRSHICK R B, et al. You only look once: unified, real-time object detection [C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016:779-788.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: single shot multibox detector [C]// European conference on computer vision, Cham, Switzerland, 2016:21-37.
- [7] GIRSHICK R B, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]// Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014:580-587.
- [8] 肖体刚,蔡乐才,高祥,等.改进 YOLOv3 的安全帽佩戴检测方法[J].计算机工程与应用,2021,57(12):216-223.
- [9] 易继禹,陈慈发,龚国强.基于改进 Faster RCNN 的输电线路航拍绝缘子检测[J].计算机工程,2021,47(6):292-298.



- [10] REN S, HE K, GIRSHICK R B, 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.
- [11] GIRSHICK R B. Fast R-CNN[C]//Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 1440-1448.
- [12] CALJDSKI T, HARABASZ J. A dendrite method for cluster analysis[J]. Communications in Statistics, 1974, 3(1): 1-27.
- [13] HE K, ZHANG X, REN S, 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.
- [14] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [15] njvisionpower. Safety Helmet Wearing-Dataset [EB/OL]. [2022-04-15]. <https://github.com/njvisionpower/Safety-Helmet-Wearing-Dataset>.
- [16] LIU S, HUANG D, WANG Y. Receptive field block net for accurate and fast object detection[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 385-400.
- [17] REDMON J, FARHADI A. Yolov3: An incremental improvement [J]. arXiv preprint arXiv: 1804.02767, 2018.
- [18] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [19] SONI P, SHAH F, VYAS N. Faster object tracking pipeline for real time tracking[J]. arXiv preprint arXiv: 2011.03910, 2020.

#### 作者简介:

张彦凯(1984),男,硕士,高级工程师,研究方向为电力系统安全稳定分析;

余飞鸿(1998),男,硕士研究生,研究方向为图像处理;夏岩(1983),男,博士,高级工程师,从事智能电网工作;

刘勇(1981),男,实验师,研究方向为计算机应用与人工智能;

张蕊(1998),男,硕士研究生,研究方向为图像处理。

(收稿日期:2022-11-28)

(上接第 21 页)

## 3 结 论

为提升快速复电弹性,减少极端环境造成的供电损失,上面根据抗灾三阶段策略,结合浙江地区在抗台风、雷电的工程项目,在灾前阶段提出迁移电杆加强基础设施、安装拒雷器增加保护范围措施;在灾中阶段提出“量子+北斗”智能断路器实现故障定位和偏远山区通信能力不足情况下的遥控措施;灾后根据“量子+北斗”智能断路器实现上级电源无电情况下的黑启动,并通过移动储能快速接入增强保电能力。

#### 参考文献

- [1] 刘瑞环,陈晨,刘菲,等.极端自然灾害下考虑信息-物理耦合的电力系统弹性提升策略:技术分析与研究展望[J].电机与控制学报,2022,26(1):9-23.
- [2] 雷潇,许安玖,刘强,等.10 kV 配电线路避雷器优化布置研究[J].四川电力技术,2022,45(4):21-25.
- [3] 阮前途,梅生伟,黄兴德,等.低碳城市电网韧性提升挑战与展望[J].中国电机工程学报,2022,42(8):2819-2830.
- [4] 高艺文,罗凡波,苏学能,等.穿越森林草原配电线路的一二次融合成套柱上开关优化布置研究[J].四川电力技术,2022,45(4):26-31.
- [5] 黄玉雄,李更丰,张理寅,等.弹性配电系统动态负荷恢复的深度强化学习方法[J].电力系统自动化,2022,46(8):68-78.
- [6] 别朝红,林超凡,李更丰,等.能源转型下弹性电力系统的发展与展望[J].中国电机工程学报,2020,40(9):2735-2745.
- [7] 张瑞曦,徐青山,程煜,等.极端灾害下考虑动态重构的微网形成策略[J].电力工程技术,2022,41(1):56-63.
- [8] 张国庆.含分布式电源的智能分段开关控制器研究[D].南京:南京理工大学,2019.
- [9] 蔡胜,谢云云,张玉坪,等.考虑移动应急电源配置的微电网顺序恢复方法[J/OL].中国电机工程学报:1-12 [2022-03-24]. <https://kns.cnki.net/kcms/detail/11.2107.TM.20220322.2030.022.html>.
- [10] 何俊,于华,邓长虹,等.极端天气下基于态势感知的重点区域电网负荷供电保障策略[J].高电压技术,2022,48(4):1277-1285.
- [11] 李宁,安卓尔,张世乾,等.弹性电网关键技术研究的进展与展望[J/OL].电测与仪表:1-9 [2022-04-13]. <https://kns.cnki.net/kcms/detail/23.1202.TH.20220412.1014.002.html>.
- [12] 别朝红,林雁翔,邱爱慈.弹性电网及其恢复力的基本概念与研究展望[J].电力系统自动化,2015,39(22):1-9.

#### 作者简介:

樊国旗(1993),男,硕士,研究方向为电力系统调度及新能源消纳。

(收稿日期:2022-07-18)