

基于深度学习的输电线路视觉检测方法研究进展

刘传洋, 吴一全*

(南京航空航天大学电子信息工程学院, 江苏省 南京市 211106)

Research Progress of Vision Detection Methods Based on Deep Learning for Transmission Lines

LIU Chuanyang, WU Yiquan*

(College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics,
Nanjing 211106, Jiangsu Province, China)

ABSTRACT: Transmission lines inspection is the guarantee for the stable and safety operation of power grid, which purpose is to perform target detection and fault diagnosis on power lines, power towers, insulators, anti-vibration hammers and other equipment, and to observe the prediction of potentially dangerous around the power lines. The development of deep learning provides an effective means for target detection of transmission lines inspection. Compared with traditional target detection methods, deep learning methods are more effective to realize the recognition and defect detection of electrical components in aerial images. This paper reviews the research progress of transmission lines component detection methods based on deep learning in recent decade. Firstly, the deep neural networks applicable to the target detection of transmission lines inspection are summarized, including classification networks, detection networks, semantic segmentation networks and lightweight networks. Then, it focuses on the target detection of key components in transmission lines based on deep neural networks. Next, datasets from electrical components and performance evaluation indexes are introduced. Finally, the existing problems of components detection in transmission lines based on deep learning are pointed out and the further work is prospected.

KEY WORDS: transmission lines inspection; deep learning; classification network; detection network; semantic segmentation network; electrical equipment

摘要: 输电线路巡检是电网持续稳定供电的保障,其目的是

对电力线、绝缘子、电力杆塔、防振锤等线路设备进行状态检测和故障诊断,同时观测电力线周围潜在隐患。深度学习的发展为输电线路巡检提供了有效手段,与传统目标检测方法相比,深度学习方法能更有效地实现航拍图像中电力设备的识别及缺陷检测。该文综述近十年来基于深度学习的输电线路视觉检测方法的研究进展。首先,概述适用于输电线路巡检的深度卷积神经网络,包括分类网络、检测网络、语义分割网络,考虑到开发的深度学习网络模型便于在移动设备上应用,另外阐述轻量化网络;然后,重点阐述基于深度卷积神经网络的输电线路巡检图像数据目标检测;随后介绍7个电力设备数据集以及性能评价指标;最后,指出基于深度学习的输电线路巡检图像数据视觉检测方法目前存在的问题,并对进一步的工作进行展望。

关键词: 输电线路巡检;深度学习;分类网络;检测网络;语义分割网络;电力设备

0 引言

电网是关系国计民生和国家能源安全的重要基础设施,而其中的输电线路作为电力传输的纽带,其安全稳定运行是社会生产和人民生活的重要保障^[1-3]。近年来,随着用电需求的不断增加,输电线路分布越来越广泛,其总长度也随之快速增长。由于输电线路架设在各种自然环境中,常年经受风吹日晒和雨淋,加之时有冰雪覆盖等恶劣天气的影响,难免会造成电力设备缺失或损坏。因此,定期巡检成为一项保障电能持续供应、输电线路安全运行的重要工作^[4-5]。

输电线路巡检是获取线路走廊中架空电力线、绝缘子、电力杆塔、金具、建筑物、植被等对象的图像及空间数据信息,其目的是实现线路设备状态检测和故障诊断及观测线路走廊的潜在隐患。现有

基金项目: 国家自然科学基金项目(61573183); 高校自然科学基金研究项目(CZ2022ZRZ07)。

Project Supported by National Natural Science Foundation of China (61573183); Natural Science Research Project of University (CZ2022ZRZ07).

的输电线路巡检方式包括人工巡检^[6]、机器人巡检^[7]、载人直升机巡检^[8]、遥感卫星巡检^[9]及无人机(unmanned aerial vehicle, UAV)巡检^[10-11]等5种方式。其中UAV巡检目前已经成为各大电网的重要巡检方式,“无人机巡检为主,人工巡检为辅”业已发展成为我国输电线路巡检的主要运维模式^[12-13]。然而,UAV巡检势必产生海量的巡检图像,针对大量的巡检图像中的电力设备检测若主要采用人工检测的方式,不仅消耗大量的人力资源,而且容易造成漏检或误判^[14]。为进一步提高输电线路巡检的自动化水平,众多研究者致力于无人机航拍图像中电力设备的识别与缺陷检测研究^[15-16]。

在电力设备图像特征提取方面,根据是否采用人工设计方式分为传统目标检测方法和深度学习方方法^[17]。前者通常在阈值分割、边缘检测、区域生长等图像分割的基础上,再提取图像特征,如颜色特征^[18-19]、形状特征^[20]、纹理特征^[21]、融合特征^[22-23]、空间形态学特征^[24-25]等。但是,传统的目标检测方法在进行电力设备检测过程中,易受复杂背景的影响,对于不同类别、形态差异显著、尺度变化较大的电力设备检测往往是针对特定特征来实现,其识别准确率低,不具有可扩展性,难以应用于实际场景中。而基于深度学习的检测方法,利用卷积神经网络自动提取图像深度特征,取得了比传统目标检测方法更好的性能。深度学习网络模型在ImageNet多项竞赛的成绩已证明其性能远超过传统目标检测方法,两类方法检测流程图分别如图1、2所示。




图1 传统目标检测方法流程图

Fig. 1 Flow chart of traditional target detection method




图2 深度学习检测方法流程图

Fig. 2 Flow chart of deep learning detection method

随着计算机视觉技术不断发展,以深度卷积神经网络(deep convolutional neural network, DCNN)为基础的一系列深度学习算法在目标识别与分类

中成功应用,深度学习技术在目标检测^[26]、图像处理^[27]、无人驾驶^[28]等方面取得了引人注目的成果。国家电网积极响应政策,不断推进人工智能和电力行业深度融合,推动输电线路巡检向自动化、智能化方向发展^[29]。

近年来,以计算机视觉和人工智能算法为实现方法的智能电网巡检研究日益受到广泛关注^[30],人们对输变电系统中的自动化巡检技术进行了大量研究^[31-35]。Nguyen等^[31]全面回顾了输电线路巡检方法和各种相关数据源,以无人机巡检为手段和光学图像为主要数据源,综述了深度学习技术在电力巡检业务中的研究现状和潜在作用。张等^[32]概括了深度学习发展历程和常见的神经网络结构,以时空数据和图像数据为基础综述了深度学习在电网数据智能处理中的应用。Yang等^[33]综述了2016—2020年间的输电线路巡检图像检测技术的研究进展,概述了巡检航拍图像中的检测任务,分析了输电线路不同巡检平台的优缺点,总结了多种自动巡检系统的检测任务。周等^[34]概述了视频图像智能识别技术,从电网设备监控和人身安全检测方面综述了图像识别技术在电力输变电系统中的应用研究。赵等^[35]回顾了输电线路巡检图像中电力设备识别及缺陷视觉检测的研究进展,对线路中绝缘子、螺栓的缺陷检测方法进行了综述,并指出了深度学习方法在小目标部件检测中存在的问题。迄今为止,基于深度学习的输电线路巡检图像中电力设备检测技术已经取得了相当进展,但由于电力设备种类繁多、形态各异,没有一种通用的算法能够很好地检测出图像中所有的电力设备。因此,有必要对各种不同的电力设备检测方法进行分析和归纳,以便针对特定的电力设备检测选取合适的深度学习算法。

鉴于此,本文梳理和分析大量的基于深度学习的输电线路巡检图像检测方法,对深度学习技术在输电线路巡检中的应用进行全面系统的综述,为从事智能电网自动化巡检研究人员提供有价值参考。文中作以下安排:第1部分概述用于输电线路巡检图像检测的深度卷积神经网络,主要从分类网络、检测网络、语义分割网络、轻量化网络4个方面进行概括;第2部分阐述基于深度卷积神经网络的输电线路巡检图像数据目标检测,主要从电力线、绝缘子、电力杆塔、金具、危险地物、多目标识别6个方面进行归纳与分析,并对研究成果进行了统计

分析；第 3 部分介绍 7 个电力设备公开数据集以及性能评估指标。最后，针对现有基于深度学习的输电线路巡检图像视觉检测方法存在的不足，对进一步的研究工作进行展望。

1 输电线路巡检图像检测中的 DCNN

自 Hinton 等提出利用神经网络自动学习多媒体数据中的深度特征以来，深度学习理论研究取得了长足进步并得到了日益完善。DCNN 通过卷积神经网络(convolutional neural network, CNN)自动逐层学习输入数据特征，利用大规模训练数据优化网络模型参数以提高其检测性能，并在特征提取方面体现出了强大的优势，已经在人工智能相关应用领域证明了其性能的卓越和稳定。凭借大规模公开数据集(imageNet、MS COCO、PASCAL VOC)、高性能的硬件处理设备，DCNN 将巡检航拍图像中的电力设备识别及缺陷检测技术提高到了一个水平，基于深度学习的输电线路巡检图像检测已成为计算机视觉领域的研究热点之一。本节主要概述输电线路巡检图像检测中的 DCNN，按照分类网络、检测网络、语义分割网络及轻量化网络这一架构进行总结。

1.1 分类网络

Yann LeCun 等于 1998 年提出了 5 层 CNN 结构 LeNet-5^[36]，并将其成功用于数字识别，开创了现代 CNN 的先河。Alex Krizhevsky 等在 2012 年提出了 Alex-Net^[37]，将网络加深到 8 层，获得了当年 ImageNet 竞赛冠军。自 Alex-Net 网络问世以来，随着对深度神经网络结构研究的加深，通过重构处理单元和设计新模块，开发出了很多新颖的网络结构，例如 9 层的 ZF-Net^[38]、典型的 VGG-16 和 VGG-19^[39]、22 层的 GoogLeNet^[40]、广泛应用的 ResNet^[41] 等。基于深度学习的输电线路巡检图像检测网络大多使用 VGG-Net、GoogLeNet、ResNet 作为骨干网络，这些骨干网络常用于航拍图像中的电力设备特征提取和分类。

1.1.1 VGG-Net

2014 年，Visual Geometry Group 团队将 3×3 卷积核与 2×2 最大池化组合，提出了结构简单、泛化性能较好的 VGG-Net 网络，取得了当年 ImageNet 竞赛的亚军。VGG-Net 通过多个卷积核(3×3)堆叠来提升空间特征学习能力，具有较强的实用性。为了预防输电线路的涉鸟故障，邱等^[42]构建了基于

CAM-VGG16 的危害鸟种图像识别模型。首先采用类激活映射(class activation mapping, CAM)提取鸟种图像热力图；再对 VGG-16 进行微调，将 conv5-3 后的池化层和全连接层用卷积+全局平均池化+全连接层+输出替代，且全连接层的维数由原始的 1×1000 调整为 1×88；最后对不同深度学习网络模型进行训练与测试。CAM-VGG16 模型的测试结果准确率达到 87.73%，比 Alex-Net 模型高出 5%，仅落后 ResNet50 模型 2%。为了提取输电线路金具的深度特征，赵等^[43]以 VGG-16 作为特征提取器，在倒数第 2 个全连接层 FC7 后利用主成分分析(principal component analysis, PCA)对 1×4096 特征降维，进一步地提升了金具缺陷识别精度。

1.1.2 GoogLeNet

为了降低计算成本，GoogLeNet 网络取消了全连接层，在网络宽度方面引入 Inception 模块化结构，网络层数加深到 22 层。GoogLeNet 网络将 top-5 的错误率降低到 7%以下，成为 2014 年 ImageNet 竞赛冠军。汪等^[44]将 GoogLeNet 网络用于复合绝缘子憎水性分级研究，解决了传统 CNN 网络中全连接层参数复杂问题。为了实现海量巡检图像的智能分类，徐等^[45]基于 GoogLeNet Inception-V3 模型对电力设备图像进行智能识别，将卷积核(1×1)与卷积核(3×3)、卷积核(5×5)和池化层串联使用，在增大感受野的同时降低了计算成本。实验结果表明，GoogLeNet 模型的电力设备识别准确率高达 92%，比浅层 CNN 模型和最近邻(k-NearestNeighbor, kNN)分类算法分别提高 32.5%和 24%。

1.1.3 ResNet

DCNN 网络深度的加深会引起梯度消失或梯度爆炸，为了解决这一问题，何等^[41]运用残差学习机制设计残差块和 shortcut 跨层连接，提出了 ResNet 网络，网络深度可达到 152 层，并获得 2015 年度 ImageNet 竞赛冠军。以 ResNet 为骨干网络的深度学习网络模型可以增强特征表达与提取能力。张等^[46]提出了一种多尺度特征融合网络模型，以骨干网络(ResNet-50)级联特征金字塔网络(feature pyramid network, FPN)用于图像特征提取，实现鸟巢、涉鸟故障等目标多分辨特征融合。李等^[47]以 ResNet-101 为基础网络级联 6 层 FPN 网络，提高了小目标绝缘子的检测精度。李等^[48]以 ResNet 为 SSD 算法骨干网络并引入注意力机制，提高了防振锤检测精度。shortcut 跨层连接使更深层次的网络模型

训练成为可能,研究者在 ResNet 残差网络的基础上开发出 ResNext^[49]、Inception-ResNet^[50]、DenseNet^[51]、Res2Net^[52]、ResNeSt^[53]等改进网络,改进网络模型训练的网络深度可达上千层,且相同深度的检测精度更高。

随着经典网络层数逐渐加深,网络特征提取性能得到显著提高。以 Darknet 为深度学习框架构建了 Alex-Net、VGG-Net、ResNet、ResNeXt、DenseNet 和 Darknet53 预训练模型,表 1 给出了部分预训练网络模型在分类任务(ImageNet)中的预测结果,包括相应训练模型的 top-1、top-5 预测准确率, GPU 和 CPU 图像处理速度,预训练权重文件大小,其中 GPU 和 CPU 图像处理速度分别在 Titan X、Intel i7-4790K(4GHz)上完成测试。

表 1 预训练模型分类任务性能对比

Table 1 Performance comparison of pre-trained models for the tasks of classification

Model	top-1	top-5	GPU	CPU	Weights
Alex-Net	0.570	0.803	3.1 ms	0.29 s	238 MB
VGG-16	0.705	0.900	9.4 ms	4.36 s	528 MB
VGG-19	0.729	0.912	6.2 ms	0.87 s	80 MB
ResNet 18	0.707	0.899	4.6 ms	0.57 s	44 MB
ResNet 50	0.758	0.929	11.4 ms	1.13 s	87 MB
ResNet 101	0.771	0.937	20.0 ms	2.23 s	160 MB
ResNet 152	0.776	0.938	28.6 ms	3.31 s	220 MB
ResNeXt 50	0.778	0.942	24.2 ms	1.20 s	220 MB
DenseNet 201	0.770	0.937	32.6 ms	1.38 s	66 MB
Darknet 53	0.772	0.938	26.3 ms	7.21 s	159 MB

1.2 检测网络

目标识别采用人工设计分类器方式的传统目标检测方法难以满足实时性要求,而深度学习方法利用 CNN 自动学习样本图像特征,实现了端到端的目标检测,极大地压缩了目标检测的中间过程,避免了传统目标检测方法鲁棒性差等缺陷。

基于 DCNN 的主流目标检测算法根据有无候选框生成阶段分为双阶段(two-stage)检测网络和单阶段(one-stage)检测网络两大类。本节重点概括了两类检测网络中的典型算法,并对其在绝缘子检测中的应用研究进行了总结。

1.2.1 two-stage 检测网络

two-stage 检测网络先以滑动窗口、选择性搜索等方式选取大量的目标候选区域,再进行图像特征提取和分类,最终得到预测边界框。典型的 two-stage 算法包括 R-CNN^[54](Regions with CNN)、SPP-Net^[55](spatial pyramid pooling network)、Fast

R-CNN^[56]、Faster R-CNN^[57]、R-FCN^[58](region-based fully convolutional networks)等。

2014 年 Girshick 等^[54]提出了 R-CNN 算法, R-CNN 成为了 two-stage 检测网络的开山之作,然而其通过选择性搜索获得候选区域存在大量冗余操作。何等^[55]将空间金字塔(spatial pyramid pooling, SPP)池化层引入 R-CNN,提出 SPP-Net 算法,解决了输入图像尺寸受到限制的问题。受到 SPP-Net 的启发,2015 年 Girshick 等将候选区域坐标引入分类和边界框回归,提出了 Fast R-CNN 算法,进一步提高了目标检测速度。基于 Fast R-CNN 和区域提议网络(region proposal network, RPN),Ren 等^[57]提出了 Faster R-CNN 算法,利用 RPN 网络替代选择性搜索算法来产生候选区域,将特征提取、区域提议、分类、边界框回归等过程整合到一起,基本上实现了 end-to-end 的目标检测,进一步地提高了 DCNN 的检测精度和速度。Faster R-CNN 算法结构如图 3 所示。

Faster R-CNN 具有较高的检测精度,作为主流的目标检测算法,已应用于输电线路巡检解决电力设备识别及缺陷检测问题。刘等^[59]采用深度学习算法进行航拍图像中绝缘子定位与缺陷检测,训练好的 Faster R-CNN 网络模型在测试集上取得了较好的检测效果(94%的准确率,88%的召回率),10 帧/s(frames per second, FPS)的检测速度。针对不同尺度以及相互遮挡绝缘子的状态检测,Zhao 等^[60]在 RPN 网络中引入非极大值抑制策略对 Faster R-CNN 进行改进,绝缘子检测平均精度(average precision, AP)比原有算法提高了 17.8%。为了解决多类别巡检线路设备缺陷检测问题,Liang 等^[61]通过改进 Faster R-CNN 算法构建多类别缺陷检测网络模型,设计以 ResNet-101 为骨干网络的 Faster R-CNN,该网络模型用于绝缘子、均压环、防振锤、鸟巢、异物等 10 个类别缺陷检测,平均精度均值(mean Average Precision, mAP)达到 91.1%,高于以 VGG-16 为骨干网络的 Faster R-CNN 算法 11%。传统目标检测方法在进行绝缘子缺陷检测过程中存在效率低下、成本高的缺陷,为了克服上述缺陷,Fan 等^[62]将深度学习算法与机器学习算法结合用于绝缘子缺陷自动识别,首先采用随机森林(random forest, RF)分类算法识别出绝缘子,再利用 Faster R-CNN 算法进行绝缘子自爆区域检测,玻璃绝缘子自爆缺陷检测的 AP 值比传统的图像处理方法有所

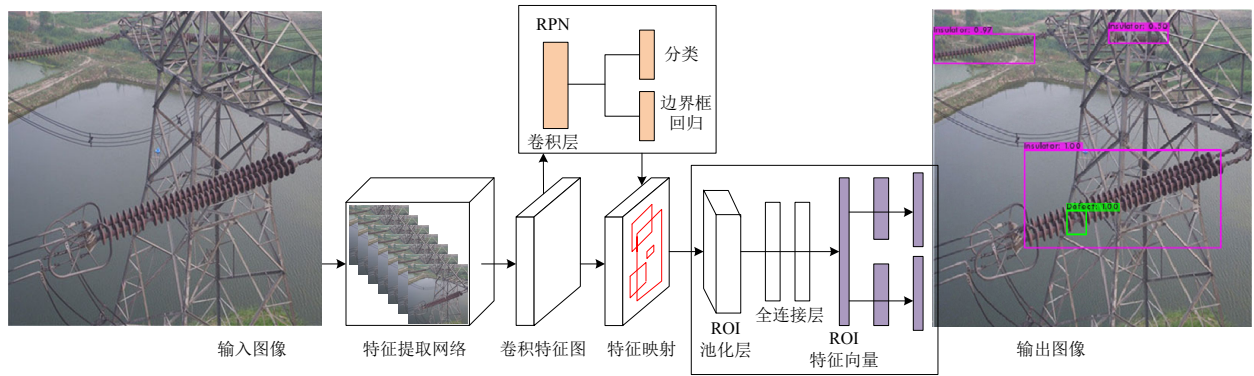


图 3 Faster R-CNN 算法

Fig. 3 Structure of Faster R-CNN algorithm

提高。对巡检图像进行去噪处理和绝缘子分割操作是一项困难的任务, Li 等^[63]将 RPN 网络与 FCN 算法结合训练出具有较强鲁棒性和环境适应性的 R-FCN 算法, 利用像素分类方法检测出绝缘子缺陷。为了能够实现图像中不同尺度的多个绝缘子缺陷检测, Yang 等^[64]利用 Mask R-CNN 进行绝缘子识别和自爆缺陷检测。针对小目标绝缘子缺陷检测, 文献^[65-66]将目标检测算法与语义分割算法相结合构成级联检测模型, 先利用深度学习算法 (faster R-CNN 算法) 对巡检图像中绝缘子定位, 再通过语义分割算法 (FCN 算法或 U-net 算法) 进行缺陷位置检测。

two-stage 检测网络首先获取目标候选区域, 然后提取目标特征、分类、边界框回归, 此类算法具有较高的准确率, 由于网络模型复杂且参数较多, 使得网络模型训练时间较长。

1.2.2 one-stage 检测网络

one-stage 检测网络无需进行候选区域生成阶段, 直接在特征提取网络后分类与边界框回归, 输出预测目标位置与所属类别, 典型算法包括 YOLO 系列^[67-69](you only look once)、SSD^[70](single shot multibox detector) 等。

2015 年 Redmon 等人将物体检测当作回归问题来处理, 提出了 YOLO-v1 模型, 与采用滑窗或区域提议方式训练网络模型不同, YOLO 网络模型提取特征后直接输出预测结果, 可实现端到端的训练。YOLO-v1 网络模型的图像处理速度较快 (可以达到 45FPS), 但是其检测速度的加快是以牺牲了一定精度为代价。YOLO-v2^[67]以 Darknet-19 为骨干网络, 引入 Anchor 机制和特征融合策略等, 进一步提升了网络模型的检测平均精度和检测速度。2018 年, Redmon 等人借鉴残差网络思想构建了 Darknet53 骨干网络, 在 YOLO-v2 的基础上, 通过改进骨干网络、多尺度预测、9 个 Anchor 机制、损失函数等, 提出了适用于物体实时检测的 YOLO-v3^[68]模型, 其算法结构如图 4 所示。除此之外, YOLO-v4、YOLO-v5 等优秀的 YOLO 系列目标检测网络被相继提出。

YOLO-v3 能够满足实时检测任务的要求, 在目标检测平均精度和检测速度上具有突出的优势, 已成为当前工程界首选的深度学习检测算法之一。为了便于网络模型部署在嵌入式设备上, 韩等^[71]将内存占用量较小的 ResNet50 网络取代 Darknet53 作为骨干网络, 利用改进 YOLO-v3 算法获取航拍图像

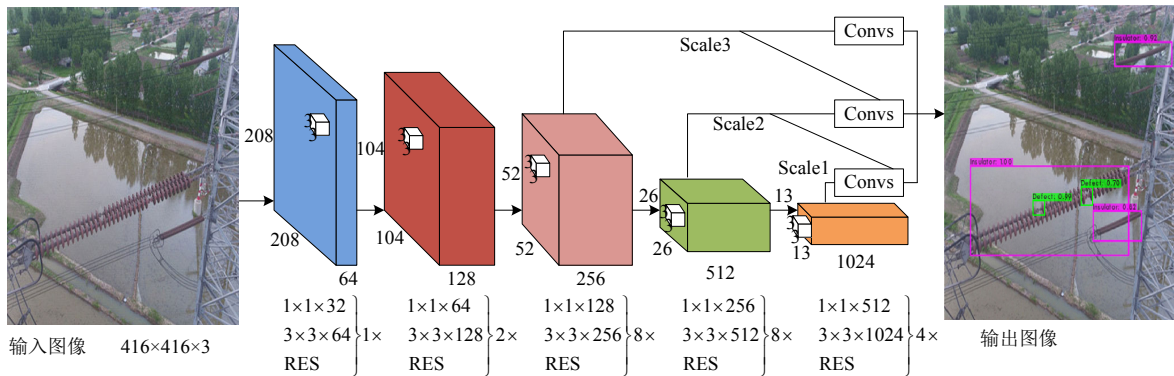


图 4 YOLO-v3 算法

Fig. 4 Structure of YOLO-v3 algorithm

中绝缘子的准确位置,与原始 YOLO-v3 算法相比,改进网络模型的内存占用量降低了 14.5%。为了实现复杂背景下绝缘子多缺陷检测,Han 等^[72]提出级联 YOLO 模型用于航拍图像中绝缘子多个自爆缺陷检测,先利用 YOLO-v3 识别图像中的绝缘子,再将定位出绝缘子区域设置成感兴趣区域(region of interest, RoI),最后利用简化的 YOLOv3 模型(YOLOv3-tiny)对 RoI 区域进行缺陷检测。与文献[71]中所采用的传统图像处理方法检测绝缘子缺陷相比,检测准确率和召回率分别提升近 30%,绝缘子图像缺陷检测的平均运行时间由 130ms/幅缩短到了 30ms/幅。

2016 年 Liu 等^[70]在 YOLO-v1 回归思想的基础上,有效地结合 Faster R-CNN 算法的 Anchor 生成机制以及多尺度特征融合策略,提出了 SSD 算法,如图 5,其以 VGG-16 为骨干网络,通过多尺度预测和多个先验框设置,利用大尺度和小尺度特征图融合识别图像中同一类别不同大小的物体。与 Faster R-CNN、YOLO-v1 算法相比,SSD 算法将不同尺度的特征进行融合,进一步提高了目标检测速度和平均精度。为了识别巡检航拍图像中不同尺度的绝缘子,Xu 等^[73]利用 SSD 网络模型用于可见光图像中绝缘子定位研究,SSD 网络模型比 Faster R-CNN 取得了更好的检测效果(mAP 提高了 2.1%,检测速度提升近 3 倍)。Tan 等^[74]提出一种级联检测模型用于自动识别输电线路巡检图像中的缺陷绝缘子,先利用 SSD 算法检测所有绝缘子的位置,再利用 DenseNet 网络对检测到的绝缘子进行分类,最后在测试数据集上进行实验,缺陷绝缘子的识别准确率达到 95%。SSD 算法对大目标检测取得了较好的效果,但对中小目标检测还存在鲁棒性差的问题。为此,一些研究者通过改进特征提取网络、多

尺度特征融合等方式,衍生很多改进算法(如 DSSD、FSSD、RSSD 等)。

Faster R-CNN、YOLO、SSD 等常用目标检测算法都是基于 Ancher 机制实现目标检测,但是 Ancher 机制不仅需要提取大量的候选区域,而且还会引起正负样本不均衡问题^[75]。Law 等^[76]基于 Ancher-free 的思想提出 CornerNet 网络模型,将边界框检测转换成角点对检测,然而角点对的选择需要复杂的计算,且易生成错误的边界框。在 CornerNet 的基础上,Duan 等^[77]提出 CenterNet 网络模型,利用左上角、右下角、中心点结合构成三元组对生成的边界框进行限定,通过级联角点池化和中心池化优化边界框,有效地提高了 Ancher-free 模型的检测精度和速度。赵等^[78]基于 CenterNet 提出一种用于高压输变电线路多故障巡检的实时检测方法,先通过 DLA-SE(deep layer aggregation and squeeze excitation)特征提取网络提取检测对象的中心点热力图,再利用 CenterNet 确定检测对象的边界框,所提出的级联检测模型与 YOLO-v3、SSD 实时检测模型相比,电力设备故障检测 mAP 得到大幅提升。

在输电线路巡检中,基于深度学习的目标检测得到了广泛应用,众多研究者对两类检测网络进行了深入研究,提出了很多典型应用的改进算法,取得了较好的检测效果。表 2 对比了上述两类深度学习典型算法的性能,给出了在数据集(PASCAL VOC 2007)上的检测速度(FPS)及其平均精度均值(mAP)。表 3 列出了深度学习算法在绝缘子识别中的典型应用。two-stage 算法具有较高的检测准确率,one-stage 算法具有较快的检测速度,它们分别是精度和速度的代表。其中,one-stage 算法对目标实时处理更具适用性,在公共数据集上获得了更好的性能。




图5 SSD 算法

Fig. 5 Structure of SSD algorithm

表 2 不同目标检测算法性能

Table 2 Performance of different target detection algorithms

检测算法	检测速度/FPS	mAP
R-CNN	0.075	46~64%
SPP-Net	-	63.3~82.1%
Fast R-CNN	-	66.7~70.2%
Faster R-CNN	14.9	73.1~85.4%
YOLO	44.8~150.1	58.6~8.6%
SSD	58.2~72.1	75.2%

表 3 深度学习算法在绝缘子识别中的典型应用研究

Table 3 Research on typical applications of deep learning algorithms for insulator recognition

类别	算法	文献	应用场景	数据集规模/幅	训练模型检测效果
two-stage 算法	Faster R-CNN	[59]	绝缘子识别、 自爆故障检测	2620	绝缘子识别准确率 94%，召回率 88%；绝缘子自爆 检测准确率 92%，召回率 75.5%；FPS 大于 10。
	Faster R-CNN	[60]	输变电设备中 绝缘子检测	2535	以 VGG-16 为主干网络，引入 NMS 到 RPN 中， 绝缘子检测 AP 为 81.8%，相比之前算法提高了 17.8%。
	Faster R-CNN	[61]	输电线路巡检 10 个 类别缺陷检测	8000	以 ResNet-101 为主干网络的检测模型 mAP 为 91.1%， 比以 VGG-16 为主干网络的检测模型提高了 11%。
	Faster R-CNN	[62]	绝缘子缺陷检测	700	绝缘子缺陷检测 AP 为 91%，比传统图像处理方法 提高了 1.3%，图像平均处理时间为 0.5s。
	R-FCN	[63]	绝缘子裂纹检测	4104	绝缘子裂纹检测 AP 为 90.5%，单张图像处理时间小于 1s。
	Mask R-CNN	[64]	绝缘子自爆检测	810	单目标检测的 AP 接近 100%，多目标检测 mAP 达到 94.8%。
	Faster R-CNN + FCN	[65]	绝缘子自爆检测	3000	在极其复杂的背景下，能够有效地检测出绝缘子故障位置。
	Faster R-CNN + U-net	[66]	绝缘子缺陷检测	1600	绝缘子缺陷识别的准确率 91.9%，召回率 95.7%。
one-stage 算法	YOLO-v3	[71]	绝缘子检测	4031	绝缘子检测的平均精度 90.31%，检测速度 50 FPS。
	级联 YOLO 模型	[72]	绝缘子故障检测	764	故障检测准确率 92.1%，召回率 92.2%，平均运行时间 30ms。
	SSD	[73]	绝缘子检测	6000	绝缘子检测 mAP 达到 94.7%，检测时间为每幅图像 30ms。
	SSD	[74]	绝缘子故障检测	1308	绝缘子识别准确率 95%，绝缘子故障分类准确率 98%。
	CenterNet	[78]	绝缘子自爆、防振锤 脱落、鸟巢检测	2509	绝缘子自爆、防振锤脱落、鸟巢三类故障的检测 mAP 为 91.7%，检测速度达到了 27 FPS。

1.3 语义分割网络

语义分割网络与 1.2 节目标定位和分类的检测网络不同，语义分割网络还需要还原目标轮廓，通常利用解码器重建目标的位置信息。目前语义分割网络主要有编码器-解码器^[79-81]和空洞卷积层^[82]两种网络结构。

1.3.1 编码器-解码器网络

以 FCN、SegNet、U-Net 为代表的语义分割网络，卷积层+池化层操作构成编码器使图像特征图尺寸逐渐减小以获得高层语义信息，反卷积层+shortcut 跨层连接构成解码器使图像特征图尺寸逐渐增大以恢复底层空间位置信息。编码器部分通常采用 VGG-16、ResNet、GoogleNet 等分类网络作为特征提取网络。

FCN 去除了分类网络中的全连接层，以跨层连接方法融合图像特征，完成每个像素分类。虽然其只能从像素层面对特征图像素分类，没有考虑图像

分割的整体性，但是 FCN 网络推动了图像分割向深度学习方向发展。李德胜^[83]对 FCN 网络进行改进，在第 5 个池化层后引入多尺度采样模块，利用多个膨胀卷积层并融合多尺度信息，有效地分割出输电线路中的关键线路设备。

在 FCN 网络中，通过反卷积和跨层连接无法得到精细的分割图，只能通过引入更多的 shortcut 跨层连接提升图像分割效果。然而，FCN 跨层连接仅复制了编码器特征，与之不同的是，SegNet 网络提出了解码器结构，并在解码器端引入了最大池化指数，使得 SegNet 网络性能优于 FCN 网络，其主要用于多分类语义分割任务。

U-Net 网络基于完全对称的 U 型编码器-解码器结构，通过增加特征提取网络深度可以改善像素分割效果。为了对线路走廊的施工车辆进行准确检测，王等^[84]将 U-Net 网络原有的 18 个 3×3 卷积层增加到 23 个，小目标检测能力得到了提高。黄等^[85]

为了实现架空电力线实时分割,以 VGG-16 为特征提取网络,通过优化网络结构来改进 U-Net 网络,改进网络模型应用于 Jetson TX2 移动端设备并取得了良好的检测效果。

1.3.2 空洞卷积层结构网络

Chen 等^[86]提出 DeepLab v1 以来,空洞卷积层成为语义分割网络中另一种常见结构。含有空洞卷积层的语义分割网络采用设置不同的空洞率的方式来实现深层特征与浅层特征融合。电力线在航拍图像中所占像素宽度较小,通常只有 1-5 个像素,为了准确定位航拍图像中的电力线,王栩文^[87]融合了 DeepLab v3+ 和 SegNet 网络的思想,提出了 DeepLab v3+ Decoder 网络模型,改进网络模型比 DeepLab v3+ 更适合完成航拍图像中电力线分割任务。

在完成航拍输电线路航拍图像中的电力设备检测任务时,电力线检测通常采用二分类语义分割算法,其它电力设备检测大多采用 one-stage 或 two stage 检测算法,多目标检测还可以采用多分类任务的实例分割算法^[88]实现。

1.4 轻量化网络

DCNN 对硬件计算资源要求较高,而应用场景中的终端设备计算能力有限,为了解决这一矛盾,研究者致力于轻量化网络在移动设备上的应用,开发出了以 SqueezeNet^[89]、MobileNet^[90] 系列、ShuffleNet^[91] 系列、Xception^[92] 等为代表的轻量化网络。

1.4.1 SqueezeNet

为了压缩模型参数,Iandola 等^[89]在 Inception 模块的基础上改进网络结构设计出 Fire module,多个 Fire module 堆叠构成了 SqueezeNet 网络,使网络模型的深度和大小得到了进一步降低。王等^[93]提出了基于 SqueezeNet 的图像融合方法,设计的 SqueezeNet 模型参数量仅为 ResNet-50 的 1/204,且模型大小压缩近 20 倍。Gholami 等^[94]在 SqueezeNet 的基础上,结合残差网络 ResNet 的思想,开发出了 SqueezeNext 网络。

1.4.2 MobileNet 系列

为了降低网络模型的参数量和计算量,MobileNetV1-3 网络利用深度可分离卷积块构成骨干网络。为了克服 SSD 算法对中小型目标检测效果不好的缺陷,任等^[95]利用 MobileNet 优化 SSD 算法,提高了改进模型的准确性、实时性和鲁棒性。马等^[96]将 MobileNetV3 轻量化网络与多尺度检测网络

SSD 结合提出 MobileNetV3-SSD 目标检测模型,实现了输电线路覆冰厚度的智能识别与监测。

1.4.3 ShuffleNet 系列

Zhang 等^[91]对常规残差网络单元进行改进,提出 ShuffleNetV1 轻量化网络。ShuffleNetV1 由深度可分离卷积+分组卷积构成。Ma 等^[97]在 ShuffleNetV1 的基础上,利用通道变换改进分组卷积,提出了 ShuffleNetV2 网络。张等^[98]基于 ShuffleNetV2 优化 YOLOv4 算法,采用 ShuffleNetV2 替换 CSPDarknet53 骨干网络,并通过深度可分离卷积取代普通卷积层,改进模型在牺牲了 1.8% 的精度下,检测速度提高 27%,容量压缩 23.7%。

1.4.4 Xception

为了解决深度可分离卷积计算零散的问题,Google 公司在 InceptionV3 的基础上结合空间相关性和通道相关性,提出 Xception 轻量化网络,其计算能力优于 InceptionV3 模块。邱等^[99]将 Xception 骨干网络作为编码器引入 DeepLabV3+ 语义分割网络中,实现了更快、更强的编码解码,较好地提升了分割效果。

除上述网络外,还有很多轻量化网络没有列举,如 NasNet、MnasNet、YOLO-Tiny、CSPNet、EfficientNet、ThunderNet、BiSeNet 等,将轻量化网络部署在移动设备上与 UAV 结合用于输电线路在线巡检也是未来的发展方向之一。

2 输电线路巡检图像数据目标检测

随着 UAV 应用逐渐普及,基于 UAV 的输电线路巡检具有广阔的应用前景,很多电力公司已将 UAV 航拍输电线路图像用于线路设备状态检测与故障诊断。输电线路巡检中关键设备检测方法包括人工观察、传统目标检测及深度学习 3 类方法。人工观察方法是通过人工肉眼观察的方式在巡检图像中查找线路设备并对缺陷位置进行标注,由于需要处理大量的图像数据,容易造成线路设备的错检和漏检。传统目标检测方法通常先以滑动窗口的方式获取感兴趣区域 RoI,再利用特征描述算子获取特征向量,该方法需要人工设计特征分类器,存在计算量大、学习效率低、学习能力差等缺陷。深度学习方法在特征提取等很多方面具有较大优势,通过 DCNN 提取线路设备深度特征,实现 end-to-end 的目标检测,在很大程度上改善了前两种方法的不足。

利用深度学习算法在海量的航拍图像中对线

路设备及缺陷进行自动识别与分类具有重要研究意义。DCNN 近年来才开始用于输电线路巡检目标检测, 针对输电线路巡检图像数据中关键设备识别及缺陷检测研究目前主要集中在电力线、绝缘子、电力杆塔、金具等线路设备, 基于 UAV 巡检的输电线路航拍图像如图 6 所示。




图 6 输电线路巡检航拍图像

Fig. 6 Aerial images of transmission lines inspection

2.1 电力线识别

电力线作为高压架空输电线路的主体, 起着传输电能的作用。UAV 在输电线路巡检的广泛应用使得电力线检测变得至关重要, 准确识别电力线有助于 UAV 自动避障、保障 UAV 低空飞行安全。从图 6 中输电线路巡检样本来看, UAV 航拍图像中电力线性特征明显, 宽度只有 1~5 个像素, 但是对于复杂的现实应用场景, 电力线识别易受植被、道路、田地等因素影响。

目前电力线识别算法主要集中在基于边缘检测算子、霍夫变换(Hough Transform)、Radon 变换、基于联合特征的电力线提取算法^[100], 上述非深度学习算法不具有扩展性, 当场景变化时无法通过自适应调整参数来维持算法良好的性能。Yetgin 等^[101]利用深度学习网络框架对电力线检测进行探究, 分别以 ResNet-50 和 VGG-16 作为骨干网络构建深度学习算法, 实现航拍图像中的电力线正确分类, 但所设计的算法利用 CNN 对电力线进行特征提取,

仅用于判断航拍图像中是否存在电力线, 无法定位出图像中的电力线。为了定位航拍图像中的电力线, Nguyen 等^[102]提出了一种基于像素分割的电力线检测网络 LS-Net(line segment-net), 由全卷积特征提取器、分类器、线段回归器构成, 以线段端点回归的方式快速、准确地定位出电力线。虽然还有很多基于深度学习的电力线分割算法被相继提出, 但大部分电力线分割算法都是基于像素分割, 面临着缺乏大规模电力线数据和像素级标注困难的问题。为此, 陈等^[103]提出了一种用于电力线语义分割的实时轻量级网络 SaSnet 和自监督学习算法, 相比现有电力线分割算法, 电力线识别精度和速度在公开数据集上都有了明显提升。

目前随着深度学习算法的广泛应用, 基于深度学习框架的端到端分类器实现了航拍图像中电力线的正确分类, 在自监督或弱监督下设计电力线语义分割、实例分割算法更具有研究价值。

2.2 绝缘子及缺陷检测

绝缘子作为输变电系统中重要电力设备之一, 在输电线路中起着电气绝缘与电力支撑的双重作用。绝缘子也是中最容易发生事故的电力设备之一, 其数量大、种类多、分布广, 而且长期暴露于户外, 容易造成表面缺陷。据统计, 电力系统中的很多电力事故是由绝缘子缺陷引起的^[8]。

在主流深度学习算法(Faster R-CNN、SSD、YOLO)的基础上, 研究者提出了一些性能良好的深度学习算法, 开展无人机巡检图像中绝缘子识别及缺陷检测研究。针对现有 Faster R-CNN 网络模型在绝缘子缺陷识别中呈现出检测时间长、精度低的不足, Wang 等^[104]提出了改进的 Faster R-CNN 算法, 以 ResNeSt 网络作为骨干网络, 将 RPN 网络引入 ResNeSt 网络加强缺陷特征提取, 绝缘子缺陷检测的准确率提高到 98.38%, 检测速度达到 12.8 FPS。鉴于绝缘子及缺陷的形状各异, 为了准确定位航拍图像中绝缘子的缺陷, 江等^[105]采用多层感知集成学习模型识别绝缘子及其缺陷, 先利用 4 个 SSD 网络模型训练出 1 个绝缘子定位模型和 3 个绝缘子缺陷的检测模型, 再利用多层感知与集成强化学习将航拍图像中全局信息与局部绝缘子缺陷信息融合实现绝缘子缺陷的检测, 检测准确率提升到 92.26%, 比单一 SSD 算法提高近 10%。为了解决航拍图像中绝缘子定位不准确的问题, 李等^[106]提出了基于改进 SSD 算法的绝缘子定向识别方法, 将

SSD 网络模型的损失函数引入角度信息变量,通过定向边界框迭代回归定位出绝缘子,在包含 87 幅图像的测试集上进行对比实验,改进 SSD 算法比边界框固定 SSD 算法的检测准确率提高 5%。在复杂背景干扰的航拍图像中,为了实现不同尺度下的绝缘子定位, Liu 等^[107]提出了一种改进的 YOLO-v3 算法,通过在 Darknet53 网络中加入 DenseNet 模块和改进特征融合策略,实现了不同背景干扰下的多绝缘子准确定位。为了满足输电线路巡检中绝缘子实时检测要求,刘等^[108]基于轻量化 MobileNet 网络实现航拍图像中绝缘子检测,瓷质绝缘子的检测精度达到 96.29%,高于 Faster R-CNN(94.58%)、R-FCN(92.43%),检测速度提高到 43 FPS。

级联网络模型可以有效提高小目标检测精度,陶等^[109]将绝缘子缺陷检测问题转化为绝缘子定位和缺陷两级目标检测,先利用绝缘子定位网络(insulator localizer network, ILN)定位出图像中的所有绝缘子,然后分割图像中的绝缘子,再利用缺陷检测网络(defect detector network, DDN)在分割绝缘子图像上定位出缺陷位置,级联检测模型在绝缘子缺陷检测上取得了较好的检测结果(准确率为 91%,召回率为 96%),但级联检测模型的平均运行时间为 359ms/幅。为了准确、快速定位出玻璃绝缘子自爆缺陷位置, Ling 等^[110]提出一种基于 Faster R-CNN 和 U-Net 网络的级联检测模型,先利用 Faster R-CNN 算法定位图像中的绝缘子,再利用语义分割算法(U-Net)进行绝缘子缺陷检测,测试结果表明级联检测模型的检测性能优于 Faster R-CNN、U-net 单一检测算法。Chen 等^[111]设计了一种基于二阶 FCN 算法的绝缘子缺陷检测模型,先用一个 FCN 模型从复杂背景中分割出绝缘子,再利用第 2 个 FCN 模型对分割出的绝缘子区域进行缺陷检测,与经典的 CNN 和 FCN 分割算法相比,二阶 FCN 算法能够有效抑制背景干扰,进一步提高缺陷检测精度。绝缘子自爆区域相比整个绝缘子乃至整幅航拍图像要小得多,为此,林等^[112]融合多种深度学习网络模型实施绝缘子缺陷检测,先通过训练集依次对 Mask R-CNN、RetinaNet、YOLO-v3 算法进行训练,得到 Mask R-CNN、RetinaNet、YOLO-v3 检测模型,利用训练好的检测模型分别进行绝缘子自爆缺陷检测,再设计多模型融合策略对上述多个检测结果进行融合后输出。所提方法的检测性能优于 Mask R-CNN、RetinaNet、YOLO-v3、Faster R-CNN、

SSD 等单一检测模型。

为了解决训练样本不足、图像标注繁琐等问题, Shi 等^[113]提出了一种基于 Faster R-CNN 弱监督学习方法用于绝缘子缺陷检测,取得了 92.86%的缺陷检测准确率, F1-Score 为 90.85%。王等^[114]改进生成对抗网络(generative adversarial network, GAN)用于绝缘子缺陷检测,将 GAN 与 U-Net 相结合构成无监督学习模型,玻璃绝缘子自爆缺陷检测平均精度达到 84.6%。

基于深度学习的 UAV 巡检图像中绝缘子识别及缺陷检测是一项极具挑战性的任务,上述方法在绝缘子识别及缺陷检测取得了良好的检测性能,它对如何将目标检测、语义分割、实例分割算法部署到嵌入式设备上实施输电线路设备在线检测,以及探索在雾天等恶劣天气条件下绝缘子缺陷检测具有重要意义。

2.3 电力杆塔与附属设施检测

电力杆塔是输电线路中基础设施之一,用于支撑电力线以保证架空电力线路安全运行和保障电力线与地面满足人体安全距离,及时发现电力杆塔故障对输电线路灾损评估和灾后抢修具有重要意义。为了快速地检测航拍图像中的电力杆塔, Bian 等^[115]提出了 Tower R-CNN 检测模型,通过减少 Faster R-CNN 的卷积层数和限制区域建议数量,实现了输电线路中电力杆塔的快速检测,在保证检测精度的同时,检测速度由 0.8 帧/s 提升到 5 帧/s。郭等^[116]提出基于 YOLO-v3 的实时目标检测模型,用于无人机视频巡检图像中电力杆塔的状态检测,通过 K-means 聚类分析、优化模型参数,有效地检测出多种环境下不同尺度的电力杆塔目标,电力杆塔检测的平均精度达到 94.09%,检测速度达到 20 FPS。电力杆塔损伤评估是电力公司日常运营的一部分, Hosseini 等^[117]提出基于深度学习的电力杆塔损伤智能分类与评估算法,利用 4 个 ResNet-18 网络模型识别电力杆塔的状态和故障类型,并估计它们遭受的损伤程度。电力杆塔倾倒与燃烧分类准确率分别高达 97.14%和 98.78%,单幅图像的预测时间仅需 6ms。随着高压输电线路的不断增多,鸟害导致输电线路跳闸事件和电力设备损坏频繁发生,电力杆塔上安装防鸟刺可以有效地驱除鸟害。为了检测航拍图像中防鸟刺故障,缪等^[118]提出基于深度学习的防鸟刺识别与故障检测算法,以 ResNet-152 残差网络作为 YOLO-v3 的骨干网络,

有效地识别出巡检图像中故障防鸟刺,检测准确率达到 92.3%,与以 VGG-16、Darknet-53、ResNet-101 为特征提取网络的 YOLO-v3 网络模型相比,防鸟刺故障分类准确率提高了 11%、14%和 2%。

2.4 金具及缺陷检测

金具用于连接或加固绝缘子、电力线等电力设备,用以传递电气负荷、机械负荷及起到防护作用。由于金具种类繁多,主要金具类电力设备包括防振锤、均压环、间隔棒、连接板、螺栓、销钉等。根据(国网(运检/4)305-2014)管理规定,架空线路设备包含 878 种缺陷,在线路巡检中常见的金具缺陷占有 111 种^[29]。随着电力线使用寿命的增加,金具会出现腐蚀、磨损、开裂、松动等迹象。由于部分金具及缺陷目标较小,在输电线路中进行金具及缺陷检测困难较大。为了识别小部件金具,王等^[119]利用 two-stage 算法(Faster R-CNN)识别巡检图像中的金具类设备(防振锤、均压环、间隔棒),均压环检测准确率达到 92.7%,图像的识别速度接近 80ms/幅,小部件识别性能明显优于 DPM(deformable part model)、SPP-Net 算法。Wang 等^[120]基于 Faster R-CNN 算法在不同光照条件下识别巡检图像中的均压环,均压环识别平均精度达到 87.8%,实验结果证明所采用的深度学习网络模型具有较好的鲁棒性。防振锤是一种广泛使用的电力设备。针对传统图像处理方法在检测防振锤存在精度差、效率低的问题,罗等^[121]利用 R-FCN 算法对复杂背景下不同形态的防振锤进行识别,防振锤检测的 mAP 达到 88%。销钉也是一种重要的电力设备,用于固定螺母。销钉脱落缺陷检测可以看作小目标检测。李等^[122]对 Faster R-CNN 算法进行改进,提出了 PinNet 算法,SCNet 取代 ResNet 作为特征提取网络,引入 Pin-FPN 特征融合提高小目标检测能力,通过对比实验,PinNet 的销钉缺陷识别平均精度与 Faster R-CNN、YOLO-v3、Cascade R-CNN 算法相比分别提高 18%、11%和 5%。

小目标金具及其缺陷检测目前是电力行业的难点问题,深度学习算法能够用于无人机巡检图像中的金具类设备目标检测,构建更大的小部件样本库、更精细的部件类别可以进一步提高金具类目标识别精度。

2.5 输电走廊在线监测

架空输电线路作为供电系统的重要组成部分,其安全性与整个电力系统的正常运行息息相关,随

着城市化进程的加快,危险地物已成为高压架空输电线路安全隐患之一。由于输电线路走廊较长,异物(风筝、气球、塑料袋、鸟巢等)、植被、推土机和挖掘机等工程车辆不断侵入供电保护区,对供电安全构成严重威胁。Wang 等^[123]采用深度学习网络模型检测输电线路异物,利用 SSD 算法实现了巡检电力线图像中风筝、气球、鸟巢等异物检测,异物检测的 mAP 达到 85.2%,检测速度达到 26 帧/s,相比检测速度为 3 帧/s 的 Faster R-CNN 算法要快得多。随着城市基础设施建设的发展,为了避免推土机、挖掘机等外力破坏,供电部门加强了工程车辆的智能巡检。为了识别航拍图像中的工程车辆,Xiang 等^[124]对现有 Faster R-CNN 网络模型进行改进,通过调整 RoI 池化层位置来改变特征提取网络结构,推土机和挖掘机检测的 mAP 取得了 89.9%,比 Faster R-CNN 算法提高 0.8%。为了检测巡检线路上的异物,Zhu 等^[125]提出了多尺度深度学习网络模型,通过多尺度空间金字塔融合、定向边界框回归、尺度直方图匹配策略预测异物空间位置、角度和类别,异物检测的 mAP 达到 88.10%,比 YOLO-v3 和 SSD 分别提高 5%和 13%,检测速度高达 45 帧/s,比 SSD 算法每秒多处理 26 幅图像。

2.6 多类电力设备识别与分类

输电线路中电力设备种类繁多,前几节大多是采用深度学习算法实现了单一电力设备的识别与缺陷检测,相比传统的目标检测算法取得了较好的效果。文献[126-129]基于深度学习算法实现了多类电力设备的智能识别与分类。传统目标检测算法在复杂背景下不能对多种电力设备有效识别,为此,李等^[126]将深度学习算法与传统机器学习算法相结合识别巡检航拍图像中的电力设备,先利用 Alex-Net 预训练网络模型提取电力设备图像特征,再通过机器学习算法(随机森林 RF 算法)进行电力设备分类,5 种电力设备分类的 mAP 达到 89.6%,比 RF 分类算法和常规深度学习分类器分别提高了 12.6%和 6.8%。边远山区通常利用巡检机器人进行输电线路巡检,由于现场光照变化明显,巡检机器人无法准确识别电力线上的障碍物(绝缘子、防振锤、连接件等),Wang 等^[127]提出了基于简化 SSD 算法的输电线路障碍物检测方法,将原始 SSD 算法的 23 个卷积层减少到 7 层,障碍物识别的 mAP 达到 91.51%,虽然比原始 SSD 算法降低了 3%,但是在保证检测准确率的同时,障碍物的检测速度由 4.5

帧/s 提高到 15 帧/s。针对大部分目标检测算法不能满足巡检图像中多类别目标实时检测的要求,董等^[128]提出了基于 YOLO-v3 的电力设备实时检测方法,以 Darknet53 为特征提取网络,通过多尺度特征融合,改善小目标检测效果,实现了电力设备(防振锤、均压环、玻璃绝缘子、屏蔽环、复合绝缘子)的高精度实时检测,多种电力设备检测速度达到 57 帧/s,线路设备识别的 mAP 达到 90.80%,比 Faster R-CNN 算法高了近 3%。输电线路巡检航拍图像中目标智能识别和故障诊断主要针对绝缘子、均压环、防振锤、绝缘子自爆缺陷、鸟巢等,存在电力设备目标有限、故障种类覆盖不足的问题,刘等^[129]

提出了基于 R-FCN 算法的巡检图像中电力设备识别与故障诊断方法,先构建了 R-FCN 网络模型,再通过软件非极大值抑制等策略优化深度学习网络模型,最后将训练好的检测模型用于放电间隙松动等 12 类电力设备识别与定位,12 类电力设备检测的 mAP 达到 89.15%,比 YOLO-v3 算法提高 8%,比 Faster R-CNN 算法提高 5%,但其检测速度只有 8 帧/s,比 YOLO-v3 算法的 42 帧/秒要慢得多。

DCNN 在输电线路巡检中发挥着重要作用,上述基于 DCNN 的输电线路巡检航拍图像中电力设备及缺陷检测研究成果统计如表 4 所示。DCNN 已经在输电线路巡检图像检测方面发挥了重要作用,

表 4 基于深度学习算法的输电线路巡检目标检测研究成果统计

Table 4 Research Statistics of transmission lines inspection objects detection based on deep learning algorithms

应用对象	文献	性能	方法
电力线识别	[101]	网络模型成功提取电力线特征,并实现了电力线正确分类。	VGG-19 和 ResNet50 构成电力线分类器
	[102]	LS-Net 可以接近实时运行(20.4 FPS)。	LS-Net(CNNs+分类器+线段回归器)
	[103]	识别精度和速度在公开数据集上都超越了现有方法,具备实时检测能力。	SaNet(U-net+特征融合模块)和自监督学习
绝缘子及缺陷检测	[104]	绝缘子缺陷检测准确率 98.38%, mAP 为 95.8%, FPS 为 12.8。	改进 Faster R-CNN(改进 ResNeSt+RPN)
	[105]	绝缘子缺陷检测召回率、准确率分别为 93.69%、91.23%,缺陷检测 AP 为 92.26%,比 SSD 算法提高了 10%。	多层感知(4 个 SSD 检测模型)+集成强化学习
	[106]	绝缘子定位 AP 为 81.5%,比 SSD 算法提高了 5%。	SSD 检测模型+定向边界框
	[107]	绝缘子定位精度达到 94.47%,比 YOLO-v3 提高了 4%。	Darknet53+DenseNet+改进特征融合策略
	[108]	瓷质绝缘子的检测平均精度达到 96.29%,高于 Faster R-CNN(94.58%)、R-FCN(92.43%),检测速度可以达到 43 FPS。	可分离卷积层构成的 MobileNet 轻量化网络
	[109]	绝缘子缺陷的检测准确率和召回率分别为 91%、96%,单幅图像的平均运行时间需要 359ms。	绝缘子定位网络+缺陷检测网络
	[110]	绝缘子缺陷检测的准确率和召回率分别为 95.1%、95.5%,绝缘子自爆缺陷检测性能优于 Faster R-CNN、U-net 单一检测算法。	Faster R-CNN 算法+U-net 算法
	[111]	绝缘子缺陷检测准确率在 99%以上,与经典的 CNN 和 FCN 分割算法相比,能够有效抑制背景干扰,提高了绝缘子缺陷检测精度。	二阶 FCN 网络模型
电力杆塔与附属设施检测	[112]	绝缘子缺陷检测平均精度、准确率、召回率分别为 93.43%、97.23%、95.49%,均高于 Mask R-CNN、Retinanet、YOLO-v3 单一模型检测结果。	Mask R-CNN、Retinanet、YOLO-v3 构成多模型融合检测网络
	[113]	绝缘子缺陷准确率达到了 92.86%, F1-Score 达到 90.85%。	Faster R-CNN+弱监督学习方法
	[114]	缺陷检测平均精度达到了 84.6%,每幅图像的平均处理时间仅需 6.3 ms。	GAN 与 U-Net 结合构成无监督学习模型
	[115]	检测速度由 0.8 帧/s 提升到了 5 帧/s,检测平均精度为 89.8%。	Tower R-CNN
	[116]	电力杆塔检测的平均精度达到 94.09%,检测速度达到了 20 FPS。	YOLO-v3+K-means 聚类
	[117]	杆塔倾倒、燃烧分类准确率分别为 97.14%、98.78%,图像的预测时间仅需 6ms。	4 个 ResNet-18 网络模型
	[118]	防鸟刺识别准确率为 92.3%,与以 VGG-16、Darknet53、Resnet 101 特征提取网络分别提高了 11%、14%和 2%。	Resnet 152 作为特征提取网络的 YOLO-v3
	[119]	均压环识别准确率达到了 92.7%,图像的识别速度接近 80ms/幅,小部件识别性能明显优于 DPM、SPP-Net 算法。	Faster R-CNN
金具及缺陷检测	[120]	不同光照条件下均压环识别平均精度达到 87.8%。	Faster R-CNN
	[121]	防振锤的识别平均精度达到 88%。	R-FCN
	[122]	基于 PinNet 的销钉缺陷识别平均精度与 Faster R-CNN、YOLO-v3、Cascade R-CNN 算法相比分别提高了 18%、11%和 5%。	PinNet 算法(SCNet+PinFPN)
输电走廊在线监测	[123]	异物检测的 mAP 达到 85.2%,检测速度为 26 帧/s。	SSD 算法
	[124]	工程车辆检测 mAP 为 89.9%,比 Faster R-CNN 提高了 0.8%。	改进的 Faster R-CNN 算法
	[125]	异物检测 mAP 为 88.10%,比 YOLO-v3 和 SSD 分别提高了 5%和 13%,检测速度达到了 45 帧/s,比 SSD 多处理 26 帧/s。	多尺度卷积神经网络(多尺度空间金字塔融合+定向边界框回归+尺度直方图匹配策略)
多类电力设备识别与分类	[126]	5 类电力部件识别 mAP 达到了 89.6%,比常规深度学习分类器、随机森林分类器分别高出了 6.8%、12.6%。	AlexNet 网络模型+随机森林分类器
	[127]	多类别电力部件检测 mAP 为 91.51%,虽然比原始 SSD 算法降低了 3%,但是检测速度由 4.5 帧/s 提高到了 15 帧/s。	简化的 SSD 算法(23 个卷积层减少到 7 层)
	[128]	3 种电力部件检测速度达到 57 帧/s,部件识别 mAP 达到 90.80%,比 Faster R-CNN 算法高了近 3%。	YOLO-v3
	[129]	12 类电力部件检测 mAP 达到 89.15%,比 YOLO-v3 算法高了 8%,比 Faster R-CNN 算法高了 5%,检测速度达到 8 帧/s,比检测速度为 42 帧/秒的 YOLO-v3 算法要慢得多。	R-FCN

从研究成果来看,在不同深度学习算法下,绝缘子、电力杆塔、防振锤等特征明显的电力设备检测准确率达到 90%以上,具有代表性的 Faster R-CNN、YOLO-v3、SSD 算法在巡检图像中目标检测准确率相差不大,YOLO-v3 算法可以实现线路设备的实时检测,检测速度可以达到 50 帧/s,甚至更快。传统目标检测算法依赖人工设计检测器进行目标特征提取和分类,存在目标检测单一、泛化能力较差、不具有扩展性的缺陷。相比之下,深度学习算法依靠 CNN 自动学习提取特征,具有高度的可扩展性,同一网络模型适用于多种输电线路设备识别与缺陷检测,在工程应用中具有普适性。

3 数据集及评价指标

3.1 数据集

深度学习技术之所以能够快速发展,得益于大规模数据集的出现,目标检测算法的广泛应用,同样离不开数据集的支持。随着输电线路巡检业务的发展和无人机控制技术的不断进步,吸引了很多研究者从事输电线路设备识别及缺陷检测研究。但是电网作为国家重要的战略设施,处于保密等原因,绝大部分输电线路巡检图像处于非公开状态,只有有限的公开数据集用于相关研究。本节搜集整理了 7 个公开输电线路巡检数据集,主要集中于电力线和绝缘子,具体如下表 5 所示。

表 5 输电线路巡检公开数据集

Table 5 Public datasets of transmission lines inspection

数据集	规模	应用场景	链接
PLD [101]	8000	电力线分类	https://data.mendeley.com/datasets/n6wr4ry6v/8
GTPLD [101]	800	电力线 语义分割	https://data.mendeley.com/datasets/twpx8xcccw/9
CPLID [109]	848	绝缘子 及其故障检测	https://github.com/InsulatorData/InsulatorDataSet
Insulator Dataset [130]	2630	绝缘子检测	https://cv.po.opole.pl/dataset1
TTPLA [131]	1100	电力塔架 实例分割	https://github.com/r3ab/ttpla_dataset
OPDL [132]	4960	绝缘子分类、 缺陷检测	http://www.dee.eng.ufba.br/dslab/index.php/opdl_dataset
PLD-UAV [133]	860	电力线 语义分割	https://github.com/SnorkerHeng/PLD-UAV

PLD(Powerline Image Dataset) 和 GTPLD (Ground Truth of Powerline Dataset)^[101]数据集是 Lee 等人与土耳其电力传输公司(TEIAS)合作,使用红

外和可见光摄像机采集到的航拍图像,其提供了含有电力线的红外和可见光图像各 2200 幅及 4400 幅不包括电力线的红外和可见光图像。其中,8000 幅像素为 128×128 图像用于电力线分类检测,800 幅像素为 512×512 图像用于电力线语义分割检测。

CPLID^[109](Chinese Power Line Insulator Dataset)数据集是由中国国家电网公司提供的高压绝缘子航拍图像,其中包括正常绝缘子图像 600 幅,由于缺陷绝缘子样本有限,陶等人利用图像合成的方法生成绝缘子缺陷图像 248 幅。

Insulator Dataset^[130]数据集公开了在室外不同光照和背景条件下的支柱绝缘子图像 2630 幅。

TTPLA(Transmission Towers and Power Lines Aerial-image)^[131]数据集作为首个用于电力塔架实例分割的开源数据集,其公开了带有分割标签的电力塔架和电力线图像 1100 幅,图像分辨率为 3840×2160。

OPDL (Overhead Power Distribution Lines)^[132]数据集公开了工作电压为 15kV 下的 4 种配电绝缘子共计 4960 幅,包括陶瓷针式、陶瓷双色、聚合物灰色和玻璃绿色 4 类绝缘子。

PLD-UAV(Power Line Detection in Unmanned Aerial Vehicle)^[133]数据集由武汉大学测绘遥感实验室提供的无人机航拍图像用于电力线像素分割,包含 PLDU(Power Line Detection Urban) 和 PLDM(Power Line Detection Mountain)两个场景。

3.2 评价指标

将 1.2 节所述的两类(one-stage 和 two-stage)深度学习算法应用于目标检测中,需要对它们的性能进行评估,明确上述算法的优缺点,其性能指标包括准确率(Precision)、召回率 (Recall)、平均精度 (AP)、平均精度均值(mAP)。在机器学习分类任务中,存在常见的 4 种预测结果(True Positive、False Positive、True Pegative 和 False Pegative),它们用于描述真实标签与模型预测结果的关系,定义如表 6 所示。

表 6 TP、FN、FP、FN 的定义

Table 6 Definition of TP、FN、FP、FN

真实标签	模型预测	定义
前景(Positive)	前景 (Positive)	TP
背景(Negative)	前景 (Positive)	FP
背景(Negative)	背景 (Negative)	TN
前景(Positive)	背景 (Negative)	FN

Precision用于计算正确的预测结果占有所有预测结果的比例,其定义如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (1)$$

用于计算正确的预测结果占应该有预测结果的比例,可定义为

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (2)$$

如图7所示,以Precision和Recall分别为纵横坐标绘制成二维Precision-Recall曲线,AP(平均精度)用于评估深度学习检测模型整体效果,Precision-Recall曲线下的面积即为AP值,其定义如下:

$$AP = \int_0^1 P(R) dR \quad (3)$$




图7 Precision-Recall曲线

Fig. 7 Curve of Precision-Recall

多类别的平均精度值称为mAP(平均精度均值),它是评估所设计模型总体性能指标,可定义为

$$mAP = \frac{1}{c} \sum_{c \in \text{classes}} AP(c) \quad (4)$$

4 主要问题和展望

4.1 主要问题

深度学习技术在是输电线路巡检中发挥着重要作用,深度学习算法已成功用于巡检航拍图像中电力设备识别及缺陷检测,但也揭示了诸多问题等待挑战。

1) 训练样本匮乏。深度学习网络模型对样本数据量的依赖程度较高,良好的深度学习网络模型需要经过大量样本训练得到,而现有用于电力设备识别与分类的公开数据集较少,不能提供足够的训练样本数据,使得训练出的深度学习网络模型效果不佳,会造成过拟合或网络模型无法收敛。

2) 类别不平衡问题。用于图像分类的数据集需要有平衡的类别,即分类任务中不同类别的训练

样本数目应差别不大。然而在电力巡检航拍图像中,线路设备正常样本数量较多,且容易收集,而缺陷样本比较稀有,难以收集,(如绝缘子在输电线路中的用量较大,因此绝缘子出现得非常频繁,而存在缺陷的绝缘子却很少)。深度学习网络模型倾向于拥有训练样本数量较多的类别,而忽略拥有较少训练样本的类别,但是少量训练样本的类别往往就是需要识别的缺陷类别。

3) 小目标缺陷检测效果不佳。大多数深度学习算法如SSD、YOLO、以及Faster R-CNN,在小目标检测效果上表现欠佳^[134],这是电力设备识别及缺陷检测的一个主要难题,有些电力设备的缺陷相比正常设备要小得多(如绝缘子自爆区域与完好的绝缘子串相比),有些电力设备或部件缺陷与周围物体相比要小得多,(如与螺栓相配合的销钉,防振锤脱落、电力线断股等)。图8给出了4种输电线路巡检小部件缺陷,第1行为绝缘子自爆缺陷;第2行为销钉脱落缺陷,从左到右依次为绝缘子下挂点螺栓缺销钉、U型连板螺丝缺销钉、三角连板螺丝缺销钉和销钉滑出;第3行给出了防振锤脱落和电力线断股缺陷。




图8 输电线路巡检小目标缺陷

Fig. 8 Small objects failure of transmission lines inspection

4) 小样本部件及缺陷检测。输电线路中使用了多种电力设备,国网运维管理规定指出高压输电线路设备共计878种缺陷,涉及电力杆塔、绝缘子、接地装置、通道环境等8大类。电网容易受到各种类型缺陷影响,训练集难以覆盖所有缺陷形态,训练样本数据的缺乏以及深度学习模型在预测未知类别方面的局限性,给基于DCNN的输电线路巡检带来很大挑战。

5) 复杂背景下电力线特征提取。无人机巡检已在输电线路巡检中普遍应用,为确保无人机避障

巡航有必要进行电力线特征提取。由于电力线比较细且缺乏丰富特征，复杂背景下电力线通常很难与背景分离，电力线特征准确提取是无人机巡检关键的任务之一。

6) 航拍图像数据退化问题。UAV 巡检工作在室外场景下，其捕获的可见光图像易受到光照、地理环境等因素影响，导致航拍图像中存在噪声干扰、畸变、成像不清晰等退化问题。

4.2 展望

在输电线路巡检航拍图像智能处理中，深度学习方法占据着举足轻重的地位。虽然深度学习算法已经在巡检目标识别与缺陷检测方面得到了成功应用，但在数据集、类别不平衡、小目标检测、稀有部件及缺陷检测和电力线特征提取方面面临严峻的挑战。巡检电力设备目标识别与缺陷检测是深度学习应用领域富有挑战性的研究课题之一。

目前 DCNN 尚存在训练速度慢、网络模型选择得不到理论支撑的不足。在场景复杂目标多变的输电线路巡检中，未来研究可以从以下几个方面展开：

1) 小样本学习方法。图像增强是扩大训练样本数量的有效手段，常用的数据增强方法包括裁剪、镜像、添加噪声等，物理渲染方法、射线追踪技术合成图像可以有效增加样本数量。在样本数量有限的情况下，如何使用小样本数据训练出良好的深度学习网络模型将是未来深度学习研究内容之一。

2) 样本图像合成。利用 GAN^[135]等图像合成技术生成模拟样本，将自然图像与模拟样本图像混合共建数据集，解决样本匮乏问题。图像合成技术在一定程度上可以解决类别不平衡问题。类别不平衡问题的还可以通过给不同类别的样本分配不同的权重来解决。

3) 建立统一的数据集和评价标准。由于输电线路巡检行业的特殊性，深度学习在电力设备目标检测中应用面临的首要问题就是缺乏公开数据集，深度学习需要大量样本数据进行支撑，建设输电线路巡检影像公开数据集可以极大地促进深度学习技术落地。由于目标之间的差异性、算法的多样性，电力设备识别及缺陷检测还缺乏统一的评价标准，亟需建立一个输电线路巡检系统性能评价标准。

4) 小目标多级检测。在无人机输电线路巡检中，小部件缺陷类似于细小金具、均压环、防振锤等占据了 50% 以上。目标检测、图像分类和语义分割算法相结合，利用先验知识、联合特征、上下

文信息等构成物体检测器，通过对限制目标进行逐级检测与分割，多级层次化检测策略将是小目标缺陷检测的有效解决方案。

5) 多层特征融合。在深度学习网络框架下，较多的纹理、形状特征利用浅层卷积提取特征，较高的语义特征利用深层卷积提取特征，随着深度学习网络层数的加深，检测目标纹理、形状信息弱化，相应语义信息不断增强，引入特征金字塔结构进行多尺度特征深度融合，加强检测目标特征提取能力。

6) 多源图像数据融合。采用传统图像处理方法对图像进行增强处理(如图像灰度化、滤波、直方图均衡化以及图像分割等)可以有效避免采集到的航拍图像退化问题。另外将可见光图像、热图像、紫外线图像、激光雷达图像进行多源数据融合可以有效扩展电力设备检测的应用范围，实现不同应用场景下的电力设备目标识别及状态检测。

7) 多种学习方法深度融合。鉴于数据集中样本数量有限，采用一小部分样本数据在训练好的模型上训练，通过将深度学习与迁移学习、弱监督学习、强化学习等深度融合实现不同学习技术的优势互补。深度学习与多种机器学习技术不断融合发展将是未来深度学习在输电线路巡检中应用的研究重点。

5 结论

输电线路作为电力传输的纽带，其在电力系统输配电过程中发挥着重要作用，确保线路电力设备安全是重要的巡检任务，快速、准确地实现巡检航拍图像中电力设备识别及缺陷检测具有重要研究意义。随着深度学习技术发展，基于深度神经网络的输电线路电力设备识别及缺陷检测得到广泛关注，越来越多的研究者致力于巡检图像中电力设备目标检测的研究工作，同时也推动输电线路巡检向自动化、智能化方向创新和进步。

本文以无人机为巡检工具，以可见光航拍图像为数据源，以深度学习算法为主要实现方法，综述了近十年来基于深度学习的输电线路巡检图像检测方法的研究进展。首先概述了深度神经网络，阐明了两类(one-stage 和 two-stage)深度学习算法；然后阐述了深度神经网络在电力线识别、绝缘子及缺陷检测、电力杆塔及附属设施检测、金具及缺陷检测、输电走廊在线监测、多类电力设备识别与分类等应用；最后阐明了基于深度学习的输电线路巡检

图像视觉检测方法在数据集、类别不平衡、小目标检测等方面面临挑战,给出了小样本学习方法、样本图像合成、小目标多级检测、多层特征融合、多源图像数据融合、多种学习方法深度融合等应对措施,YOLO、SSD等 one-stage 算法比 Faster R-CNN 等 two-stage 算法更适用于输电线路目标识别及缺陷检测,多种深度学习网络模型融合有利于提高小目标的检测精度;指明了深度学习与迁移学习、强化学习、弱监督学习等深度融合是今后输电线路巡检图像视觉检测方法的重要研究方向之一,如何将目标检测、语义分割、实例分割算法部署到嵌入式设备上实施输电线路设备在线检测,以及探索在雾天等恶劣天气条件下进行电力设备目标识别及缺陷检测具有重要意义,这将极大地推动深度学习在输电线路巡检乃至整个智能电网中应用。

参考文献

- [1] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. 中国电机工程学报, 2020, 40(17): 5506-5515.
HE Jinghan, LUO Guomin, CHENG Xiaomeng, et al. A research review on application of artificial intelligence in power system fault analysis and location[J]. Proceedings of the CSEE, 2020, 40(17): 5506-5515(in Chinese).
- [2] 陆佳政, 周特军, 吴传平, 等. 某省级电网 220kV 及以上输电线路故障统计与分析[J]. 高电压技术, 2016, 42(1): 200-207.
LU Jiazheng, ZHOU Tejun, WU Chuanping, et al. Fault statistics and analysis of 220 kV and above power transmission line in province-level power grid[J]. High Voltage Engineering, 2016, 42(1): 200-207(in Chinese).
- [3] 胡伟, 郑乐, 闵勇, 等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. 电网技术, 2017, 41(10): 3140-3146.
HU Wei, ZHENG Le, MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. Power System Technology, 2017, 41(10): 3140-3146(in Chinese).
- [4] 康忠健, 李昌超, 于洪国, 等. 一种识别电力系统关键输电线路的方法[J]. 电力自动化设备, 2020, 40(4): 63-70.
KANG Zhongjian, LI Changchao, YU Hongguo, et al. Identification method of key transmission lines in power system[J]. Electric Power Automation Equipment, 2020, 40(4): 63-70(in Chinese).
- [5] 陈驰, 彭向阳, 宋爽, 等. 大型无人机电力巡检 LiDAR 点云安全距离诊断方法[J]. 电网技术, 2017, 41(8): 2723-2730.
CHEN Chi, PENG Xiangyang, SONG Shuang, et al. Safety distance diagnosis of large scale transmission line corridor inspection based on LiDAR point cloud collected with UAV[J]. Power System Technology, 2017, 41(8): 2723-2730(in Chinese).
- [6] 王淼, 杜伟, 孙鸿博, 等. 基于红外图像识别的输电线路故障诊断方法[J]. 红外技术, 2017, 39(4): 383-386.
WANG Miao, DU Wei, SUN Hongbo, et al. Transmission line fault diagnosis method based on infrared image recognition[J]. Infrared Technology, 2017, 39(4): 383-386(in Chinese).
- [7] 李振宇, 郭锐, 赖秋频, 等. 基于计算机视觉的架空输电线路机器人巡检技术综述[J]. 中国电力, 2018, 51(11): 139-146.
LI Zhenyu, GUO Rui, LAI Qiupin, et al. Survey of inspection technology of overhead transmission line robot based on computer vision[J]. Electric Power, 2018, 51(11): 139-146(in Chinese).
- [8] 全卫国, 苑津莎, 李宝树. 图像处理技术在直升机巡检输电线路中的应用综述[J]. 电网技术, 2010, 34(12): 204-208.
TONG Weiguo, YUAN Jinsha, LI Baoshu. Application of image processing in patrol inspection of overhead transmission line by helicopter[J]. Power System Technology, 2010, 34(12): 204-208(in Chinese).
- [9] MATIKAINEN L, LEHTOMÄKI M, AHOKAS E, et al. Remote sensing methods for power line corridor surveys[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119: 10-31.
- [10] LI Yincheng, ZHANG Wenbin, LI Peng, et al. A method for autonomous navigation and positioning of UAV based on electric field array detection[J]. Sensors, 2021, 21(4): 1146.
- [11] 郝帅, 杨磊, 马旭, 等. 基于注意力机制与跨尺度特征融合的 YOLOv5 输电线路故障检测[J]. 中国电机工程学报, 2023: 43(6): 2319-2331.
HAO Shuai, YANG Lei, MA Xu, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion[J]. Proceedings of the CSEE, 2023: 43(6): 2319-2331(in Chinese).
- [12] MA Yunpeng, LI Qingwu, CHU Lulu, et al. Real-time detection and spatial localization of insulators for UAV inspection based on binocular stereo vision[J]. Remote Sensing, 2021, 13(2): 230.
- [13] HUI Xiaolong, BIAN Jiang, YU Yongjia, et al. A novel autonomous navigation approach for UAV power line inspection[C]//2017 IEEE International Conference on Robotics and Biomimetics(ROBIO), Macau, China: IEEE, 2017.

- [14] SAMPEDRO C, MARTINEZ C, CHAUHAN A, et al. A supervised approach to electric tower detection and classification for power line inspection[C]//2014 International Joint Conference on Neural Networks. Beijing: IEEE, 2014: 1970-1977.
- [15] NGUYEN V N, JENSSEN R, ROVERSO D. Intelligent monitoring and inspection of power line components powered by UAVs and deep learning[J]. IEEE Power and Energy Technology Systems Journal, 2019, 6(1): 11-21.
- [16] LIU Xinyu, MIAO Xiren, JIANG Hao, et al. Data analysis in visual power line inspection: an in-depth review of deep learning for component detection and fault diagnosis[J]. Annual Reviews in Control, 2020, 50: 253-277.
- [17] 吴雪, 宋晓茹, 高嵩, 等. 基于深度学习的目标检测算法综述[J]. 传感器与微系统, 2021, 40(2): 4-7, 18. WU Xue, SONG Xiaoru, GAO Song, et al. Review of target detection algorithms based on deep learning[J]. Transducer and Microsystem Technologies, 2021, 40(2): 4-7, 18(in Chinese).
- [18] 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(in Chinese).
- [19] ZHAI Yongjie, WANG Di, ZHANG Muli, et al. Fault detection of insulator based on saliency and adaptive morphology[J]. Multimedia Tools and Applications, 2017, 76(9): 12051-12064.
- [20] ZHAO Zhenbing, LIU Ning, WANG Le. Localization of multiple insulators by orientation angle detection and binary shape prior knowledge[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(6): 3421-3428.
- [21] WU Qinggang, AN Jubai, LIN Bin. A texture segmentation algorithm based on PCA and global minimization active contour model for aerial insulator images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(5): 1509-1518.
- [22] WANG Wanguo, WANG Yufu, HAN Jun, et al. Recognition and drop-off detection of insulator based on aerial image[C]//2016 9th International Symposium on Computational Intelligence and Design. Hangzhou: IEEE, 2017: 162-167.
- [23] LIAO Shenglong, AN Jubai. A robust insulator detection algorithm based on local features and spatial orders for aerial images[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(5): 963-967.
- [24] 侯一民, 邸建铭. 改进的尺度不变特征转换精确图像匹配在电力设备目标定位中的应用[J]. 中国电机工程学报, 2012, 32(19): 134-139.
- HOU Yimin, DI Jianming. Application of improved scale invariant feature transform accurate image matching in target positioning of electric power equipment[J]. Proceedings of the CSEE, 2012, 32(19): 134-139(in Chinese).
- [25] ZHAI Yongjie, CHEN Rui, YANG Qiang, et al. Insulator fault detection based on spatial morphological features of aerial images[J]. IEEE Access, 2018, 6: 35316-35326.
- [26] TONG Kang, WU Yiquan, ZHOU Fei. Recent advances in small object detection based on deep learning: A review[J]. Image and Vision Computing, 2020, 97: 103910.
- [27] 薛明华, 艾春美, 律慧瑾, 等. 电厂安全帽佩戴安全性监控的智能图像处理方法[J]. 中国电机工程学报, 2022, 42(9): 3346-3354. XUE Minghua, AI Chunmei, LV Huijin, et al. Intelligent image processing technology for safety helmet wearing in power plant[J]. Proceedings of the CSEE, 2022, 42(9): 3346-3354(in Chinese).
- [28] 吕品, 李凯, 许嘉, 等. 无人驾驶汽车协同感知信息传输负载优化技术[J]. 计算机学报, 2021, 44(10): 1984-1997. LV Pin, LI Kai, XU Jia, et al. Cooperative sensing information transmission load optimization for automated vehicles[J]. Chinese Journal of Computers, 2021, 44(10): 1984-1997(in Chinese).
- [29] 刘志颖, 缪希仁, 陈静, 等. 电力架空线路巡检可见光图像智能处理研究综述[J]. 电网技术, 2020, 44(3): 1057-1069. LIU Zhiying, MIAO Xiren, CHEN Jing, et al. Review of visible image intelligent processing for transmission line inspection[J]. Power System Technology, 2020, 44(3): 1057-1069(in Chinese).
- [30] 刘云鹏, 许自强, 李刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348. LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348(in Chinese).
- [31] NGUYEN V N, JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: A review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107-120.
- [32] 张宇航, 邱才明, 杨帆, 等. 深度学习在电网图像数据及时空数据中的应用综述[J]. 电网技术, 2019, 43(6):

- 1865-1873.
ZHANG Yuhang, QIU caiming, YANG Fan, et al. Overview of application of deep learning with image data and spatio-temporal data of power grid[J]. Power System Technology, 2019, 43(6): 1865-1873(in Chinese).
- [33] YANG Lei, FAN Junfeng, LIU Yanhong, et al. A review on state-of-the-art power line inspection techniques[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9350-9365.
- [34] 周俊煌, 黄廷城, 谢小瑜, 等. 视频图像智能识别技术在输变电系统中的应用研究综述[J]. 中国电力, 2021, 54(1): 124-134, 166.
ZHOU Junhuang, HUANG Tingcheng, XIE Xiaoyu, et al. Review of application research of video image intelligent recognition technology in power transmission and distribution systems[J]. Electric Power, 2021, 54(1): 124-134, 166(in Chinese).
- [35] 赵振兵, 蒋志钢, 李延旭, 等. 输电线路部件视觉缺陷检测综述[J]. 中国图象图形学报, 2021, 26(11): 2545-2560.
ZHAO Zhenbing, JIANG Zhigang, LI Yanxu, et al. Overview of visual defect detection of transmission line components[J]. Journal of Image and Graphics, 2021, 26(11): 2545-2560(in Chinese).
- [36] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [37] SZEGEDY C, TOSHEV A, ERHAN D. Deep neural networks for object detection[C]//Proceedings of the 26th International Conference on Neural Information Processing Systems. Lake Tahoe: Curran Associates Inc., 2013: 2553-2561.
- [38] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]//13th European Conference on Computer Vision(CVPR). Cham: Springer, 2014: 818-833.
- [39] CHATFIELD K, SIMONYAN K, VEDALDI A, et al. Return of the devil in the details: delving deep into convolutional nets[C]//Proceedings British Machine Vision Conference. Nottingham: BMVA Press, 2014: 1-41.
- [40] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston: IEEE, 2015.
- [41] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas: IEEE, 2016: 770-778.
- [42] 邱志斌, 石大寨, 况燕军, 等. 基于深度迁移学习的输电线路涉鸟故障危害鸟种图像识别[J]. 高电压技术, 2021, 47(11): 3785-3794.
QIU Zhibin, SHI Dazhai, KUANG Yanjun, et al. Image recognition of harmful bird species related to transmission line outages based on deep transfer learning[J]. High Voltage Engineering, 2021, 47(11): 3785-3794(in Chinese).
- [43] 赵振兵, 张薇, 戚银城, 等. 融合深度特征的输电线路金具缺陷因果分类方法[J]. 北京航空航天大学学报, 2021, 47(3): 461-468.
ZHAO Zhenbing, ZHANG Wei, QI Yincheng, et al. Causal classification method of transmission lines fitting defect combined with deep features[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(3): 461-468(in Chinese).
- [44] 汪然然, 娄联堂. 基于图像分析和深度学习的复合绝缘子憎水性分级[J]. 武汉工程大学学报, 2021, 43(5): 580-585.
WANG Ranran, LOU Liantang. Hydrophobicity classification of composite insulators based on image analysis and deep learning[J]. Journal of Wuhan Institute of Technology, 2021, 43(5): 580-585(in Chinese).
- [45] 徐凯, 梁志坚, 张懿议, 等. 基于 GoogLeNet Inception-V3 模型的电力设备图像识别[J]. 高压电器, 2020, 56(9): 129-135, 143.
XU Kai, LIANG Zhijian, ZHANG Yiyi, et al. Image recognition of electric equipment based on GoogLeNet Inception-V3 model[J]. High Voltage Apparatus, 2020, 56(9): 129-135, 143(in Chinese).
- [46] 张焯, 高玉菡, 黄新波, 等. 基于 Fine Mask RCNN 的 110~220kV 输电铁塔涉鸟故障识别与评估[J]. 电网技术, 2022, 46(6): 2132-2144.
ZHANG Ye, GAO Yuhuan, HUANG Xinbo, et al. Fault identification and evaluation of tower wading in 110~220kV transmission line with Fine Mask RCNN[J]. Power System Technology, 2022, 46(6): 2132-2144(in Chinese).
- [47] 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 Xin, LIU Shuainan, YANG Zhen, 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(in Chinese).
- [48] 李飞, 王超, 浦东, 等. 基于卷积注意力的输电线路防震锤检测识别[J]. 计算机测量与控制, 2022, 30(3): 48-53, 105.
LI Fei, WANG Chao, PU Dong, et al. Convolutional attention mechanism based object detection method for vibration damper[J]. Computer Measurement & Control,

- 2022, 30(3): 48-53, 105(in Chinese).
- [49] XIE Saining, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu: IEEE, 2017.
- [50] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco, USA: AAAI Press, 2017: 4278-4284.
- [51] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu: IEEE, 2017.
- [52] GAO Shanghua, CHENG Mingming, ZHAO Kai, et al. Res2Net: A new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(2): 652-662.
- [53] ZHANG Hang, WU Chongruo, ZHANG Zhongyue, et al. ResNeSt: split-attention networks[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops(CVPRW). New Orleans: IEEE, 2020.
- [54] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE, 2014: 580-587.
- [55] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 37(9): 1904-1916.
- [56] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision(ICCV). Santiago, Chile: IEEE, 2015: 1440-1448.
- [57] REN Shaoqing, HE Kaiming, 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, 2017, 39(6): 1137-1149.
- [58] DAI Jifeng, LI Yi, HE Kaiming, et al. R-FCN: object detection via region-based fully convolutional networks [C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2016.
- [59] LIU Xinyu, JIANG Hao, CHEN Jing, et al. Insulator detection in aerial images based on faster regions with convolutional neural network[C]//2018 IEEE 14th International Conference on Control and Automation (ICCA). Anchorage: IEEE, 2018.
- [60] ZHAO Zhenbing, ZHEN Zhen, ZHANG Lei, et al. Insulator detection method in inspection image based on improved faster R-CNN[J]. Energies, 2019, 12(7): 1204.
- [61] LIANG Huagang, ZUO Chao, WEI Wangmin. Detection and evaluation method of transmission line defects based on deep learning[J]. IEEE Access, 2020, 8: 38448-38458.
- [62] FAN P, SHEN H M, ZHAO C, et al. Defect identification detection research for insulator of transmission lines based on deep learning[J]. Journal of Physics: Conference Series, 2021, 1828(1): 012019.
- [63] LI Shanjun, ZHOU Haomiao, WANG Guoyou, et al. Cracked insulator detection based on R-FCN[J]. Journal of Physics Conference Series, 2018, 1069: 012147.
- [64] YANG Yanli, WANG Ying, JIAO Hongyan. Insulator identification and self-shattering detection based on mask region with convolutional neural network[J]. Journal of Electronic Imaging, 2019, 28(5): 053011.
- [65] GAO Feng, WANG Jiao, KONG Z Zhizhan, et al. Recognition of insulator explosion based on deep learning [C]//2017 14th International Computer Conference on Wavelet Active Media Technology and Information Processing(ICCWAMTIP). Chengdu: IEEE, 2017.
- [66] LI Xuefeng, SU Hansong, LIU Gaohua. Insulator defect recognition based on global detection and local segmentation[J]. IEEE Access, 2020, 8: 59934-59946.
- [67] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6517-6525.
- [68] REDMON J, FARHADI A. YOLOv3: an incremental improvement[Z]. arXiv: 1804.02767, 2018.
- [69] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[Z]. arXiv: 2004.10934, 2020.
- [70] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//14th European Conference on Computer Vision(ECCV). Cham: Springer, 2016.
- [71] HAN Jiaming, YANG Zhong, ZHANG Qiuyan, et al. A method of insulator faults detection in aerial images for high-voltage transmission lines inspection[J]. Applied Sciences, 2019, 9(10): 2009.
- [72] HAN Jiaming, YANG Zhong, XU Hao, et al. Search like an eagle: a cascaded model for insulator missing faults detection in aerial images[J]. Energies, 2020, 13(3): 713.
- [73] XU Changfu, BO Bin, LIU Yang, et al. Detection method of insulator based on single shot MultiBox detector[J]. Journal of Physics: Conference Series, 2018, 1069(1): 012183.
- [74] TAN Jicheng. Automatic insulator detection for power line using aerial images powered by convolutional neural

- networks[J]. *Journal of Physics: Conference Series*, 2021, 1748(4): 042012.
- [75] 罗会兰, 陈鸿坤. 基于深度学习的目标检测研究综述[J]. *电子学报*, 2020, 48(6): 1230-1239.
- LUO Huilan, CHEN Hongkun. Survey of object detection based on deep learning[J]. *Acta Electronica Sinica*, 2020, 48(6): 1230-1239(in Chinese).
- [76] LAW H, DENG Jia. CornerNet: detecting objects as paired keypoints[J]. *International Journal of Computer Vision*, 2020, 128(3): 642-656.
- [77] DUAN Kaiwen, BAI Song, XIE Lingxi, et al. CenterNet: keypoint triplets for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 6568-6577.
- [78] 赵锐, 赵国伟, 张娟, 等. 改进 CenterNet 的高压输电线路巡检故障实时检测方法[J]. *计算机工程与应用*, 2021, 57(17): 246-252.
- ZHAO Rui, ZHAO Guowei, ZHANG Juan, et al. A real-time fault detection method for high voltage transmission line based on CenterNet improved algorithm [J]. *Computer Engineering and Applications*, 2021, 57(17): 246-252(in Chinese).
- [79] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4): 640-651.
- [80] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [81] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 2015.
- [82] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [83] 李胜利. 基于 FCN 的航拍输电线路关键部件语义分割方法研究[D]. 北京: 华北电力大学, 2018.
- LI Shengli. Research on semantic segmentation method of key components of aerial transmission line based on FCN[D]. Beijing: North China Electric Power University, 2018(in Chinese).
- [84] 王彤, 朱凌, 范亚洲, 等. 基于改进 U-net 语义分割遥感影像的线路走廊隐患检测方法[J]. *南方电网技术*, 2019, 13(8): 67-73.
- WANG Tong, ZHU Ling, FAN Yazhou, et al. Hidden danger detection method of line corridor in remote sensing image based on improved U-net semantics segmentation [J]. *Southern Power System Technology*, 2019, 13(8): 67-73(in Chinese).
- [85] 黄巨挺, 高宏力, 戴志坤. 基于编码解码结构的移动端电力线语义分割方法[J]. *计算机应用*, 2021, 41(10): 2952-2958.
- HUANG Juting, GAO Hongli, DAI Zhikun. Semantic segmentation method of power line on mobile terminals based on encoder-decoder structure[J]. *Journal of Computer Applications*, 2021, 41(10): 2952-2958(in Chinese).
- [86] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[C]//3rd International Conference on Learning Representations. San Diego: ICLR, 2014: 357-361.
- [87] 王翔文. 基于图像的输电线路语义分割技术研究[D]. 杭州: 浙江大学, 2019.
- WANG Xuwen. Research on semantic segmentation of power line based on image[D]. Hangzhou: Zhejiang University, 2019(in Chinese).
- [88] 李冰, 王天, 杨珂, 等. 基于改进 Mask R-CNN 的变电设备红外图像实例分割算法[J]. *华北电力大学学报: 自然科学版*, 2023, 50(2): 91-99.
- LI Bing, WANG Tian, YANG Ke, et al. Instance segmentation algorithm for substation equipment infrared images based on improved mask R-CNN[J]. *Journal of North China Electric Power University: Natural Science Edition*, 2023, 50(2): 91-99(in Chinese).
- [89] IANDOLA F N, HAN Song, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size[Z]. arXiv: 1602.07360, 2016.
- [90] HOWARD A G, ZHU Menglong, CHEN Bo, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[Z]. arXiv: 1704.04861, 2017.
- [91] ZHANG Xiangyu, ZHOU Xinyu, LIN Minyu, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018.
- [92] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017.
- [93] 王继霄, 李阳, 王家宝, 等. 基于 SqueezeNet 的轻量级图像融合方法[J]. *计算机应用*, 2020, 40(3): 837-841.
- WANG Jixiao, LI Yang, WANG Jiabao, et al. Light-

- weight image fusion method based on SqueezeNet[J]. *Journal of Computer Applications*, 2020, 40(3): 837-841(in Chinese).
- [94] GHOLAMI A, KWON K, WU Bichen, et al. SqueezeNext: hardware-aware neural network design[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City: IEEE, 2018: 1719-1728.
- [95] 任宇杰, 杨剑, 刘方涛, 等. 基于 SSD 和 MobileNet 网络的目标检测方法的研究[J]. *计算机科学与探索*, 2019, 13(11): 1881-1893.
- REN Yujie, YANG Jian, LIU Fangtao, et al. Research on target detection method based on SSD and MobileNet network[J]. *Journal of Frontiers of Computer Science and Technology*, 2019, 13(11): 1881-1893(in Chinese).
- [96] 马富齐, 王波, 董旭柱, 等. 面向输电线路覆冰厚度辨识的多感受野视觉边缘智能识别方法研究[J]. *电网技术*, 2021, 45(6): 2161-2169.
- MA Fuqi, WANG Bo, DONG Xuzhu, et al. Receptive field vision edge intelligent recognition for ice thickness identification of transmission line[J]. *Power System Technology*, 2021, 45(6): 2161-2169(in Chinese).
- [97] MA Ningning, ZHANG Xiangyu, ZHANG Haitao, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design[C]//15th European Conference on Computer Vision. Cham: Springer, 2018: 122-138.
- [98] 张宝朋, 康谦泽, 李佳萌, 等. 轻量化改进的 YOLOv4 目标检测算法[J]. *计算机工程*, 2022, 48(8): 206-214.
- ZHANG Baopeng, KANG Qianze, LI Jiameng, et al. Lightweight improved yolov4 target detection algorithm [J]. *Computer Engineering*, 2022, 48(8): 206-214(in Chinese).
- [99] 邱云飞, 温金燕. 基于 DeepLabV3+与注意力机制相结合的图像语义分割[J]. *激光与光电子学进展*, 2022, 59(4): 0410008.
- QIU Yunfei, WEN Jinyan. Image semantic segmentation based on combination of DeepLabV3+ and attention mechanism [J]. *Laser & Optoelectronics Progress*, 2022, 59(4): 0410008(in Chinese).
- [100] 赵乐, 王先培, 姚鸿泰, 等. 基于可见光航拍图像的电力线提取算法综述[J]. *电网技术*, 2021, 45(4): 1536-1546.
- ZHAO Le, WANG Xianpei, YAO Hongtai, et al. Survey of power line extraction methods based on visible light aerial image[J]. *Power System Technology*, 2021, 45(4): 1536-1546(in Chinese).
- [101] YETGIN Ö E, BENLIGIRAY B, GEREK Ö N. Power line recognition from aerial images with deep learning [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2019, 55(5): 2241-2252.
- [102] NGUYEN V N, JENSSEN R, ROVERSO D. LS-Net: fast single-shot line-segment detector[J]. *Machine Vision and Applications*, 2021, 32(1): 12.
- [103] 陈梅林, 王逸舟, 戴彦, 等. SaSnet: 基于自监督学习的电力线实时分割网络[J]. *中国电机工程学报*, 2022, 42(4): 1365-1374.
- CHEN Meilin, WANG Yizhou, DAI Yan, et al. Small and strong: power line segmentation network in real time based on self-supervised learning[J]. *Proceedings of the CSEE*, 2022, 42(4): 1365-1374(in Chinese).
- [104] WANG Shuqing, LIU Yifan, QING Yihui, et al. Detection of insulator defects with improved ResNeSt and region proposal network[J]. *IEEE Access*, 2020, 8: 184841-184850.
- [105] JIANG Hao, QIU Xiaojie, CHEN Jing, et al. Insulator fault detection in aerial images based on ensemble learning with multi-level perception[J]. *IEEE Access*, 2019, PP(99): 61797-61810.
- [106] 李彩林, 张青华, 陈文贺, 等. 基于深度学习的绝缘子定向识别算法[J]. *电子与信息学报*, 2020, 42(4): 1033-1040.
- LI Cailin, ZHANG Qinghua, CHEN Wenhe, et al. Insulator orientation detection based on deep learning[J]. *Journal of Electronics & Information Technology*, 2020, 42(4): 1033-1040(in Chinese).
- [107] LIU Chuanyang, WU Yiquan, LIU Jingjing, et al. Improved YOLOv3 network for insulator detection in aerial images with diverse background interference[J]. *Electronics*, 2021, 10(7): 771.
- [108] 刘欣宇, 缪希仁, 庄胜斌, 等. 基于轻量级深度卷积神经网络的绝缘子检测[J]. *福州大学学报: 自然科学版*, 2021, 49(2): 196-202.
- LIU Xinyu, MIAO Xiren, ZHUANG Shengbin, et al. Insulator detection based on lightweight deep convolutional neural network[J]. *Journal of Fuzhou University: Natural Science Edition*, 2021, 49(2): 196-202(in Chinese).
- [109] TAO Xian, ZHANG Dapeng, WANG Zihao, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(4): 1486-1498.
- [110] LING Zenan, ZHANG Dongxia, QIU R C, et al. An accurate and real-time method of self-blast glass insulator location based on faster R-CNN and U-net with aerial images[J]. *Csee Journal of Power and Energy Systems*, 2019, 5(4): 474-482.
- [111] CHEN Jingwen, XU Xin, DANG Hongshe. Fault detection of insulators using second-order fully convolutional network model[J]. *Mathematical Problems*

- in Engineering, 2019, 2019: 6397905.
- [112] 林志成, 缪希仁, 江灏, 等. 多模型融合的输电线路绝缘子自爆故障检测[J]. 福州大学学报: 自然科学版, 2020, 48(2): 217-223.
LIN Zhicheng, MIAO Xiren, JIANG Hao, et al. Multi-model fusion of transmission line insulator self-explosion fault detection[J]. Journal of Fuzhou University: Natural Science Edition, 2020, 48(2): 217-223(in Chinese).
- [113] SHI Chunxue, HUANG Yaping. Cap-count guided weakly supervised insulator cap missing detection in aerial images[J]. IEEE Sensors Journal, 2021, 21(1): 685-691.
- [114] 王道累, 孙嘉璐, 张天宇, 等. 基于改进生成对抗网络的玻璃绝缘子自爆缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1096-1103.
WANG Daolei, SUN Jiajun, ZHANG Tianyu, et al. Self-explosion defect detection method of glass insulator based on improved Generative Adversarial Network[J]. High Voltage Engineering, 2022, 48(3): 1096-1103(in Chinese).
- [115] BIAN Jiang, HUI Xiaolong, ZHAO Xiaogaung, et al. A monocular vision-based perception approach for unmanned aerial vehicle close proximity transmission tower inspection[J]. International Journal of Advanced Robotic Systems, 2019, 16(1).
- [116] 郭敬东, 陈彬, 王仁书, 等. 基于YOLO的无人机电力线路杆塔巡检图像实时检测[J]. 中国电力, 2019, 52(7): 17-23.
GUO Jingdong, CHEN Bin, WANG Renshu, et al. YOLO-based real-time detection of power line poles from unmanned aerial vehicle inspection vision[J]. Electric Power, 2019, 52(7): 17-23(in Chinese).
- [117] HOSSEINI M M, UMUNNAKWE A, PARVANIA M, et al. Intelligent damage classification and estimation in power distribution poles using unmanned aerial vehicles and convolutional neural networks[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3325-3333.
- [118] 缪希仁, 林志成, 江灏, 等. 基于深度卷积神经网络的输电线路防鸟刺部件识别与故障检测[J]. 电网技术, 2021, 45(1): 126-133.
MIAO Xiren, LIN Zhicheng, JIANG Hao, et al. Fault detection of power tower anti-bird spurs based on deep convolutional neural network[J]. Power System Technology, 2021, 45(1): 126-133(in Chinese).
- [119] 王万国, 田兵, 刘越, 等. 基于RCNN的无人机巡检图像电力小部件识别研究[J]. 地球信息科学学报, 2017, 19(2): 256-263.
WANG Wanguo, TIAN Bing, LIU Yue, et al. Study on the electrical devices detection in UAV images based on region based convolutional neural networks[J]. Journal of Geo-information Science, 2017, 19(2): 256-263(in Chinese).
- [120] WANG Jiwu, ZHANG Xinying, ZHENG Lele, et al. A study on the grading ring recognition method of power line based on deep learning[C]//2018 International Conference on Information and Communication Technology Robotics(ICT-ROBOT). Busan: IEEE, 2018.
- [121] 罗玉鹤, 庞红旗, 高飞翔, 等. 电力巡检图像中防振锤的区域全卷积网络识别方法[J]. 福州大学学报: 自然科学版, 2020, 48(6): 714-719.
LUO Yuhe, PANG Hongqi, GAO Feiling, et al. Identification method of region based fully convolution networks for damper in power inspection image[J]. Journal of Fuzhou University: Natural Science Edition, 2020, 48(6): 714-719(in Chinese).
- [122] 李雪峰, 刘海莹, 刘高华, 等. 基于深度学习的输电线路销钉缺陷检测[J]. 电网技术, 2021, 45(8): 2988-2995.
LI Xuefeng, LIU Haiying, LIU Gaohua, et al. Transmission line pin defect detection based on deep learning[J]. Power System Technology, 2021, 45(8): 2988-2995(in Chinese).
- [123] WANG Bixiao, WU Runze, ZHENG Zhe, et al. Study on the method of transmission line foreign body detection based on deep learning[C]//2017 IEEE Conference on Energy Internet and Energy System Integration. Beijing: IEEE, 2017.
- [124] XIANG Xuezhi, LV Ning, GUO Xinli, et al. Engineering vehicles detection based on modified Faster R-CNN for power grid surveillance[J]. Sensors, 2018, 18(7): 2258.
- [125] ZHU Jinguo, GUO Yue, YUE Fanding, et al. A deep learning method to detect foreign objects for inspecting power transmission lines[J]. IEEE Access, 2020, 8: 94065-94075.
- [126] 李军锋, 王钦若, 李敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
LI Junfeng, WANG Qinruo, LI Min. Electric equipment image recognition based on deep learning and random forest[J]. High Voltage Engineering, 2017, 43(11): 3705-3711(in Chinese).
- [127] WANG Yun, GAO Hongli, LIU Yuekai, et al. Obstacle detection for power transmission line based on deep learning[C]//2019 Prognostics and System Health Management Conference. Qingdao: IEEE, 2019.
- [128] 董召杰. 基于YOLOv3的电力线关键部件实时检测[J]. 电子测量技术, 2019, 42(23): 173-178.
DONG Zhaojie. Real-time detection of power transmission line key components based on YOLOv3[J].

- Electronic Measurement Technology, 2019, 42(23): 173-178(in Chinese).
- [129] 刘思言, 王博, 高昆仑, 等. 基于 R-FCN 的航拍巡检图像目标检测方法[J]. 电力系统自动化, 2019, 43(13): 162-168.
- LIU Siyan, WANG Bo, GAO Kunlun, et al. Object detection method for aerial inspection image based on region-based fully convolutional network[J]. Automation of Electric Power Systems, 2019, 43(13): 162-168(in Chinese).
- [130] TOMASZEWSKI M, RUSZCZAK B, MICHALSKI P. The collection of images of an insulator taken outdoors in varying lighting conditions with additional laser spots[J]. Data in Brief, 2018, 18: 765-768.
- [131] ABDELFAHATTAH R, WANG Xiaofeng, WANG Song. TTPLA: an aerial-image dataset for detection and segmentation of transmission towers and power lines [C]//ACCV 2020: 15th Asian Conference on Computer Vision. Kyoto, Japan: Springer, 2020.
- [132] PRATES R M, CRUZ R, MAROTTA A P, et al. Insulator visual non-conformity detection in overhead power distribution lines using deep learning[J]. Computers & Electrical Engineering, 2019, 78: 343-355.
- [133] ZHANG Heng, YANG Wen, YU Huai, et al. Detecting power lines in UAV images with convolutional features and structured constraints[J]. Remote Sensing, 2019, 11(11): 1342.
- [134] HUANG J, RATHOD V, SUN Chen, et al. Speed/accuracy trade-offs for modern convolutional object detectors[C]//30th IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu: IEEE, 2017: 3296-3305.
- [135] 赵洪山, 彭轶灏, 刘秉聪, 等. 基于边缘注意力生成对抗网络的电力设备热成像超分辨率重建[J]. 中国电机工程学报, 2022, 42(10): 3564-3573.
- ZHAO Hongshan, PENG Yihao, LIU Bingcong, et al. Super-resolution reconstruction of electric equipment's thermal imaging based on generative adversarial network with edge-attention[J]. Proceedings of the CSEE, 2022, 42(10): 3564-3573(in Chinese).



刘传洋

在线出版日期: 2022-08-31。

收稿日期: 2022-05-04。

作者简介:

刘传洋(1982), 男, 博士研究生, 主要研究方向为图像处理与机器视觉、输电线路视觉检测与故障诊断, liuchuan yang608@nuaa.edu.cn;

*通信作者: 吴一全(1963), 男, 教授, 博士生导师, 主要研究方向为视觉检测与图像测量、图像处理与分析、红外目标检测与识别、视频处理与智能分析等, nuaaimage@163.com。

(编辑 乔宝榆, 李新洁)