

基于深度检测网络的配网工程动态缺陷检测进展

李运硕¹, 段祥骏¹, 李佳¹, 林奕夫², 任敬飞³, 杨婷⁴

(1. 中国电力科学研究院有限公司, 北京市海淀区 100192;

2. 国网福建省电力有限公司经济技术研究院, 福建省福州市 350001;

3. 国网山东省电力公司电力科学研究院, 山东省济南市 250002;

4. 南京工程学院电力工程学院, 江苏省南京市 211167)

Progress of Dynamic Defect Detection in Distribution Network Engineering Based on Deep Detection Network

LI Yunshuo¹, DUAN Xiangjun¹, LI Jia¹, LIN Yifu², REN Jingfei³, YANG Ting⁴

(1. China Electric Power Research Institute, Haidian District, Beijing 100192, China;

2. Economic and Technological Research Institute of State Grid Fujian Electric Power Co., Ltd., Fuzhou 350001, Fujian Province, China;

3. State Grid Shandong Electric Power Research Institute, Jinan 250002, Shandong Province, China;

4. Nanjing Institute of Technology, School of Electric Power Engineering, Nanjing 211167, Jiangsu Province, China)

摘要: 配网工程中大量的安全质量潜在缺陷给配网运行带来了极大的安全隐患。将深度检测网络应用于配网工程动态缺陷检测可加强配网工程管理、减少人工运维工作量, 达到提质增效的目的。文章首先对配网工程缺陷种类进行梳理分类; 然后, 针对典型深度检测网络及其在配网工程动态缺陷检测领域的应用现状开展深入研究, 并对现有研究成果进行详细综述; 再次, 总结深度检测网络应用于配网工程动态缺陷检测的关键问题及其解决方案。最后, 对该领域的研究方向进行展望, 期望为后续研究工作提供有益参考。

关键词: 深度检测网络; 配网工程动态缺陷; 目标检测; 机器视觉; 模型部署

ABSTRACT: A large number of potential safety and quality defects have brought great potential safety hazards to the operation of distribution network. Applying the deep detection network to the dynamic defect detection of distribution network engineering could strengthen the management, reduce the workload of manual operation, and achieve the purpose of improving quality and efficiency. Firstly, the types of defects of distribution network engineering are classified. Secondly, the advanced deep detection network and its application in the field of dynamic defect detection in distribution network engineering are researched and analyzed in-depth, and the existing research achievements are reviewed in detail. Then, the key issues and its solutions of deep detection network applied to dynamic defect detection of distribution network engineering are summarized. Finally, the research direction is prospected in order to provide a valuable reference for the follow-up research.

KEY WORDS: deep detection network; dynamic defect detection of distribution network engineering; target detection; machine vision; model deployment

0 引言

近年来, 深度检测网络在电网运行状态监测^[1]、电力系统故障自动判别^[2]、负荷预测^[3]、电力设备部件识别^[4]以及电力设备故障诊断^[5]中已有一些应用。目前, 针对基于深度检测网络的配网工程动态检测与告警技术研究大多局限于算法架构、人脸识别以

及安全帽简单标识物等检测, 缺少在配网工程质量安全领域的系统性研究和工程应用方面的论述^[6]。不论配电网新建或者改造工程, 均具有工期紧任务重、政府社会与用户关注度高等特点。尤其是随着配网新建与改造工程任务逐年增多, 配网工程呈现出点多面广、施工环境复杂等特点, 相关工程安全管理难度高、工作量大。基于深度检测网络的机器视觉识别是人工智能领域最重要、最活跃的领域之一^[7], 通过引入机器视觉等先进技术, 对配网

基金项目: 国家电网有限公司总部科技项目资助“基于机器视觉深度学习的配网工程强化管控技术研究”(5400-202116141A)。

施工过程中可能存在的隐患问题进行智能识别、异常检测以及提前预警^[8], 保证配网工程安全可控、顺利开展, 减少人工运维工作量, 提高现场管理效率, 辅助配网工程项目管理与安全建设质量管控, 达到配网工程建设安全、优质以及高效的目标。

文章首次将配网施工现场多种潜在隐患的智能分类与异常识别, 归纳为配网工程动态缺陷检测问题。首先从配网工程现场常见的安全质量问题出发, 对配网工程缺陷进行梳理分类; 然后, 立足于配网工程动态缺陷检测的技术需求, 系统论述基于深度检测网络的配网工程动态缺陷检测的技术路线; 其次, 从深度检测网络在目标检测领域的发展趋势出发, 回顾深度检测网络在配网工程缺陷检测中的应用现状和研究进展, 总结归纳配网工程缺陷检测所面临的挑战及其解决方案; 最后, 针对配网工程动态缺陷检测研究工作的研究方向进行讨论和展望, 期望为该领域快速工程化部署以及后续相关研究工作提供有价值的参考。

1 配网工程动态缺陷分类

配网工程动态缺陷是指在配网工程建设施工现场包含的大量的潜在隐患。这些隐患不仅包括人员组织或管理部分, 还包括施工过程中设备或部件安装不规范引起的实际施工与设计方案的差异。配网工程动态缺陷的分类维度并不唯一, 从质量与安全管理角度, 可将其分为质量缺陷与安全缺陷; 按照配网施工场景, 可将质量类缺陷进一步细分为站房类、配变类、电缆类以及架空线路类; 按照被检测目标类型可分为文本类、人员类、设备类以及工艺类。通过对配网大量工程现场多种缺陷进行梳理, 常见配网工程动态缺陷分级分类如表1所示, 其中, 质量缺陷关注配网电力设备或组件安装隐患, 而安全缺陷关注现场工作人员操作隐患。

以质量缺陷站房工程中的开关柜 (switch cabinet, SC) 安装缺陷为例, 进一步细分后的工程缺陷包括并不仅限于如设备命名标识不齐全 (文本类)、人员行为不规范 (人员类)、设备未接地 (设备类)、母排存在异物 (设备类)、电缆接头缺相序标识 (工艺类) 以及设备未封堵 (设备类) 等。配网工程缺陷细分种类多、范围广, 仅依靠人工现场核查存在易忽视、难发现的问题。且配网工程受外界环境干扰因素较多, 存在现场安全风险防控难、依靠人工监管难度大等突出问题, 为配网工程埋下安全质量隐患。

表1 配网工程动态缺陷分类

Table 1 Schematic diagram of dynamic defect classification of distribution network engineering

大类	细分	部件	缺陷细节
质量缺陷	站房工程	SC、IT、GCK等	标识是否齐全、设备是否封堵等
	配变工程	PMT、JP柜、EP电杆、OL、CA、IW等	设备是否封堵、安装是否规范等
	电缆工程	CB、CL、CHMJ、SS等	绝缘是否破裂、安装是否规范、标识是否齐全等
	架空线路	SW、SPP、Wire、LP等	安装是否规范、设备组件是否缺失、是否接地等
安全缺陷	安全防护	SD、SBS、SF、TM等	安全帽、工装、绝缘手套、安全绳以及安全带等是否正正常佩戴, 是否加装围栏等
	其他	Crane、梯子、抽烟、IS等	是否有人监护、是否严格禁烟等

2 配网工程动态缺陷检测技术概述

针对配网工程广泛存在的动态缺陷进行识别与检测, 需依托配网工程现场监控设备 (如无人机、智能巡检仪、视频监控以及移动拍摄设备等) 的分布式机器视觉, 通过部署先进深度检测网络对动态缺陷图像特征进行智能检测, 识别缺陷的类别与严重程度, 如图1所示。动态检测体现于3个方面: 配网施工现场视频数据为实时动态图像; 无人机等巡检设备处于动态监测状态中; 无人机、智能巡检仪以及本地视频监控设备等具备一定算力的边缘设备, 通过搭载轻量级检测算法可实时得到检测结果。

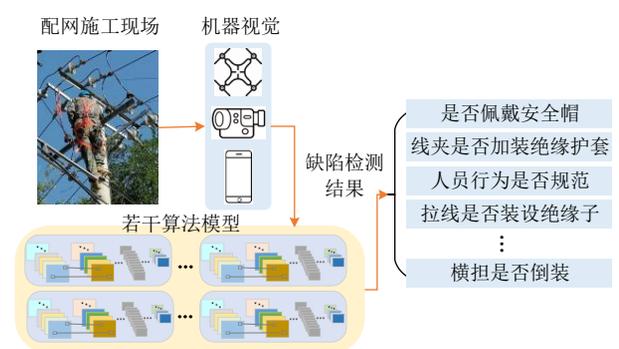


图1 配网工程动态缺陷检测

Fig. 1 Dynamic defect detection of distribution network engineering

配网工程动态缺陷的检测识别本质上可归纳为机器视觉中的图像识别与目标检测在配网工程特定场景中的应用, 其技术需求可归纳为快速、高效以及准确的识别不同类型配网工程动态缺陷, 该研究领域具有跨专业、多学科交叉融合的特点。其关键技术可归纳为: 广泛搜集配网施工工程动

态缺陷图像数据集，构建良好的标注样本库；通过技术提取动态缺陷图像特征并进行识别，研究提高图像识别精确度与异常检测准确率的算法与网络模型。

建立包含多种缺陷完备信息特征的配网工程动态缺陷样本模型库是实现配网工程动态缺陷智能检测与识别的前提条件，高质量与数据量丰富的图像样本不仅可以提高缺陷检测模型的泛化能力，还可以提高缺陷检测的识别精度。数据的来源可利用配网施工现场的视频监控设备或网络资源，通过广泛搜集多种类、多状态、多角度以及多时段的工程现场照片，完成图像样本的初步搜集。依据动态缺陷分类，对初步搜集的图像进行进一步细分，并针对缺陷特征确立差异化样本标注方案，建立样本库。

由于单个算法模型只能实现某种或某一类型的配网工程动态缺陷检测，因此需根据不同缺陷种类部署若干个深度检测网络模型。深度检测网络是机器学习中具有深层结构的神经网络模型，属于机器学习的子集。深度检测网络可被定义为基本网络框架中具有大量参数和层数的神经网络，包括卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)以及残差网络(residual network, ResNet)等^[9]。大量理论和实践均已证明，深度检测网络在机器视觉领域取得系列突破，涌现出一批表现优异的深度检测网络^[10]。典型目标检测深度CNN网络结构如图2所示，主要包括5层结构：输入层Input、卷积层Convolution、激活层(默认隐含在卷积层与池化层Max-Pool之间)、池化层、特征空间转换Dense层以及全连接层FC。

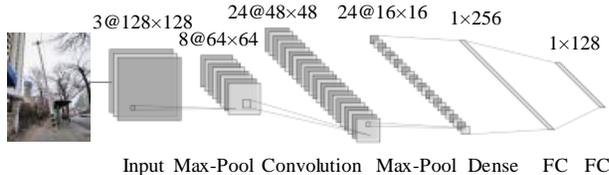


图2 目标检测网络示意

Fig. 2 Target detection network

配网工程动态缺陷检测技术实现的具体流程如图3所示。进一步地，可将动态缺陷样本模型库分为训练样本集与验证样本集，合理选择和部署主流深度检测网络进行训练。针对配网工程动态缺陷检测的特点与技术需求，对预选深度检测网络模型进行优化改进，通过缺陷检测与识别结果比较得到表现优异的算法模型，最终实现工程应用。

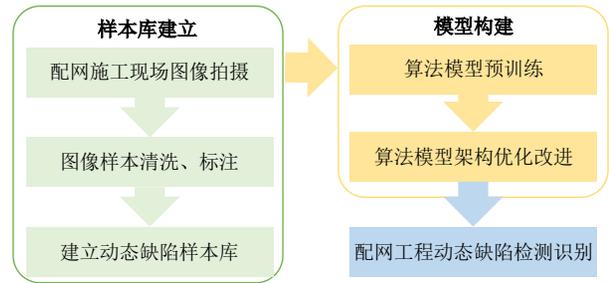


图3 配网工程动态缺陷检测实现流程

Fig. 3 Implementation process of dynamic defect detection in distribution network engineering

3 深度检测网络在配网缺陷检测中的应用现状

3.1 深度网络发展趋势概述

以深度网络为代表的机器学习领域近年来取得一些突破性的进展。但相对于在应用领域的成功，深度网络本身的理论基础却较为薄弱，尤其是随着网络不断加深，深度网络将面临更严峻的挑战^[9-10]，解决这些问题对推进配网工程动态缺陷检测技术细节研究与工程应用均具有较大的促进作用，主要包括：深度神经网络的损失函数大多为非凸函数，通常难以找到全局最优解；过参数化是深度神经网络的公认特性^[11]，该特性将导致高计算成本和高内存占用；深度神经网络需要大量的训练数据，因此无法使用计算代价很高的二阶优化方法(如K-FAC^[12])，而以SGD、AdaGrad^[13]等为代表的一阶方法的训练效率通常较低；深度神经网络存在梯度消失或爆炸问题，导致基于梯度的优化方法经常失效；过拟合问题，即由样本数量少、模型复杂度高以及过参数等导致的深度网络泛化能力差。

针对深度网络非凸优化问题，文献[14]分析随机超完全张量分解的优化问题，指出在非凸目标上梯度上升可有效解决该问题，首次将Kac-Rice公式和随机矩阵理论成功应用于求解深度网络的极小值；文献[15]在矩估计的框架下，采用谱算法避免CNN的复杂非凸优化问题。

针对深度网络退化问题，文献[16]首次提出深度ResNet，通过在视觉几何组(visual geometry group, VGG)网络的基础上引入残差单元，较好地解决由于网络深度增加而引起的梯度消失与爆炸的问题。

针对深度网络的过拟合问题，主要优化方案包括：提前截断，即在模型对数据集迭代收敛之前停止迭代防止过拟合；样本扩充，不断增加训练集数据，推动模型参数修正；正则化，在损失函数中适当的引入正则化项；Dropout操作，随机地使一部

分神经元失活，通过阻断部分神经元的系统作用，减轻神经元之间的联合适应性，从而降低过拟合风险，提高模型的泛化能力。

3.2 深度检测网络在目标检测中的应用

除深度网络领域本身所面临的挑战外，基于深度检测网络的图像识别与目标检测领域也面临着亟待解决的问题，这些问题同时制约着配网工程动态缺陷检测技术的快速发展，主要包括：复杂场景多目标检测识别、检测对象数目动态变化提高样本标注与建模复杂性；目标尺寸不平衡，针对不同尺寸目标的追踪效率不高；样本数量有限或者稀缺引起的小样本适应性差；特殊场景下需进一步考虑模型可解释性；难以平衡网络模型复杂度、检测实时性以及准确度。

深度检测网络的改进对提升图像分类与目标检测性能具有直接推动作用。近年来在目标检测算法模型的演进中涌现出一批具有代表性的检测器^[17]。文献[18]在R-CNN(Region-CNN)系列算法的基础上提出Faster R-CNN，采用神经网络生成候选检测框生成网络(region proposal networks, RPN)，从而实现端到端训练，大幅提高目标检测的训练速度。针对Faster R-CNN第一阶段的RPN进行改进，衍生出YOLO系列算法^[19-20]。YOLO及其衍生系列遵循将图像分割为多个区域，同时预测每个区域的边界框与概率的基本思想，可有效提高检测速度。为提高不同尺寸特征图的适应性，以SSD及其衍生系列为代表的直接预测目标类别和边界框的多目标检测算法，相较于Faster R-CNN显著提高了检测速度^[21]。为优化复杂场景中的目标检测性能，RetinaNet通过引入焦损失函数，针对标准交叉熵损失进行重构，使检测器在训练过程中可以更加关注疑难检测目标^[22]。绝大多数检测器主要通过综合运用如加权残差连接、跨阶段部分连接、跨小批量标准化、自对抗训练、马赛克数据增强、特征金字塔以及改进CloU Loss函数等技术手段优化网络结构，从而提高检测性能。部分当前图像识别与目标检测领域主流的、具有代表性的目标检测算法如图4所示。

3.3 深度检测网络在配网工程目标检测中的应用

随着机器视觉领域深度检测网络模型的不断迭代，配网工程领域的目标检测准确度与实时性均得以提高。近期的研究热点主要聚焦于将多种主流目标检测算法应用于配网工程领域，并进行持续优化改进。本节将从目标检测类型的角度出发，将配网工程安全质量缺陷现状按照文本类、人员类、设备

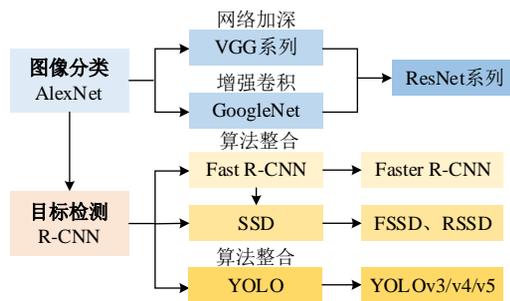


图4 经典目标检测算法

Fig. 4 Examples of classical targets detection algorithms

类以及工艺类进行综述。

3.3.1 文本检测

文本检测的内容包括：检测配网设备照片是否具备铭牌或标识，判断标牌是否脱落；识别设备铭牌、标识的具体内容；针对配网设备图像故障缺陷文本进行挖掘，快速判断其是否存在缺陷。内容属于目标检测中的文本检测识别，属于基于深度检测网络的语义识别。

针对铭牌文本进行提取通常是先做检测后再识别，“检测-识别”的任务框架由于采用两阶段模式，铭牌文字提取需要同时考虑准确性与实时性。文献[23-25]针对常规文本检测识别提出解决方案。其中，文献[23]利用VGG-16网络中的卷积层和池化层从输入图像中提取特征，然后综合TPN网络、RFE解码以及TDN网络等技术，实现文字标签检测。文献[24]在CNN+softmax结构的基础上提出一种文本检测专用神经网络，首先采用网格发生器检测输入图像的若干区域，然后使用双线性插值提取文字区域信息。文献[25]提出一种快速文本定位算法(fast oriented text spotting, FOTS)可减少网络训练工作量。电力设备铭牌内容一般为电力相关术语，字符上下文语义和语境存在关联，文献[26]将电力设备铭牌候选字符的排列进行预处理，按照电力术语的组合规则实现铭牌信息的定性排序。文献[27]将TDRN模型应用于铭牌检测，结合注意力机制以期提高文本识别准确率。为提高文本处理效率，文献[28]提出一种集成CNN与概率图模型的文本序列特征抽取方法，能够更好地理解设备故障文本语义。

配网设备运维中将产生大量表计信息图像，可能包含故障缺陷文本^[29]，如指示灯面板、数字表盘、硬压板、指针表盘以及二次屏柜等。通过机器视觉对示数或状态信息文本进行智能读取，识别可能存在的缺陷，确保对重要设备状态全面感知、优先监视和告警。针对指针表盘示数的检测与识别，文献[30]在CNN模型的基础上，增加相机视野比例

计算，并通过透视变换消除表盘平面和相机平面偏差造成的表盘图像畸变。文献[31]将图像分割技术融入Faster R-CNN模型，并对U-Net网络进行改进从而提高刻度和指针识别的有效性。文献[32]从工程化的角度简单论述将机器视觉运用到变电站屏柜运检中的关键技术，包含经典深度检测网络的选择、训练以及部署。

3.3.2 人员检测

人员检测的内容包括：参与配网工程的人员人脸识别、人数实时统计；工程人员行为规范性检测。前者属于基于深度检测网络的目标检测领域，后者需要在特定场景下对人员行为进行动态识别。

配网工程场景中需要通过人脸识别对进入施工场地的人员进行资质审核和客流量统计。人员资质审核的基础是人脸识别技术，文献[33-35]针对提高人脸识别的准确度问题开展了深入研究。文献[33]对人脸识别技术进行较为全面的总结，指出人脸识别系统通常由人脸位置检测、人脸对齐、人脸表征以及人脸匹配等多个模块构建，其中，人脸检测分为基于知识规则的方法、基于特征的方法、基于模板匹配的方法以及基于统计模型的方法。文献[34]尝试类比三元组损失函数、中心损失函数以及范围损失函数等在人脸识别中的应用结果。针对人员检测领域L-Softmax的类间距小，类内距离大等问题，文献[35]提出Anangular-Softmax损失函数用于学习判别人员行为特征，在超球面流形上增加判别约束，验证结果表明Anangular-Softmax的识别优化结果优于L-Softmax函数。

某些配网工程场景中参与施工人员较多，需要对人数是否符合规范进行核查，此时需要对客流量或者人数进行统计。针对现有检测算法可能存在的误检、漏检问题，文献[36]在CN算法中加入方向梯度直方图特征增强人体目标颜色、背景光照的鲁棒性，可有效提高运动目标检测精度。文献[37]重点针对小目标检测、运动目标关联匹配以及双向客流量统计算法开展研究，在Faster R-CNN的基础上改进图像浅层特征提取，并加入运动轨迹预测追踪算法，提高对密集场所人员统计的准确性。

人员行为检测需要结合具体场景，通常是从动态视频中的多帧图像中辨识行为特征。配网工程场景中的人员行为检测包括：基本行为规范性检测，如是否佩戴安全帽、是否正确穿着工装和佩戴防护用品、是否违规吸烟以及是否处于安全距离内(构建虚拟安全围栏)等；人员行为远方稽查，主要针对人员操作与流程是否规范进行核查。文献[38-39]

分别运用改进SSD与优化YOLOv3对安全帽识别任务开展研究。文献[40]针对变电站作业人员着装规范性问题，通过适当调整YOLOv5输出层结构，经过样本扩充和初始化模块聚类预处理，能够有效检测长袖/短袖2种着装类型。针对一些人员行为检测特征提取高度依赖人工经验的缺点，文献[41]所提3D CNN能够直接从原始输入中提取特征，通过执行3D CNN在监控视频中从时间和空间维度提取特征，该方法相比于传统的方法在人体行为识别准确率取得更优的表现。

由于工程人员在一段时间内动作和姿势具有连续语义，兼具时间和空间维度，如何对行为序列进行模式判别，识别语义上所代表的行为规范性，成为人员行为检测的难点^[42]。文献[43]分别基于RNN、CNN以及GCN算法模型架构，综述基于3D骨架序列数据的动作行为识别的有效性，指出由于GCN是基于拓扑图的方法，最贴近人体骨骼关节的自然表示。此外，Transformer模型使用的自注意力机制区别于RNN的顺序结构，使模型可以并行化训练，更容易提取全局信息，文献[44]所提Mesh Transformer已被证实对人体行为识别的数据集中具有较高的准确度。文献[45-46]针对电网检修人员是否处于安全通道进行实时监测。针对帧间差分法引起运动目标背景轮廓不完整的问题，文献[45]提出一种改进混合高斯模型的算法模型，在电网检修人员是否存在处于安全距离的视频集上进行验证。文献[46]对变电站场景下的人员和安全通道特点进行语义分割，提出PSPNet语义分割模型，能够有效提取出人员与安全通道的外部轮廓。

3.3.3 设备检测

设备检测的内容包括：识别不同配电设备的类型；识别配电设备当前状态；检测配电设备是否存在缺陷，主要指设备外观异常检测。

配网典型设备类型包括母排、变压器、开关柜、断路器、绝缘子、横担、线缆以及线夹等。典型的设备状态识别如刀闸开关分合状态确认。设备外观异常检测如开关柜门未关闭、电缆柜入口封堵以及设备外壳是否污损等。针对开关状态检测的技术特点，文献[47]基于开关边沿特征对直线段进行筛选，提出一种基于融合直线检测与深度学习的方法，生成预选框后经过YOLOv3进行网络训练与检测识别。针对特定设备的目标检测问题，文献[48]搭建基于深度学习分类网络、电表终端监测网络、组态匹配和故障识别网络，将电表终端设备型号为输入，使用组态匹配监测方法获取每个电表终端面

板信息特征。通过将典型的“无故障”和“有故障”图片送入深度学习网络进行训练，达到识别电表终端故障的目的。文献[49-50]针对系统中的瓷绝缘子、线路破损等进行图像识别，采用深度检测网络，利用大量不同部件图像样本作为输入数据集，经过CNN构建分类器对不同种类的瓷绝缘子进行分类，对线路局部异常破损进行监测辨识。

针对复杂场景的多类型设备检测问题，文献[51-53]从配电设备红外目标检测的角度，分别提出基于改进YOLOv3、Faster RCNN以及RetinaNet的特定场景多设备目标检测模型，其本质上是综合运用多种技术如数据增强、改进损失函数以及分层聚类等，小幅度提升配电设备目标检测与缺陷识别准确率。文献[54-55]分别基于结合深度学习的随机森林分类方法与改进YOLOv4算法模型，通过直接提取电力设备图像特征，采用多种典型电力设备图像对模型进行测试，结果表明对于绝缘子、导线、套管、变压器以及断路器等配网设备平均识别准确率有一定程度的提高。针对配网设备部件外形相似度高、小样本检测困难的问题，文献[56]采用深度迁移学习的方式，提出一种改进的单阶段多框检测器SSD，通过优化非极大抑制比计算，能够有效提高算法模型对小样本设备数据集检测的精确度。

3.3.4 工艺检测

工艺检测的内容主要针对配网施工工艺的规范性进行检测，如横担是否正装、拉线是否装设绝缘子、接地固定是否使用恒力弹簧以及线夹是否安装绝缘护套等等安装工艺缺陷。

工艺缺陷检测不仅要求准确识别出具体目标，还需要对其工艺规范性进行判断，因此一些研究者将该问题转化为分类问题。为实现目标异常检测，文献[57]指出在网络训练前需要对异常数据集进行大量标注。在工艺检测的深度检测网络方面，文献[58-60]分别针对线路中螺母、销钉、防震锤部件缺陷的判别问题，提出利用层次模型“与或图”对目标进行分解表达，建立部件之间的约束关系，构建多向的判别路径的方法。利用基于类Haar特征和级联Ada Boost分类器对目标基元进行识别，通过数据合成扩充数据样本用于训练，以提高分类器的训练性能，结果表明该分类器对线路工艺缺陷判别具备一定有效性。针对横担姿态检测方法，文献[61]通过构建横担基本空间几何模型，采用基于FCN区域分割的边缘检测法对横担区域进行提取，实现横担姿态检测。针对横担处螺栓是否平帽

或者松动的工艺缺陷检测，文献[62]利用灰度投影算法完成杆塔横担区域定位，然后再通过霍夫变换提取螺栓特征。针对架空线路线夹工艺缺陷检测，文献[63-64]通过Faster R-CNN与YOLOv3的迁移学习，验证2种经典网络模型的有效性。

4 配网工程动态缺陷检测关键技术

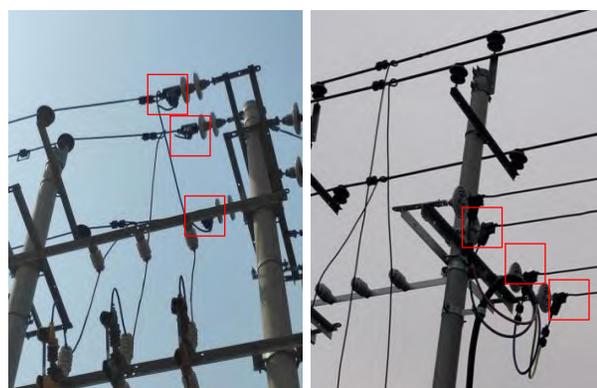
目前在配网动态缺陷检测领域已有一些基础性研究成果，然而运用深度检测网络实现配网工程动态缺陷检测，既包含深度检测网络本体架构优化设计的难题，又包含针对配网工程施工现场复杂性与动态缺陷类别多样性带来的挑战，该领域的研究工作尚处于初始阶段。

4.1 样本库建立

配网工程动态缺陷细分种类较多且具有不同特点，针对某一种或某一类型的缺陷故障需要单独确立标注方案并建立样本库。构建配网工程缺陷样本库时将遇到3个典型问题：样本数量与质量不高；样本不均衡；标注工作不够细化。

4.1.1 样本质量与数量并重

为提高缺陷识别的准确率，需对样本图像拍摄角度、光线、尺寸以及清晰度等提出较高质量要求，同时尽可能多的增加不同缺陷种类有效样本数量。在数据清洗时需剔除不合格样本与无效样本，此处不符合拍摄质量要求的属于不合格样本，错误图片与冗余图片属于无效样本。以耐张线夹加装绝缘护套为例，角度不佳、光线不足以及检测目标被严重遮挡的不合格样本示意如图5所示。



(a) 角度不佳

(b) 对象遮挡

图5 耐张线夹加装绝缘护套不合格样本示意

Fig. 5 Unqualified samples of installing insulation sheath on strain clamp

由于样本数量不足或标注信息较少时引起的小样本问题是将深度检测网络引入电气行业的突出障碍。解决小样本问题的方法主要有：数据增强；迁移学习^[65]；元学习^[66]。文献[67]指出针对配网工程

现场异物检测问题，提出一种基于样本扩充的Faster R-CNN的检测技术，通过高斯滤波合成样本扩充训练集，从而提高检测模型的精确性。利用数据增强预处理样本训练集可以增加训练数据，提升算法模型的鲁棒性。数据增强的本质是人为地引入模拟人视觉的先验知识，常见的数据增强方法如尺度变换、平移、旋转以及剪裁等^[68]。

4.1.2 均衡样本数量

在工程现场搜集的样本集中，针对某一种类型的配网工程缺陷，可能存在正负样本数量不均衡。以线路螺栓是否缺失为例，定义线路螺栓未缺失为正样本，螺栓缺失为负样本，若将其视为二分类问题，则可能出现某一类样本远多于另一种样本。且实际工程应用中螺栓种类较多，此时可能出现某种螺栓与其他种类螺栓类别不均衡的情况。样本不均衡将大大降低模型的泛化能力，影响缺陷检测的准确度，严重时甚至导致模型失效。

针对样本不均衡问题，可通过数据增强扩充样本库^[69]。文献[70]将类别不平衡的解决方案分为4类：硬采样法，指定数量或比例的正负样本；软采样法，设定样本损失权重；无采样方法，根据历史设立新分支；生成方法，基于GAN生成预测样本。当前YOLOv4算法中集成的马赛克数据增强已被证实为一种有效的技术手段^[20]。马赛克数据增强综合运用如几何畸变、光照畸变、图像畸变以及自对抗训练(self-adversarial training, SAT)等，用于提高算法模型的鲁棒性。通常认为数据增强是解决小样本和样本不均衡问题的有效方法。

4.1.3 差异化样本标注

配网工程动态缺陷细分种类较多，某种或某一类型缺陷具有其独到的特征，在标注工作中应采用差异化标注，针对具体问题具体分析，良好的标注方案可以帮助算法模型准确理解特征。以线夹是否加装绝缘护套为例，线夹加装绝缘护套正负样本标注如图6所示，配网施工过程中使用线夹种类较多，外形轮廓差异较大。此处以螺栓型耐张线夹为例，为提高缺陷识别准确率，图6(a)、(b)分别为正负样本标注方法，采用方框与标签1、0区分正负样本。

横担倒装正负样本标注方法如图7所示，由于区分横担的倒装的依据是螺栓定位孔方向，因此标注时既标注单个螺栓定位孔，同时也标注成对螺栓定位孔所在的区域。

需要说明的是，标注框在包含检测目标全部信息的基础上应尽可能的缩小，利于排除背景干扰信息，或依据目标外观采用不规则标注框。此外，在

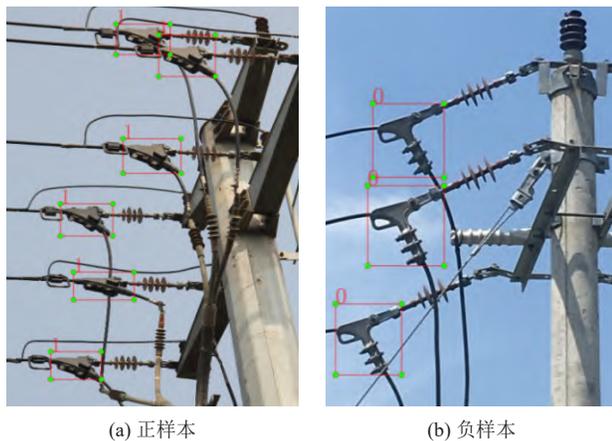


图6 线夹加装绝缘护套正负样本标注

Fig. 6 Mark the positive and negative samples of the insulated sheath installed on the clamp

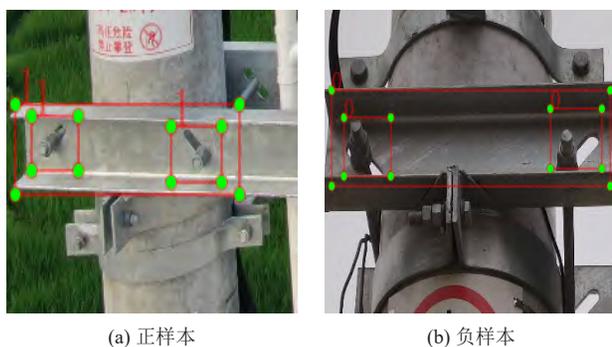


图7 横担倒装正负样本标注

Fig. 7 Mark on the positive and negative samples of crossbar inverted

大规模标注工作前可运用智能标注对标注方案进行先验。但某些缺陷检测可能无法准确标注出正负样本，如拉线未安装绝缘子的负样本，可将其视为联合信息空间关系抽取的标注问题，对此文献[71]提出了一种带有偏置目标函数的端到端模型，不需要提前分开识别实体关系，可同时联合抽取实体和实体间的关系，为解决此类问题提供了参考思路。

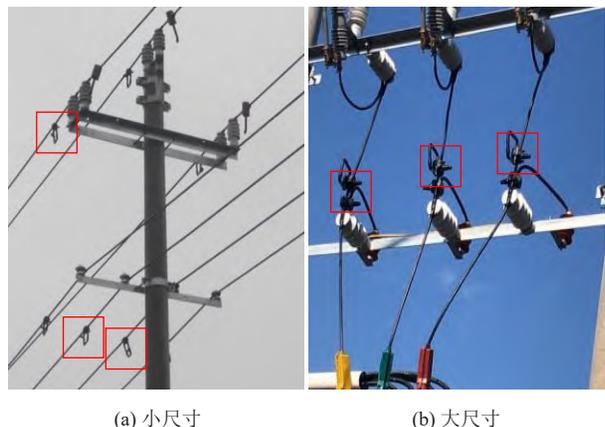
4.2 模型构建

在构建配网动态缺陷检测模型时，除3.1节所述的深度检测网络模型设计本身面临的问题外，针对配网工程现场这一特殊场景，在模型构建还将面临检测目标尺寸不平衡、目标检测与分类复合目标以及算法模型不适用迁移学习等系列挑战。

4.2.1 适应目标尺寸不平衡

由于配网施工现场监测设备距离检测目标距离、视角不完全一致，将引起样本图像中检测目标尺寸不一致的问题，甚至检测目标在图像中占比过低，属于目标检测领域的空间不平衡问题。此时要求算法与模型对于同类异型、不同尺寸的检测目标有良好的泛化能力^[72]。不同场景下柱上变压器接地

环安装正样本如图8所示,可以看出,图8(a)中由于拍摄距离较远,接地环占样本图像的比例较小。



(a) 小尺寸 (b) 大尺寸

图8 接地环安装不同尺寸正样本

Fig. 8 Positive samples of different sizes for grounding ring installation

为解决目标尺寸不平衡问题,文献[73-74]对目标检测领域中的图像金字塔系列典型策略在多尺度目标检测中的应用现状进行总结,并对锚点、交并比阈值、动态卷积、边界框损失函数等细节层面进一步分析优化尺度问题的策略。文献[75]建立多视点神经网络,从合并异构体中提取图像特征,利用多视图分类器的神经网络进行图像间的相关性分析,该模型相比单视点深度神经网络,具有更高的效率和泛化性能。文献[76]总结目标检测领域尺度不均衡的解决方法,主要包括基于Backbone特征层次的预测方法、基于特征金字塔的方法等。空间不平衡的主要解决方案包括级联式R-CNN、分层发射探测器(hierarchical shot detector, HSD)以及IoU-uniform R-CNN等。目标不平衡可通过额外设置超参数作为权重因子来平衡损失项。

在目标尺寸不平衡领域,小尺寸目标的检测识别是难点。Fast R-CNN、Faster R-CNN、SPPNet^[77]以及R-FCN^[78]等大多只利用深度神经网络的最后层进行预测,在小目标检测上普遍表现不佳。由于空间和细节特征信息的丢失,难以在深层特征图中检测小目标。在深度神经网络中,浅层的感受野更小,语义信息弱,上下文信息缺乏,但可以获得更多空间和细节特征信息。为提高小目标检测精度,文献[79]提出特征金字塔,通过对图片进行多次下采样,提高模型在不同尺寸目标检测的适用性,缺点在于有可能导致模型消耗较大的内存和计算量。YOLOv4版本以上模型由于在骨干网络中嵌入特征金字塔,在不同尺寸目标检测上的表现较为优异。

4.2.2 模型选择与部署

根据不同配网工程场景的差异化缺陷检测需

求,需要合理选择深度检测网络模型和部署方案。模型选择与部署可以从以下角度切入:样本库数量;检测目标区分为大/中尺寸、小尺寸目标;目标检测的准确度;目标检测的实时性;拍摄场景,包含拍摄分辨率、硬件算力以及场景的复杂度。

单阶段检测器、两阶段检测器是目标检测的2个主要方向。单阶段检测器通常仅使用一个CNN网络直接预测物体的类别与位置,代表算法有YOLO v3、YOLO v4、SSD、RetinaNet以及PeeleNet^[80]等。两阶段检测器需要先使用启发式方法或者CNN网络提取目标的候选位置,然后再对其进行识别与分类,代表算法有Faster R-CNN、Mask R-CNN^[81]以及ThunderNet^[82]等。单阶段检测器的特点是训练和识别速度较快,而两阶段检测器准确度比单阶段检测器有所提高,但降低实时性。随着CornerNet的推出,目标检测衍生出Anchor-Free类型^[83]。Anchor-Free系列算法网络结构简单,可以降低算法模型超参数调整难度,对算法设计人员更友好。Anchor-free可实现待检测目标中心和4条边框的预测,代表算法有DenseBox^[84]、DDBNet^[85]以及YOLOX^[86]等。

固定高清摄像头所拍摄的图像往往具有高分辨率,而如手机、无人机等移动终端设备的图像分辨率通常低于高清摄像头。虽然高分辨率图像有助于提高目标检测准确率,但是将带来庞大的计算量。相较于单目标检测,复杂配网工程场景的多目标缺陷检测需求还会增加模型的复杂程度。因此,针对配网工程的目标检测模型选择应综合考虑检测目标尺寸、检测准确度、实时性以及拍摄场景等。

结合配网工程应用场景,对于检测准确度要求不高、动态检测实时性要求较高的场合,考虑到移动终端设备算力有限,推荐部署轻量级算法,如在无人机、手机或平板电脑等部署检测算法,通过移动巡检设备实现架空线路巡线。对于检测准确度要求较高、动态检测实时性要求较低的场合,推荐在服务器部署非轻量级算法,如配备视频监控的站房工程与配变工程的复杂多目标缺陷检测场景。

4.3 模型预训练

目前有一些深度检测网络模型在ImageNet或COCO等开源图片数据集中取得了较好的图像分类或目标检测准确率。但配网工程动态缺陷检测任务场景有非常强的专业性,尚缺乏直接涉及该领域的开源图片集。因此,针对深度检测网络模型进行训练时,由于在其他领域学习到的知识或特征无法直接应用到配网工程领域,建议不直接采用迁移学习

的方式，而是将某个主流算法已经训练好的权重集作为初始化参数，针对不同配网工程动态缺陷重新对算法与模型进行预训练，在预训练得到新的权重集后，再进一步考虑算法模型超参数的优化改进。

模型预训练通常包括特征提取和微调模型两个部分^[87]。其中，特征提取是指使用已经训练好的网络在新的样本集上提取特征，然后将特征输入新的分类器，并重新训练网络。微调模型是指将冻结的卷积基逐层解冻，然后再进行全连接层联合训练。例如可将现有无人机巡检高压输电线路的模型用于配网架空线路场景，重新训练进行特征提取，然后再通过微调模型逐步提高新模型的性能。

模型预训练有利于减少大规模模型训练量，若将模型预训练的思想与知识蒸馏相结合，可用于模型压缩^[88]。模型压缩是在 teacher-student 框架中^[89]，将复杂且学习能力强的大规模网络所学习的特征知识蒸馏出来后，传递给参数量小、学习能力弱的小规模网络。这些小规模网络属于轻量级模型，更加利于在配网工程缺陷检测的移动端设备进行线上部署。

4.4 模型可解释

配网工程动态缺陷检测不仅需要准确检测目标，还需综合判断是否存在缺陷甚至估计缺陷程度。初期大量研究集中于运用典型网络模型进行迁移学习，或者做出适当改进优化检测性能，这对于短期内小幅提升检测器性能是有效的。然而从长远来看，除本文所提到的各种技术手段以外，还需要考虑引入模型的可解释性，具体问题具体分析，以期显著提高检测器性能。

在配网工程的特定应用场景，“目标与场景”和“目标与目标”之间常常存在共存关系，通过利用这种可解释性将有助于提升模型的检测性能^[90-91]。架空线路是否装设绝缘子如图9所示，架空线路拉线是否装设绝缘护套如图10所示，拉线与电杆间存在固定的类三角形几何可解释性。为准确判断拉线位置，避免与输电线路混淆误判，可在算法模型中引入几何可解释性。

大量设备的相序标识与颜色有关，如ABC三相分别用黄绿红颜色进行区分，中线用黑色标识，这种特定颜色关系属于外观可解释性的表现。架空线路螺栓型耐张线夹装设绝缘护套示意如图11所示，通常绝缘护套由3~4种按照颜色进行区分相序。为准确判断线夹是否装设绝缘护套，可在算法模型中引入颜色可解释性。

通过引入不同目标之间的外观和几何结构关系



图9 拉线装设绝缘子示意

Fig. 9 Cable installation of insulators



图10 拉线装设绝缘护套示意

Fig. 10 Cable installation of insulated jacket

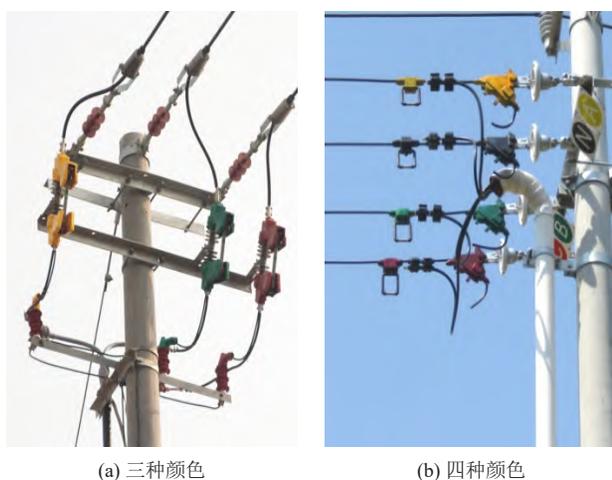


图11 螺栓型耐张线夹装设绝缘护套示意

Fig. 11 Insulation sheath for bolt type tension clamp

来做约束，实现目标之间的关系建模。将各种可解释性关系纳入到现有算法模型中，作为网络的先验知识，将有效提高配网工程缺陷检测算法模型的性能。

5 结语

配网工程动态缺陷检测问题具有复杂多样性的典型特征,如何将深度检测网络高效应用于配网工程动态缺陷检测,关键是厘清配网工程动态缺陷检测技术路线的重难点,并且广泛吸收深度检测网络在其他领域的实践经验。结合深度检测网络的发展趋势与配网工程动态缺陷检测的差异性与独特性,对该领域后续研究方向进行展望。

1) 在样本库构建方面,随着配网工程动态缺陷样本数据量的增长、运算力的持续提升,软硬件协同会突破深度网络在学习训练方面的瓶颈,将为自监督学习甚至无监督学习在该领域的运用创造必要条件,有利于减少图片标注的工作量。

2) 在深度检测网络设计方面,传统深度网络由主干网络和颈/头部组件网络组成,主干网络与检测任务无直接关系,颈部/头部用于嵌入专用先验知识。但主干网络的多尺度、分层的固有架构,不利于配网工程施工缺陷检测任务中的颈部/头部网络与主干设计解耦。为此,除考虑增加配网工程施工的可解释性约束以外,还需引入基于注意力机制的视觉 Transformer,通过非层次化架构优化主干网络,在检测通用特征的过程中可减少归纳偏置,从而更有效地提取配网工程动态缺陷变尺度特征。

3) 在深度检测网络部署方面,当前配网工程中存在大量的边缘侧设备,可低成本、高效率的在数据源源头提供智能服务,但若简单将深度网络部署于边缘侧,则功耗、时延等都会成为巨大的负担。在实践中可考虑构建轻量、紧凑以及压缩的网络,不断优化算法模型部署方案,以期更好的平衡网络模型复杂度、准确度以及效率间的矛盾;

4) 在配网工程缺陷检测技术研究的初期,验证通用型网络的识别精度将更多的受到关注。然而缺陷检测是系统工程,后续研究可采用自动机器学习构建适用于配网工程领域及其技术需求的网络架构,通过预设神经网络结构搜索算法,使模型可以自动化的学习适用于配网工程缺陷检测的参数和网络配置而无需人工干预。

参考文献

- [1] 孙国强,沈培锋,赵扬,等. 融合知识库和深度学习的电网监控告警事件智能识别[J]. 电力自动化设备,2020,40(4):40-47.
SUN Guoqiang, SHEN Peifeng, ZHAO Yang, et al. Intelligent recognition of power grid monitoring alarm event combining knowledge base and deep learning[J]. Electric Power Automation Equipment, 2020, 40(4):40-47(in Chinese).
- [2] 杜绍鑫,谢海宁,宋杰,等. 基于图像处理和深度学习的配网跳闸故障识别方法[J]. 中国科学技术大学学报,2020,50(1):39-48.
DU Zhaoxin, XIE Haining, SONG Jie, et al. A trip fault identification method of distribution network based on image processing and deep learning[J]. Journal of University of Science and Technology of China, 2020, 50(1): 39-48(in Chinese).
- [3] 陈亮,王震,王刚. 深度学习框架下LSTM网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术,2017,15(5):8-11.
CHEN Liang, WANG Zhen, WANG Gang. Application of LSTM networks in short-term power load forecasting under the deep learning framework[J]. Electric Power ICT, 2017, 15(5): 8-11(in Chinese).
- [4] 陈志强,陈旭东,DE OLIVIRA J V,等. 深度学习在设备故障预测与健康管理中应用[J]. 仪器仪表学报,2019,40(9):206-226.
CHEN Zhiqiang, CHEN Xudong, DE OLIVIRA J V, et al. Application of deep learning in equipment prognostics and health management[J]. Chinese Journal of Scientific Instrument, 2019, 40(9):206-226(in Chinese).
- [5] 蒲天骄,乔骥,韩笑,等. 人工智能技术在电力设备运维检修中的研究及应用[J]. 高电压技术,2020,46(02):369-383.
PU Tianjiao, QIAO Ji, HAN Xiao, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. High Voltage Engineering, 2020, 46(02): 369-383(in Chinese).
- [6] 程乐峰,余涛,张孝顺,等. 机器学习在能源与电力系统领域的应用和展望[J]. 电力系统自动化,2019,43(1):15-31.
CHENG Lefeng, YU Tao, ZHANG Xiaoshun, et al. Machine learning for energy and electric power systems: state of the art and prospects[J]. Automation of Electric Power Systems, 2019, 43(1): 15-31(in Chinese).
- [7] WU Yang, WANG Dingheng, LU Xiaotong, et al. Efficient visual recognition with deep neural networks: a survey on recent advances and new directions[J]. arXiv:2108.13055, 2021.
- [8] 马富齐,王波,董旭柱,等. 电力视觉边缘智能:边缘计算驱动下的电力深度视觉加速技术[J]. 电网技术,2020,44(6):2020-2029.
MA Fuqi, WANG Bo, DONG Xuzhu, et al. Power vision edge intelligence: power depth vision acceleration technology driven by edge computing[J]. Power System Technology, 2020, 44(6): 2020-2029(in Chinese).
- [9] MINAR M R, NAHER J. Recent advances in deep learning: an overview[J]. arXiv:1807.08169, 2018.
- [10] KHAN A, SOHAIL A, ZAHOORA U, et al. A survey of the recent architectures of deep convolutional neural networks[J]. Artificial Intelligence Review, 2020, 53(8):5455-5516.
- [11] TIAN Yuandong, JIANG Tina, GONG Qucheng, et al. Luck matters: understanding training dynamics of deep ReLU networks[J]. arXiv: 1905.13405, 2019.
- [12] PAULOSKI J G, ZHANG Zhao, HUANG Lei, et al. Convolutional neural network training with distributed K-FAC[C]//Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis. Atlanta: IEEE, 2020: 1-12.
- [13] 古德费洛,约书亚·本吉奥,亚伦·库维尔. 深度学习[M]. 赵申剑,黎晓君,符天,等译. 北京:人民邮电出版社,2017.
- [14] GE Rong, KUDITIPUDI R, LI Zhize, et al. Learning two-layer neural networks with symmetric inputs[J]. arXiv:1810.06793, 2018.
- [15] GE Rong, MA Tengyu. On the optimization landscape of tensor decompositions[J]. Mathematical Programming, 2022, 193(2):713-759.
- [16] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016.
- [17] ZOU Zhengxia, CHEN Keyan, SHI Zhenwei, et al. Object detection

- in 20 years: a survey[J]. Proceedings of the IEEE, 2023, doi: 10.1109/JPROC.2023.3238524.
- [18] 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.
- [19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 779-788.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[J]. arXiv:2004.10934, 2020.
- [21] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam: Springer, 2016: 21-37.
- [22] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2999-3007.
- [23] LI Hui, WANG Peng, SHEN Chunhua. Towards end-to-end text spotting with convolutional recurrent neural networks[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 5248-5256.
- [24] BARTZ C, YANG Haojin, MEINEL C. STN-OCR: a single neural network for text detection and text recognition[J]. arXiv: 1707.08831, 2017.
- [25] LIU Xuebo, LIANG Ding, YAN Shi, et al. FOTS: fast oriented text spotting with a unified network[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 5676-5685.
- [26] 杨东宁, 张志生, 赵智勇, 等. 基于深度神经网络的电网设备铭牌识别方法[J]. 微型电脑应用, 2021, 37(11): 9-11, 15.
YANG Dongning, ZHANG Zhisheng, ZHAO Zhiyong, et al. Research on nameplate identification method of power grid equipment based on deep neural network[J]. Microcomputer Applications, 2021, 37(11): 9-11, 15(in Chinese).
- [27] 陈晓龙, 陈显龙, 袁建平, 等. 基于深度学习的电力设备铭牌识别[J]. 广西大学学报(自然科学版), 2018, 43(6): 2216-2226.
CHEN Xiaolong, CHEN Xianlong, YUAN Jianping, et al. Electricity equipment nameplate recognition based on deep learning[J]. Journal of Guangxi University (Natural Science Edition), 2018, 43(6): 2216-2226(in Chinese).
- [28] 田嘉鹏, 宋辉, 陈立帆, 等. 面向知识图谱构建的设备故障文本实例识别方法[J]. 电网技术, 2022, 46(10): 3913-3922.
TIAN Jiapeng, SONG Hui, CHEN Lifan, et al. Entity recognition approach of equipment failure text for knowledge graph construction [J]. Power System Technology, 2022, 46(10): 3913-3922(in Chinese).
- [29] 邵冠宇, 王慧芳, 何奔腾. 电网设备缺陷文本的质量评价与提升方法[J]. 电网技术, 2019, 43(4): 1472-1479.
SHAO Guanyu, WANG Huifang, HE Benteng. Quality assessment and improvement method for power grid equipment defect text[J]. Power System Technology, 2019, 43(4): 1472-1479(in Chinese).
- [30] 邢浩强, 杜志岐, 苏波. 变电站指针式仪表检测与识别方法[J]. 仪器仪表学报, 2017, 38(11): 2813-2821.
XING Haoqiang, DU Zhiqi, SU Bo. Detection and recognition method for pointer-type meter in transformer substation[J]. Chinese Journal of Scientific Instrument, 2017, 38(11): 2813-2821(in Chinese).
- [31] 万吉林, 王慧芳, 管敏渊, 等. 基于 Faster R-CNN 和 U-Net 的变电站指针式仪表读数自动识别方法[J]. 电网技术, 2020, 44(8): 3097-3105.
WAN Jilin, WANG Huifang, GUAN Minyuan, et al. An automatic identification for reading of substation pointer-type meters using faster R-CNN and U-Net[J]. Power System Technology, 2020, 44(8): 3097-3105(in Chinese).
- [32] 钱金戈, 徐丹, 史豪杰. 图像识别技术在变电站屏柜运检中的应用[J]. 工业控制计算机, 2021, 34(3): 7-8, 11.
QIAN Jin'ge, XU Dan, SHI Haojie. Application of operation and maintenance of substation cabinet based on image recognition[J]. Industrial Control Computer, 2021, 34(3): 7-8, 11(in Chinese).
- [33] WANG Mei, DENG Weihong. Deep face recognition: a survey[J]. Neurocomputing, 2021, 429: 215-244.
- [34] TRIGUEROS D S, MENG Li, HARTNETT M. Face recognition: from traditional to deep learning methods[J]. arXiv: 1811.00116, 2018.
- [35] LIU Weiyang, WEN Yandong, YU Zhiding, et al. SphereFace: deep hypersphere embedding for face recognition[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 6738-6746.
- [36] 张开生, 郭碧筱, 刘泽新, 等. 基于人流量检测的改进 CN 算法[J]. 计算机工程与设计, 2020, 41(2): 411-416.
ZHANG Kaisheng, GUO Bixiao, LIU Zexin, et al. Improved CN algorithm based on pedestrian flow detection[J]. Computer Engineering and Design, 2020, 41(2): 411-416(in Chinese).
- [37] 朱军, 张天奕, 谢亚坤, 等. 顾及小目标特征的视频人流量智能统计方法[J]. 西南交通大学学报, 2022, 57(4): 705-712, 736.
ZHU Jun, ZHANG Tianyi, XIE Yakun, et al. Intelligent statistic method for video pedestrian flow considering small object features [J]. Journal of Southwest Jiaotong University, 2022, 57(4): 705-712, 736(in Chinese).
- [38] 李明山, 韩清鹏, 张天宇, 等. 改进 SSD 的安全帽检测方法[J]. 计算机工程与应用, 2021, 57(8): 192-197.
LI Mingshan, HAN Qingpeng, ZHANG Tianyu, et al. Safety helmet detection method of improved SSD[J]. Computer Engineering and Applications, 2021, 57(8): 192-197(in Chinese).
- [39] 王珩. 基于 YOLOv3 的安全帽佩戴检测方法研究[J]. 自动化仪表, 2021, 42(2): 63-67.
WANG Heng. Research on detecting method for safety helmet wearing based on YOLOv3[J]. Process Automation Instrumentation, 2021, 42(2): 63-67(in Chinese).
- [40] 何蕾, 葛鑫, 郝晨煜, 等. 基于 YOLO v5 的变电站作业人员着装规范性识别[J]. 电力大数据, 2021, 24(10): 1-8.
HE Lei, GE Xin, HAO Chenyu, et al. Identification of dress code of workers in substation based on YOLO v5[J]. Power Systems and Big Data, 2021, 24(10): 1-8(in Chinese).
- [41] 匡晓华, 何军, 胡昭华, 等. 面向人体行为识别的深度特征学习方法比较[J]. 计算机应用研究, 2018, 35(9): 2815-2817, 2822.
KUANG Xiaohua, HE Jun, HU Zhaozhua, et al. Comparison of deep feature learning methods for human activity recognition[J]. Application Research of Computers, 2018, 35(9): 2815-2817, 2822(in Chinese).
- [42] 朱煜, 赵江坤, 王逸宁, 等. 基于深度学习的人体行为识别算法综述[J]. 自动化学报, 2016, 42(6): 848-857.
ZHU Yu, ZHAO Jiangkun, WANG Yining, et al. A review of human action recognition based on deep learning[J]. Acta Automatica Sinica, 2016, 42(6): 848-857(in Chinese).
- [43] REN Bin, LIU Mengyuan, DING Runwei, et al. A survey on 3D Skeleton-Based action recognition using learning method[J]. arXiv: 2002.05907, 2020.
- [44] LIN K, WANG Lijuan, LIU Zicheng. End-to-End human pose and mesh reconstruction with transformers[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition.

- Nashville:IEEE,2021:1954-1963.
- [45] 贾宇为,王汉军. 改进混合高斯模型的电网检修人员行为检测[J]. 计算机系统应用,2020,29(10):242-247.
JIA Yuwei, WANG Hanjun. Behavior detection of grid maintenance personnel based on improved mixed Gaussian model[J]. Computer Systems & Applications, 2020, 29(10): 242-247(in Chinese).
- [46] 朱建宝,马青山,俞鑫春,等. 基于PSPNet的变电站人员巡检危险行为检测[J]. 自动化与仪表,2021,36(11):35-39.
ZHU Jianbao, MA Qingshan, YU Xinchun, et al. Detection of dangerous behaviors in substations based on PSPNet semantic segmentation[J]. Automation & Instrumentation, 2021, 36(11): 35-39 (in Chinese).
- [47] 林本丰,王呈,孙悦程. 融合LSD算法与深度学习的开关状态检测方法[J]. 计算机工程与应用,2021,57(17):181-189.
LIN Benfeng, WANG Cheng, SUN Yuecheng. Switch state detection method based on LSD algorithm and deep learning[J]. Computer Engineering and Applications, 2021, 57(17): 181-189(in Chinese).
- [48] 丁超,张秋雁,胡厚鹏,等. 基于改进深度学习的电表终端故障图像识别方法[J]. 电工技术,2020(10):36-39.
DING Chao, ZHANG Qiuyan, HU Houpeng, et al. Fault imager recognition method of meter terminal based on improved deep learning[J]. Electric Engineering, 2020(10): 36-39(in Chinese).
- [49] 高嵩,陆倚鹏,王笑倩,等. 基于深度学习的悬式瓷绝缘子红外图像识别方法[J]. 电力科学与技术学报,2020,35(5):119-125.
GAO Song, LU Yipeng, WANG Xiaoqian, et al. Infrared image recognition method of porcelain disc-suspended insulators based on deep learning technology[J]. Journal of Electric Power Science and Technology, 2020, 35(5): 119-125(in Chinese).
- [50] 张骥,余娟,汪金礼,等. 基于深度学习的输电线路外破图像识别技术[J]. 计算机系统应用,2018,27(8):176-179.
ZHANG Ji, YU Juan, WANG Jinli, et al. Image recognition technology for transmission line external damage based on depth learning[J]. Computer Systems & Applications, 2018, 27(8): 176-179 (in Chinese).
- [51] 郑含博,李金恒,刘洋,等. 基于改进YOLOv3的电力设备红外目标检测模型[J]. 电工技术学报,2021,36(7):1389-1398.
ZHENG Hanbo, LI Jinheng, LIU Yang, et al. Infrared object detection model for power equipment based on improved YOLOv3 [J]. Transactions of China Electrotechnical Society, 2021, 36(7): 1389-1398(in Chinese).
- [52] 李文璞,毛颖科,廖道,等. 基于旋转目标检测的变电设备红外图像电压致热型缺陷智能诊断方法[J]. 高电压技术,2021,47(9):3246-3253.
LI Wenpu, MAO Yingke, LIAO Xiao, et al. Intelligent diagnosis method of infrared image for substation equipment voltage type thermal defects based on rotating target detection[J]. High Voltage Engineering, 2021, 47(9): 3246-3253(in Chinese).
- [53] 苏海锋,赵岩,武泽君,等. 基于改进RetinaNet的电力设备红外目标精细化检测模型[J]. 红外技术,2021,43(11):1104-1111.
SU Haifeng, ZHAO Yan, WU Zejun, et al. Refined infrared object detection model for power equipment based on improved RetinaNet [J]. Infrared Technology, 2021, 43(11): 1104-1111(in Chinese).
- [54] 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).
- [55] 律方成,牛雷雷,王胜辉,等. 基于优化YOLOv4的主要电气设备智能检测及调参策略[J]. 电工技术学报,2021,36(22):4837-4848.
LÜ Fangcheng, NIU Leilei, WANG Shenghui, et al. Intelligent detection and parameter adjustment strategy of major electrical equipment based on optimized YOLOv4[J]. Transactions of China Electrotechnical Society, 2021, 36(22): 4837-4848(in Chinese).
- [56] 马鹏,樊艳芳. 基于深度迁移学习的小样本智能变电站电力设备部件检测[J]. 电网技术,2020,44(3):1148-1159.
MA Peng, FAN Yanfang. Small sample smart substation power equipment component detection based on deep transfer learning[J]. Power System Technology, 2020, 44(3): 1148-1159(in Chinese).
- [57] 王旭红,李浩,樊绍胜,等. 基于改进SSD的电力设备红外图像异常自动检测方法[J]. 电工技术学报,2020,35(S1):302-310.
WANG Xuhong, LI Hao, FAN Shaosheng, et al. Infrared image anomaly automatic detection method for power equipment based on improved single shot multi box detection[J]. Transactions of China Electrotechnical Society, 2020, 35(S1): 302-310(in Chinese).
- [58] 张殊,王昊天,董骁翀,等. 基于深度学习的输电线路螺栓检测技术[J]. 电网技术,2021,45(7):2821-2828.
ZHANG Shu, WANG Haotian, DONG Xiaochong, et al. Bolt detection technology of transmission lines based on deep learning[J]. Power System Technology, 2021, 45(7): 2821-2828(in Chinese).
- [59] 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).
- [60] 付晶,邵瑰玮,吴亮,等. 利用层次模型进行训练学习的线路设备缺陷检测方法[J]. 高电压技术,2017,43(1):266-275.
FU Jing, SHAO Guiwei, WU Liang, et al. Defect detection of line facility using hierarchical model with learning algorithm[J]. High Voltage Engineering, 2017, 43(1): 266-275(in Chinese).
- [61] 吴巍,郭飞,郭毓,等. 一种基于全卷积神经网络的横担姿态测量方法[J]. 华中科技大学学报(自然科学版),2018,46(12):106-111.
WU Wei, GUO Fei, GUO Yu, et al. Attitude measurement for cross arm based on fully convolutional network[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(12): 106-111(in Chinese).
- [62] 黄志文,张学习. 输电线路杆塔横担处的螺栓缺陷检测技术研究[J]. 工业控制计算机,2017,30(6):1-3,6.
HUANG Zhiwen, ZHANG Xuexi. Research on bolt defect detection technology of transmission tower[J]. Industrial Control Computer, 2017, 30(6): 1-3, 6(in Chinese).
- [63] 薛阳,吴海东,张宁,等. 基于改进Faster R-CNN输电线路穿刺线夹及螺栓的检测[J]. 激光与光电子学进展,2020,57(8):081008.
XUE Yang, WU Haidong, ZHANG Ning, et al. Detection of insulation piercing connectors and bolts on the transmission line using improved faster R-CNN[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081008(in Chinese).
- [64] 张永翔,吴功平,刘中云,等. 基于YOLOv3网络的输电线路防震锤和线夹检测迁移学习[J]. 计算机应用,2020,40(S2):188-194.
ZHANG Yongxiang, WU Gongping, LIU Zhongyun, et al. Transfer learning of transmission line damper and clamp detection based on YOLOv3 network[J]. Journal of Computer Applications, 2020, 40 (S2): 188-194(in Chinese).
- [65] PAN S J, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [66] VANSCHOREN J. Meta-learning: a survey[J]. arXiv: 1810.03548, 2018.
- [67] 史晋涛,李喆,顾超越,等. 基于样本扩充的Faster R-CNN电网异物监测技术[J]. 电网技术,2020,44(1):44-51.
SHI Jintao, LI Zhe, GU Chaoyue, et al. Research on foreign matter monitoring of power grid with faster R-CNN based on sample expansion[J]. Power System Technology, 2020, 44(1): 44-51(in Chinese).

- Chinese).
- [68] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6(1):60.
- [69] 刘洪宇, 杨林, 姜蕾. 恶劣环境下图像算法数据增强方法[J]. 计算机工程与设计, 2021, 42(9):2545-2551.
LIU Hongyu, YANG Lin, JIANG Lei. Data augmentation in harsh environments for computer vision algorithms[J]. Computer Engineering and Design, 2021, 42(9):2545-2551(in Chinese).
- [70] OKSUZ K, CAM B C, KALKAN S, et al. Imbalance problems in object detection: a review[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10):3388-3415.
- [71] ZHENG Suncong, WANG Feng, BAO Hongyun, et al. Joint extraction of entities and relations based on a novel tagging scheme [C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. Vancouver:ACL, 2017:1227-1236.
- [72] WÜRFL T, HOFFMANN M, CHRISTLEIN V, et al. Deep learning computed tomography: learning projection-domain weights from image domain in limited angle problems[J]. IEEE Transactions on Medical Imaging, 2018, 37(6):1454-1463.
- [73] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. 软件学报, 2021, 32(4):1201-1227.
CHEN Keqi, ZHU Zhiliang, DENG Xiaoming, et al. Deep learning for multi-scale object detection: a survey[J]. Journal of Software, 2021, 32(4):1201-1227(in Chinese).
- [74] DENTON E, CHINTALA S, SZLAM A, et al. Deep generative image models using a laplacian pyramid of adversarial networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal: MIT Press, 2015:1486-1494.
- [75] SADR H, PEDRAM M M, TESHNEHLAB M. Multi-view deep network: a deep model based on learning features from heterogeneous neural networks for sentiment analysis[J]. IEEE Access, 2020, 8:86984-86997.
- [76] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(1):318-327.
- [77] 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, 2015, 37(9):1904-1916.
- [78] 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. Barcelona:Curran Associates Inc., 2016:379-387.
- [79] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu:IEEE, 2017.
- [80] WANG R J, LI Xiang, LING C X. Pelee: a real-time object detection system on mobile devices[C]//Proceedings of the 32nd Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018.
- [81] HE Kaiming, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2):386-397.
- [82] QIN Zheng, LI Zeming, ZHANG Zhaoning, et al. ThunderNet: towards real-time generic object detection on mobile devices[C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South):IEEE, 2019.
- [83] LAW H, DENG Jia. CornerNet: detecting objects as paired keypoints [J]. International Journal of Computer Vision, 2020, 128(3):642-656.
- [84] HUANG Lichao, YANG Yi, DENG Yafeng, et al. DenseBox: unifying landmark localization with end to end object detection[J]. arXiv:1509.04874, 2015.
- [85] CHEN Ran, LIU Yong, ZHANG Mengdan, et al. Dive deeper into box for object detection[C]//Proceedings of the 16th European Conference on Computer Vision. Glasgow:Springer, 2020:412-428.
- [86] GE Zheng, LIU Songtao, WANG Feng, et al. YOLOX: exceeding YOLO series in 2021[J]. arXiv:2107.08430, 2021.
- [87] QIU Xipeng, SUN Tianxiang, XU Yige, et al. Pre-trained models for natural language processing: a survey[J]. Science China Technological Sciences, 2020, 63(10):1872-1897.
- [88] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. arXiv:1503.02531, 2015.
- [89] LIU Rui, SISMAN B, LI Jingdong, et al. Teacher-Student training for robust tacotron-based TTS[C]//Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona:IEEE, 2020.
- [90] 曾春艳, 严康, 王志锋, 等. 深度学习模型可解释性研究综述[J]. 计算机工程与应用, 2021, 57(8):1-9.
ZENG Chunyan, YAN Kang, WANG Zhifeng, et al. Survey of interpretability research on deep learning models[J]. Computer Engineering and Applications, 2021, 57(8):1-9(in Chinese).
- [91] 成科扬, 王宁, 师文喜, 等. 深度学习可解释性研究进展[J]. 计算机研究与发展, 2020, 57(6):1208-1217.
CHENG Keyang, WANG Ning, SHI Wenxi, et al. Research advances in the interpretability of deep learning[J]. Journal of Computer Research and Development, 2020, 57(6):1208-1217(in Chinese).



李运硕

收稿日期: 2022-05-07。

作者简介:

李运硕(1986), 男, 高级工程师, 研究方向为基于人工智能与大数据分析的配网工程管理;

段祥骏(1980), 男, 高级工程师, 研究方向为配网自动化与配网工程管理等;

李佳(1995), 女, 工程师, 研究方向为配电自动化与配网工程管理;

林奕夫(1992), 男, 工程师, 研究方向为电气工程及其自动化;

任敬飞(1984), 男, 高级工程师, 研究方向为配电网工程建设管理;

杨婷(1986), 工程师, 通信作者, 研究方向为智能电网, annayang_1986@163.com。

(责任编辑 刘雪莹)