



运营技术广角

电网机巡图像分析框架与深度学习方法

李远宁¹, 宁柏锋², 董召杰¹

(1. 南方电网数字电网研究院, 广东 广州 511458;

2 深圳供电局有限公司, 广东 深圳 518000)

摘要: 随着智能制造与物联网技术的发展, 无人机被电网企业广泛地应用于输电线路巡视检查, 同时也产生了大量的巡检图像数据亟需分析与处理。针对机巡图像分析中面临的多类多尺度、光照变化及遮挡等挑战, 设计了一套从用户数据归集、分析与自动标注到用户评价反馈的 U2U 图像分析框架, 在此基础上研究了 Faster R-CNN 和 SSD 两种深度学习方法在绝缘子、防震锤、均压环、屏蔽环等电力部件检测中的应用, 提出了基于 K -means++ 聚类分析的兴趣对象锚点信息框设定方法。实验结果表明, 本文提出的方法有效地提高了深度学习方法对多尺度兴趣部件的适应能力与检测精度, 为后续更大规模的机巡图像缺陷检测及机巡深化应用提供了有益的借鉴。

关键词: 智能电力系统; 深度学习; 多部件检测; 无人机

中图分类号: TP183

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020056

Patrol image analysis framework and deep learning method for power grid

LI Yuanning¹, NING Baifeng², DONG Zhaojie¹

1. Digital Grid Research Institute, China Southern Power Grid, Guangzhou 511458, China

2. Shenzhen Power Supply Co, Ltd., Shenzhen 518000, China

Abstract: With the development of intelligent manufacturing and IoT, UAV has been widely utilized by power grid enterprise in patrolling transmission lines. At the same time, massive patrol image data need to be analyzed urgently. A U2U image analysis framework was designed from user data collection, automatic annotation and to user feedback. Two deep learning methods, which were faster R-CNN and SSD, were explored and applied in U2U to detect five types of power components, including insulators, dampers, grading rings and shielding rings. A refining method based on K -means++ was proposed for the parameters of anchor box. Experimental results demonstrate that the proposed methods can effectively improve the adaptability and detection accuracy of deep learning method for multiple-scale power components and provide a useful reference for subsequent defect detection and deep application of UAV patrolling.

Key words: intelligent power system, deep learning, multiple-component detection, UAV



1 引言

随着智能制造与物联网技术的发展^[1], 无人机 (unmanned aerial vehicle, UAV) 已被电网企业广泛地应用于输电线路巡视检查。以南方某电网企业为例, 无人机巡检已覆盖 80% 的 110 kV 线路, 100% 覆盖 220 kV 及以上线路^[2]。相比人工巡检, 无人机巡检具有工作高效便捷、不易受地域影响、安全可靠高等优点。然而无人机巡检在电网企业的广泛应用, 也产生了大量的巡检图像数据亟需分析与处理。依靠电网运维人员手动分析巡检图像数据不仅耗时耗力, 而且对缺陷的漏检与误检容易受主观意识、技能与经验不足等因素影响^[3]。因此, 围绕无人机机巡图像数据开展自动化分析, 并利用机器视觉分析方法提升故障识别效果已成为智能电网运维检修的研究与应用热点之一。

目前, 机巡图像自动化分析方法主要划分为人工特征分析方法和深度学习方法两种。其中, 人工特征分析方法主要针对图像局部提取轮廓、颜色、纹理信息, 通过机器视觉专家提前设计的局部特征提取算法 (如 HOG^[4]、SIFT^[5]、SURF^[6]、Haar^[7]等) 获得图像高级特征, 并结合分类器或回归算法实现兴趣部件的自动检测。参考文献[8]提出一种基于局部轮廓特征的对象识别方法, 开展均压环部件识别, 但该方法对拍摄角度有严格要求。参考文献[9]基于形态学特征、不变矩特征与 Adaboost 分类器开展绝缘子检测, 并在简单杆塔背景下验证了检测效果。现有机器视觉研究表明^[10], 人工设计特征分析方法只能针对特定场景与目标分析, 其泛化能力还有待进一步提升。

深度学习方法自主学习数据深层次抽象特征, 具有较强的检测性能与泛化能力, 是人工神经网络的重要分支。从 2012 年 Hinton 带领的课题组赢得 ImageNet^[10]挑战赛以来, 以卷积神经网络

(CNN) 为代表的深度学习方法已在图像分类、兴趣对象检测等研究领域取得突破性进展。2014 年, Girshick^[11]提出了基于区域卷积网络的深度学习框架 R-CNN。随后出现了许多改进网络, 例如 Faster R-CNN^[12]、YOLO^[13]、SSD^[14]等, 兴趣对象检测性能与效率取得了不同程度的提高。在机巡输电线路部件检测领域, 参考文献[15]对比了 Faster R-CNN 与 DPM^[16]、SPPnet^[17]在间隔棒、防震锤、均压环上的检测效果, 但部件尺度与网络参数优化有待进一步深入探讨。参考文献[18]采用了 3 种预训练网络初始化 Faster R-CNN, 并在均压环、防震锤、鸟巢部件上验证了单目标检测效果。在机巡图像分析领域, 多尺度多目标检测的实用性有待进一步探讨。

机巡图像分析主要面临以下几方面的挑战: 兴趣部件类别众多, 但可供训练的样本数量不充分; 兴趣部件尺度变化大, 例如大尺度的鸟巢、绝缘子以及小尺度的金具螺栓; 图像质量易受大气环境、光照、遮挡等影响; 图像背景复杂、易受伪目标干扰。这些挑战增加了机巡巡检图像分析与异常检测的难度。

针对上述挑战, 本文设计了一套从用户数据样本归集、兴趣内容标注、模型训练、内容分析与自动标注到用户评价反馈的闭环 U2U 分析框架, 借助用户反馈与增量学习缓解了训练样本不充分问题。针对机巡图像多尺度多目标分析, 研究了两种深度学习方法在输电线路多部件自动检测上的应用, 并提出了基于 K-means++^[19]聚类分析的兴趣对象锚点信息框 (anchor box) 设定方法, 有效提高了兴趣对象尺度适应能力。

2 机巡图像分析框架

利用数据驱动的机器视觉分析方法开展机巡图像自动化分析, 机巡图像样本归集与维护是重要的前置条件。无论是人工特征分析方法还是深

度学习方法,都需要具备一定规模的包含图像样本及精细标注的集合作为分析模型训练输入。因此,本文提出了一个从用户数据样本归集、兴趣内容标注、模型训练、内容分析与自动标注到用户评价反馈的 U2U 闭环分析框架,如图 1 所示。

在训练阶段,首先对接机巡作业管理系统,实现用户历史数据归集,并结合输电线路缺陷分析报告开展机巡图像数据的兴趣部件与缺陷手工标注。最终形成企业级机巡图像训练样本库,为不同的图像深度学习模型训练提供支撑。基于 U2U 分析框架,可以进一步地应用和探索适用于机巡图像分析应用场景的机器视觉分析方法。

在测试与应用阶段,借助机巡图像分析模型对增量数据进行自动标注,实现兴趣部件的自动检测,并生成缺陷隐患报告。用户围绕分析结果进行评估,并将最终确认结果反馈给样本库,从而实现训练样本的不断补充与完善。相应地,基于增量更新地训练样本库,不断地优化机巡图像分析模型,从而缓解个别部件训练样本不充分带来的影响。

3 机巡图像分析模型

3.1 基于 Faster R-CNN 的兴趣部件检测

在机巡图像分析模型训练过程中,本文首先

采用 Faster R-CNN^[12]验证探索深度学习方法在多尺度多类别兴趣对象检测中的有效性与泛化能力。Faster R-CNN 采用区域提议网络(region proposal network, RPN)代替选择性搜索算法产生候选兴趣对象锚点信息框,模型分析检测速度较 Fast R-CNN^[20]取得了大幅提升。

Faster R-CNN 整体网络结构如图 2 所示,以 VGG16^[21]为预训练卷积网络(共有 13 个卷积层,4 个池化层),提取输入图像 1/16 的特征图并提交区域提议网络和 ROI(region of interest)池化层进行处理。区域提议网络是一个全卷积网络,用于生成候选兴趣对象区域。特征图通过区域提议网络的卷积运算得到一定数量的锚点信息框,并通过两个处理分支获取筛选并确定有效锚点信息框信息。其中,一个处理分支对所有锚点信息框筛选过滤,根据锚点信息框与真实目标框(ground truth, GT)的重叠度(intersection over union, IOU)值标记前景与背景;另一个分支计算锚点信息框与真实目标框之间的偏移量,利用偏移量学习,预测锚点信息框参数。最后汇总两个分支,利用非极大值抑制(non maximum suppression, NMS)算法筛选,取置信度较高的前 300 个候选兴趣对象区域送入 ROI 池化层。ROI 池化层将候选兴趣对象区域对应的特征块映射成




图 1 U2U 机巡图像分析框架




图2 Faster R-CNN 网络框架

一个固定尺度的特征向量，作为下一层全连接层（full connected layer, FC）的输入。全连接层通过 softmax 函数计算每个 ROI 特征向量的具体兴趣部件的概率，同时对候选兴趣区域边框回归获得更精确的目标框。

3.2 基于 SSD 的兴趣部件检测

以 Faster R-CNN 为代表的 two-stage 分析方法首先产生候选区域，然后对候选区域进行分类与边框回归。这种方法在兴趣对象检测与定位的准确率上存在优势，但其分析与处理速度难以满足实时分析要求。因此，本文进一步验证与探索 SSD 在实时机巡图像分析中的效果，引入 Faster R-CNN 中的锚点机制，将本文分类与边框回归集成为一个网络中进行端到端中的处理，检测速度获得显著提升。

SSD 包括 SSD300 和 SSD512 两种模型，分别对应 300 像素×300 像素和 512 像素×512 像素两种输入图像尺寸。图 3 描述了 SSD300 的具体网络结构。SSD300 采用 VGG16 为基础网络，修改全连接层 FC6 和 FC7 为卷积层 conv6 和 conv7，移

除 FC8 和所有 dropout 层，额外添加 4 个卷积层用于构造特征金字塔。SSD300 在 6 个特征图（conv4_3、conv7、conv8_2、conv9_2、conv10_2、conv11_2）的每个点上构造不同尺寸的锚点信息框，每个锚点信息框都输出兴趣部件的置信度和相对于默认框的位置偏移量。SSD 网络中特征图尺寸越大，感受野越小，可检测到的目标越小。因此多尺寸的特征图配合多尺寸的锚点信息框，基本可覆盖机巡图像中各种形状和尺度的兴趣目标，从而达到对原图多尺度分析的效果。

3.3 兴趣部件尺度适应

为进一步提升机巡图像分析对兴趣部件尺度变化的适应，本文利用 K -means++^[19] 聚类分析方法对兴趣对象锚点信息框进行设定。目标框尺寸分布如图 4 所示，可以看出，兴趣部件的目标框分布集中在 X 轴与 Y 轴附近，长宽比集中在 1:1~4:1。Faster R-CNN 和 SSD 通过锚点信息框捕捉兴趣目标的形状和尺度变化。根据图 4 中目标框信息得到 7 个聚类中心，对应锚点尺度分别为 [8,18,39,61,81,102,113]。考虑机巡图像分析中小尺




图3 SSD300 网络结构

度目标较多,因此在后续实验中选取前 5 个尺度,对特征图上每个滑动窗口的不同尺度生成宽长比分别为 1:1、1:2、1:4、2:1、4:1 共 25 个候选锚点信息框。




图 4 目标框尺寸分布

4 实验分析

4.1 实验环境与模型参数设置

本文使用基于 TensorFlow 框架的 Faster R-CNN 和 SSD 模型,所有结果均在同一台服务器上实现,操作系统为 64 位 Ubuntu16.04, GPU 型号为 NVIDIA Titan X (12 GB 显存)。实验先后使用了 ILSVRC-2012 分类任务中预训练的 VGG16^[21]、ResNet^[22]、MobileNet^[23]初始化 Faster R-CNN。训练前利用第 3.3 节介绍的方法设定兴趣目标面积与长宽比,并修改锚点信息框。定义模型结构后,使用反向传播和随机梯度下降算法端到端训练网络,部分参数设置如下。

- 初始化学习率 0.002,迭代次数为 10 000,

调优阶段将学习率减小至当前的 1/10。

- 训练批次大小 (batch size) 设置为 128 (单位为个,表示一次性选取 128 个样本训练),每个最小批次 (mini-batch) 选取两个样本,以缓解正样本不足的问题。
- 锚点信息框长宽比 (anchor box ratio) 设置为 [0.25,0.5,1,2,4], 尺度设置为 [8,18,39,61,81]。
- 为防止由于绝缘子串局部与整体的相似性导致的误检现象,将非极大值抑制算法阈值调整为 0.3。

4.2 实验数据集

实验研究所使用数据均由输电线路巡检过程中无人机沿线实景拍摄,共包含 12 条输电线路、4 399 张图片,拍摄时间、角度、距离不尽相同,每张图片都包含玻璃绝缘子、复合绝缘子、均压环、防震锤、屏蔽环中的一类或多类目标,筛选连拍和模糊图片之后,剩下 3 781 张用于构造样本。

无人机航拍图像分辨率较高,直接将图像输入网络,卷积计算时间复杂度大,从 3 781 张原图中裁剪出感兴趣区域后,统一缩放至 512 像素×512 像素,并对其中所有人眼可视的清晰目标外围进行人工标注(包括遮挡与不完整目标),共生成 9 636 个目标框,其中,最小像素面积为 90,最大像素面积为 230 418,绝缘子框共 5 131 个,占比超过 50%,屏蔽环框共 243 个,样本数量较少,实验随机选取 70%的图片用作训练集,剩下 30%用作测试集,表 1 为具体样本信息。

表 1 训练集与测试集样本信息

目标类别	玻璃绝缘子	复合绝缘子	均压环	防震锤	屏蔽环
目标数量/个	train 2 257	1 316	1 109	1 937	166
	test 1 050	508	454	762	77

图 5 为部分实验样本,其中,图 5 (a)~(b) 为原图与裁剪缩放之后的样本图,实验要求尽量同时检测如图 5 (c)~(d) 所示的包括被遮挡和



重叠的各类目标,并在图 5 (e) ~ (f) 中目标密度高、背景复杂等情况下达到较好的效果。为进一步弱化训练样本规模与质量对模型分析性能的影响,在模型训练过程中以 0.5 的概率对训练图片进行随机裁剪、左右翻转、顺时针 90° 旋转、高斯噪声、色彩失真 5 种变换,增强了模型的稳健性,以便在自然条件下能达到更好的预测效果。

4.3 实验结果及分析

本文以 VGG16 为基础特征提取网络对比了 Faster R-CNN 和 SSD 两种深度学习方法的性能,具体见表 2。同一个测试集下,SSD 整体分类效果略低于 Faster R-CNN,SSD512 仅在屏蔽环上的分类精度比 Faster R-CNN 高出 4%。主要原因在于 SSD 网络在深层特征图上产生预测框,感受野相对较大。由于取消了区域提议,实验测试在输入为 300×300 时,SSD 能以 23 f/s 接近实时处理的速度分析无人机巡检数据。

实验以 Res152 为基础网络,对比不同锚点发现(表 3 中锚点 1 为参考文献[20]中默认参数,锚点 3 为本文实验所用参数),优化锚点设置可以更好地适应机巡图像数据。由于区域提议网络固定输出 300 个候选框,所以锚点数量变化对测试时间影响不大。设置输出置信度阈值为 0.7,部分测试结果如图 6 所示,分析模型较精确的检测兴




图 5 部分训练样本



图 6 Faster R-CNN 上的部分测试结果

表 2 模型对比试验

对比项	玻璃绝缘子	复合绝缘子	均压环	防震锤	屏蔽环	mAP	f/s
Faster R-CNN	90.2%	90.2%	90.1%	89.4%	83.4%	88.7%	9
SSD-300	87.7%	81.9%	82.8%	81.4%	85.7%	83.9%	23
SSD-512	89.2%	81.5%	83.7%	82.9%	87.9%	85.0%	13

表 3 锚点对比实验

对比项	锚点 1	锚点 2	锚点 3
玻璃绝缘子	90.2%	90.3%	90.8%
复合绝缘子	90.2%	89.6%	91.1%
均压环	89.2%	89.7%	90.3%
防震锤	89.4%	89.6%	90.4%
屏蔽环	73.2%	79.1%	88.7%
mAP	86.4%	87.6%	90.3%
f/s	9.9	7.8	8.1

趣部件。图 7 为测试集上的精准率-召回率 (precision-recall) 曲线。

锚点 1: 长宽比设置为[0.5, 1, 2]尺度设置为[8, 16, 32]。

锚点 2: 长宽比设置为[0.25, 0.5, 1, 2, 4] 尺度设置为[8, 16, 32]。

锚点 3: 长宽比设置为[0.25, 0.5, 1, 2, 4] 尺度设置为[8, 18, 39, 61, 81]。

实验接着使用 ResNet、MobileNet 等不同的预训练模型作为 Faster R-CNN 的基础网络, 在参数相同的条件下对比了各类目标的平均精度 (AP) 和平均精度均值 (mAP)。从表 4 的统计结果可以看出, 特征提取网络越复杂, f/s 越小, 分类效果越好, 其中, ResNet152 在玻璃绝缘子和屏蔽环上的测试效果明显优于其他模型, 由于屏蔽环只占总样本的 2.5%, 网络难以学习到足够的特征, 所以屏蔽环的精度是所有部件中最低的。




图 7 精准率-召回率曲线图

表 4 特征提取网络对比实验

对比项	vgg16	res50	res101	res152	mobile
玻璃绝缘子	90.2%	89.8%	90.1%	90.8%	86.1%
复合绝缘子	90.2%	90.0%	90.4%	91.1%	85.5%
均压环	90.1%	89.5%	89.4%	90.3%	88.2%
防震锤	89.4%	89.7%	90.1%	90.4%	87.7%
屏蔽环	83.8%	85.6%	86.1%	88.7%	59.4%
mAP	88.7%	88.9%	89.2%	90.3%	81.4%
f/s	9.4	10.0	8.9	8.1	10.2

5 结束语

本文围绕机巡图像自动化分析应用场景, 提出了 U2U 的分析框架。针对兴趣部件样本有限、尺度不一、背景复杂等问题, 将 Faster R-CNN 和 SSD 模型应用到 U2U 分析框架, 可精确检测机巡图像中出现的玻璃绝缘子、复合绝缘子、防震锤、均压环、屏蔽环等部件, 为后续更大规模的缺陷检测及系统化应用提供基础。本文提出通过聚类分析方法自动化设定 Faster R-CNN 中的锚点信息框参数, 可以有效地提高分析模型对多尺度部件的适应性及检测精度。本文分析了不同特征提取网络与参数对 Faster R-CNN 检测结果的影响, 实验表明在不过拟合的条件下, 基础网络越复杂, 提取的特征越抽象, 平均精度均值越高。

为推进智能电网的发展, 下一步将对样本库进行扩充完善, 构建输电线路部件缺陷数据集, 实现更大应用范围的输电线路智能故障诊断, 并从网络结构出发对 SSD 模型进行改进, 实现无人机巡检视频数据实时分析。

参考文献:

- [1] 王志宏, 杨震. 人工智能技术研究及未来智能化信息服务体系的思考[J]. 电信科学, 2017, 33(5): 1-11.
WANG Z H, YANG Z. Research on artificial intelligence technology and the future intelligent information service architecture[J]. Telecommunications Science, 2017, 33(5): 1-11.
- [2] 窦兰秋. 浅谈高压输电线路设计工作中应注意的要点[J]. 通



- 讯世界, 2016(10): 203-204.
- DOU L Q. Talking about the key points in the design of high voltage transmission line[J]. Communication World, 2016(10): 203-204.
- [3] 赵振兵, 孔英会, 戚银城, 等. 面向智能输变电的图像处理技术[M]. 北京: 中国电力出版社, 2014.
- ZHAO Z B, KONG Y H, QI Y C, et al. Image processing technology for intelligent power transmission and transformation[M]. Beijing: China Electric Power Press, 2014.
- [4] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]// International Conference on computer vision & Pattern Recognition (CVPR'05). Piscataway: IEEE Press, 2005: 886-893.
- [5] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [6] BAY H, ESS A, TUYTELAARS T, et al. Speeded-up robust features (SURF)[J]. Computer Vision and Image Understanding, 2008, 110(3): 346-359.
- [7] LIENHART R, MAYDT J. An extended set of haar-like features for rapid object detection[C]//International Conference on Image Processing. Piscataway: IEEE Press, 2002.
- [8] 翟永杰, 王迪, 伍洋, 等. 基于骨架提取的航拍绝缘子图像分步识别方法[J]. 华北电力大学学报(自然科学版), 2015, 42(3): 105-110.
- ZHAI Y J, WANG D, WU Y, et al. Multistep recognition method of aerial insulator image based on skeleton extraction[J]. Journal of North China Electric Power University (Natural Science), 2015, 42(3): 105-110.
- [9] 班孝坤, 韩军, 陆冬明, 等. 自然场景中基于局部轮廓特征类圆对象识别方法[J]. 计算机应用, 2016, 36(5): 1399-1403.
- BAN X K, HAN J, LU D M, et al. Circle like object recognition method based on local contour feature in natural scene[J]. Computer Application, 2016, 36(5): 1399-1403.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]// Neural Information Processing Systems. Piscataway: IEEE Press, 2015.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition. [S.l.:s.n.], 2016: 779-788.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// European Conference on Computer Vision. Piscataway: IEEE Press, 2016: 21-37.
- [15] 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 W G, TIAN B, LIU Y, et al. Research on recognition of power widget in UAV Inspection Image based on RCNN[J]. Journal of Earth Information Science, 2017, 19(2): 256-263.
- [16] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1627-1645.
- [17] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [18] 汤踊, 韩军, 魏文力, 等. 深度学习在输电线路中部件识别与缺陷检测的研究[J]. 电子测量技术, 2018, 41(6): 60-65.
- TANG Y, HAN J, WEI W L, et al. Research on component identification and defect detection in transmission line based on deep learning[J]. Electronic Measurement Technology, 2018, 41(6): 60-65.
- [19] ARTHUR D, VASSILVITSKII S. K-means++: the advantages of careful seeding[C]// The Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. New York: ACM Press, 2007.
- [20] GIRSHICK R. Fast R-CNN[C]// The IEEE International Conference on Computer Vision (ICCV). [S.l.:s.n.], 2015.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv: 1409.1556, 2014.
- [22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. arXiv:1512.03385.
- [23] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[Z]. 2017.

[作者简介]



李远宁(1981—), 男, 博士, 南方电网数字电网研究院高级工程师, 主要研究方向为电力大数据、人工智能、信息化。

宁柏锋(1983—), 男, 深圳供电局有限公司高级工程师, 主要研究方向为电力信息化、电网故障诊断。

董召杰(1985—), 男, 南方电网数字电网研究院高级工程师, 主要研究方向为电力信息化、人工智能。