第 49 卷 第 1 期：294-300 高电压技术 Vol.49, No.1: 294-300
2023 年 1 月 31 日 High Voltage Engineering January 31, 2023
DOI: 10.13336/j.1003-6520.hve.20220334

航拍绝缘子自爆缺陷的轻量化检测方法

贾晓芬[1,2]，于业齐[1]，郭永存[2]，黄友锐[1]，赵佰亭[1]
（1. 安徽理工大学电气与信息工程学院，淮南 232001；
2. 安徽理工大学省部共建深部煤矿采动响应与灾害防控国家重点实验室，淮南 232001）

摘　要：为了精准识别、定位架空输电线路中航拍绝缘子串的自爆缺陷，提出一种轻量化检测方法 MDD-YOLOv3。首先将 YOLOv3 主干网络残差单元中的普通卷积替换为深度可分离卷积，设计主干网络 D-Darknet53，在网络检测精度微降的情况下，大幅提升网络的检测速度。特征挖掘模块中，设计了 Dense-SPP 模块，Dense-SPP 和它前后串联的卷积特征提取层能充分挖掘自爆缺陷的全局和局部特征，提高网络对自爆缺陷的特征表达能力。最后构建了四维度预测层，能充分提取自爆缺陷的位置、纹理和语义等信息，提高网络的小目标检测性能。仿真实验表明，MDD-YOLOv3 对绝缘子的检测精确度达到 96.1%，检测速度达到 36 帧/s，相比 YOLOv3，检测精确度和速度分别提升了 4.0%和 28.6%。研究结果证明所提方法可以在复杂背景下快速且精准的识别和定位绝缘子缺陷。
关键词：自爆缺陷；绝缘子；四维度预测；深度可分离卷积；空间金字塔池化

Lightweight Detection Method of Self-explosion Defect of Aerial Photo Insulator

JIA Xiaofen[1,2], YU Yeqi[1], GUO Yongcun[2], HUANG Yourui[1], ZHAO Baiting[1]
(1. Institute of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China;
2. State Key Laboratory of Mining Response and Disaster Prevention and Control in Deep Coal Mines, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to accurately identify and locate the self-explosion defects of aerial insulator strings in overhead transmission lines, a lightweight detection method MDD-YOLOv3 was proposed. First, the ordinary convolution in the residual unit of the YOLOv3 backbone network is replaced with a depth-wise separable convolution, and the backbone network D-Darknet53 is designed, which greatly improves the detection speed of the network when the network detection accuracy decreases slightly. In the feature mining module, the Dense-SPP module is designed. Dense-SPP and its convolutional feature extraction layer in series can fully mine the global and local features of self-explosion defects, and improve the network's feature expression ability for self-explosive defects. Finally, a four-dimensional prediction layer is constructed, which can fully extract the location, texture and semantic information of self-explosion defects, and improve the small target detection performance of the network. Simulation experiments show that the detection accuracy of MDD-YOLOv3 for insulators reaches 96.1%, and the detection speed reaches 36 frames per second. Compared with YOLOv3, the detection accuracy and speed are increased by 4.0% and 28.6%, respectively. The research results demonstrate that the proposed method can be adopted to quickly and accurately identify and locate insulator defects in complex backgrounds.
Key words: self-explosion defect; insulator; four dimensional prediction; depthwise separable convolution; spatial pyramid pooling

0　引言

随着计算机、自动化等技术的快速发展，智能电网是电网技术发展的必然趋势[1-2]。输电线路作为电网的重要组成部分，其安全稳定运行对国民经济的平稳发展具有重要作用。绝缘子是输电线路中常见电气设备之一，其长期处于相对恶劣的自然环境，容易出现自爆、锈蚀、污秽等问题[3-4]，尤其是自爆的危害性较大。因此，绝缘子定期巡检对电力系统的正常运行具有重要意义。

传统的人工绝缘子巡检方式危险系数高、效率低。随着近些年来深度学习在计算机领域的快速发

基金资助项目：安徽省自然科学基金(2108085ME158)；国家自然科学基金面上项目(52174141)；安徽高校协同创新项目(GXXT-2020-54)；安徽省重点研究与开发计划资助项目(202004a07020043)。
Project supported by Natural Science Foundation of Anhui Province (2108085ME158), National Natural Science Foundation of China (52174141), Collaborative Innovation Project in Anhui Universities (GXXT-2020-54), Key Research and Development Program Supported Projects in Anhui Province (202004a07020043).

展，利用深度学习算法部署在无人机上实现自动巡检的方式已成为主流趋势[5-6]。目前，学者研究的绝缘子自爆缺陷检测方法主要分为两类，一种是级联网络结构检测方法，此类方法检测精度高，但检测速度慢，难以满足实际应用的需求。另一种是单阶段网络结构检测，此类方法虽检测速度较快，但面对背景复杂，缺陷尺寸较小的绝缘子图像，检测效果欠佳。

在级联网络结构检测方法的研究中，Li 等通过建立语义分割和目标检测的级联网络[7]，分别在全局和局部两方面进行检测，在小目标缺陷检测方面效果较好。Tao 等针对绝缘子的定位和缺陷检测提出了一种新的深度卷积神经网络级联结构[8]，它将缺陷检测转化为两级目标检测问题，同时利用多种数据增强算法的混合使用，来解决数据集过少的问题。在单阶段网络结构检测方法研究中，鉴于 YOLO 系列目标检测网络检测速度快，能满足绝缘子自爆缺陷检测需求的优势。Yan 等采用 Focal Loss 函数和均衡交叉熵函数优化损失函数[9]，提出一种基于改进 YOLOv3 的绝缘子串诊断方法，并采用多阶段迁移学习策略训练网络。Wang 等通过改进特征提取网络[10]，以及引入双重注意力模块、空间金字塔池化模块，提出一种基于 YOLOv3 改进的绝缘子缺陷检测算法，提升了网络的特征表达能力。Gao 等采用多阶段迁移学习和余弦退火学习率衰减法提高网络检测性能[11]，并结合小目标图像超分辨率生成网络，改进了 YOLOv4 的训练策略，提高了网络识别小目标的能力。以上几种单阶段网络结构检测方法在计算机上能精准快速的检测绝缘子缺陷，但在无人机嵌入式设备中检测性能较差。

为了高效率、高精度检测绝缘子中的自爆缺陷，针对航拍绝缘子提出一种自爆缺陷的轻量化检测方法 MDD-YOLOv3。它以 YOLOv3 为基本架构[12]，提出一种轻量化的主干网络，旨在降低网络的参数量。同时，在特征融合阶段插入一个密集特征金字塔池化模块，在预测层加入一支尺度为 152×152 的预测特征层，致力于降低网络模型参数量，同时提高网络对复杂背景中微小目标的检测性能，满足实际无人机检测的要求。

1 MDD-YOLOv3 网络结构

1.1 MDD-YOLOv3 网络结构

针对绝缘子排列紧密、方向多变、自爆缺陷处面积较小、背景复杂等特点，设计了图 1 的航拍绝缘子自爆缺陷检测模型 MDD-YOLOv3，它由主干网络，特征挖掘模块和四维度预测层 3 个模块构成。

3 个模块均是以 YOLOv3 为基础网络改进得到。一是在主干网络中采用深度可分离卷积替换常规卷积，建立新主干网络 D-Darknet53，它能保证网络在检测精度略微降低的情况下，有效地减少网络模型参数量，提高网络的检测速度。二是在特征挖掘模块中，设计一种密集空间金字塔池化模块 Dense-SPP，旨在通过融合特征图局部特征和全局特征的，丰富特征图的表达能力，有效地提升网络的检测精度。三是充分利用预测特征层的浅层特征信息构建四维度预测层，提升网络对小目标的检测性能。

1.2 主干网络 D-Darknet53

考虑到网络模型需要部署到移动设备中，而嵌入式设备的存储和计算力有限，原 YOLOv3 网络在嵌入式设备中检测缓慢，难以满足绝缘子缺陷检测的速度要求。为此，提出一种轻量化的主干网络 D-Darknet53，如图 2 所示，主干网络 D-Darknet53 由 5 个残差模块 Resd$x$(x=1、2、8、8、4)组成，其中 L_1、L_2、L_3、L_4 分别为后 4 个残差模块的输出，

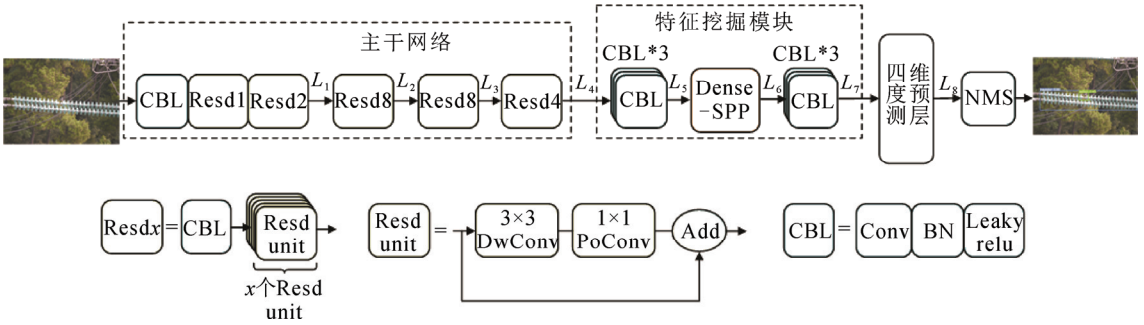


图 1 MDD-YOLOv3 网络结构

Fig.1 MDD-YOLOv3 network structure

浅层残差模块的输出特征分辨率高，几何细节信息表征能力强，但语义信息缺乏，深层残差模块的输出特征经过多次卷积下采样操作，语义信息表征能力强，但空间几何特征信息缺乏。融合深层和浅层残差模块的输出有助于实现对绝缘子串及其缺陷信息的全面检测。

每个残差模块 Resd$x$ 由 1 个 CBL(Conv+BN+Leakyrelu)和 x 个残差单元 Resd unit 组成。残差单元 Resd unit 采用深度可分离卷积替换原网络中残差单元中卷积核大小为 3×3 和 1×1 的普通卷积。深度可分离卷积 (DSConv)是将卷积分为深度卷积和点卷积两部分进行操作[13]。深度卷积(DwConv)是将每一通道作为一组，卷积核分别对每个通道进行卷积，然后再对输出特征图进行 1×1 点卷积(PoConv)，点卷积即卷积核大小为 1×1 的普通卷积。深度可分离卷积与普通卷积参数量的比例为

$$\frac{D_K \times D_K \times 1 \times M + 1 \times 1 \times M \times N}{D_K \times D_K \times M \times N} = \frac{1}{N} + \frac{1}{{D_K}^2} \quad (1)$$

式中，$D_K \times D_K \times 1 \times M$ 为深度卷积的参数量，$D_K \times D_K \times 1$ 为深度卷积的卷积核大小，M 为卷积核个数；$1 \times 1 \times M \times N$ 为点卷积的参数量，$1 \times 1 \times M$ 为点卷积的卷积核大小，N 为点卷积核个数；$D_K \times D_K \times M \times N$ 为普通卷积的参数量，$D_K \times D_K \times M$ 为普通卷积的卷积核大小，N 为普通卷积的卷积核个数。

采用卷积核大小为 3×3×1 的深度可分离卷积时，卷积核个数 N 的值远远大于 D_K，深度可分离卷积参数量约为常规卷积的 $1/9$。由此可见，在卷积核大小相同时，深度可分离卷积能大大减少网络模型的参数量，提高网络模型在无人机巡检绝缘子时的检测速度。

1.3 特征挖掘模块

绝缘子串和绝缘子串上的自爆缺陷是两种差异非常大的目标，要同时准确检测就必须有效利用 D-Darknet53 提取的细节、语义信息。为此，设计了一种密集空间金字塔池化模块 Dense-SPP，并在其前后分别串联 3 个卷积特征提取层(卷积+BN+Leaky relu)，构成了图 3 所示的特征挖掘模块，该模块能解决漏检、检测精度低的问题。

图 3 所示的 Dense-SPP 是在 SPP 模块的基础上，引入 DenseNet[14]和 SPP[15]的空间金字塔池化思想，它的特征挖掘过程为：

1）对主干网络 D-Darknet53 输出的 L_4，经过 3 个卷积特征层后，将提取的特征 L_5 输入 Dense-SPP 模块。

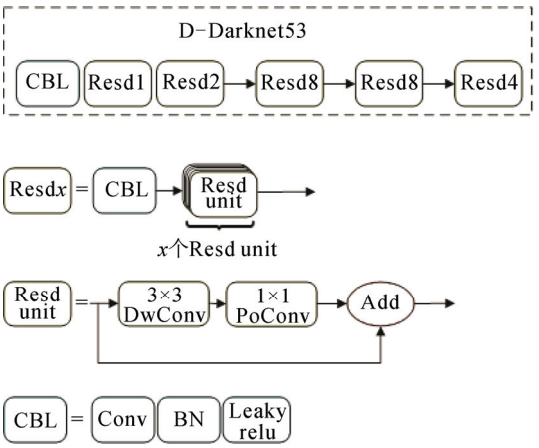


图 2 D-Darknet53 结构图

Fig.2 D-Darknet53 structure diagram

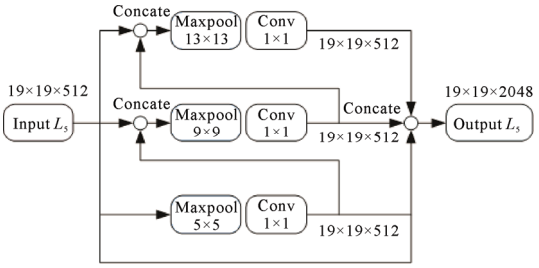


图 3 Dense-SPP 模块结构图

Fig.3 Dense-SPP Module structure diagram

2）仿照空间金字塔池化结构，将 L_5 送入 4 条并行分支，其中一条分支为跳跃连接，其余 3 条均由级联、最大池化层和 1×1 卷积层构成，3 个池化核大小分别为 5×5、9×9、13×13。

3）级联融合 4 条分支针对同一特征图提取的局部和全局特征后，得到 Dense-SPP 挖掘出的特征 L_6。

L_6 经过 3 个依次相连的卷积特征层获得特征 L_7，即为特征挖掘模块的最终输出，其中包含了绝缘子串和自爆缺陷的有效表征信息。3 条含池化层的支路中均添加了一个 1×1 卷积层，是为了便于和相邻的下一个输入层实现通道拼接。对输入的特征图 L_5 采用不同尺度的池化操作，能够提取同一特征图在不同尺度下的局部特征信息，密集连接能将上一支路提取的局部特征与输入特征 L_5 进行 concate 连接，并作为下一支路的输入，从而加强绝缘子串和其上出现的自爆点图像的局部特征与全局特征的融合，丰富特征的表达能力，提高网络模型的检测精度。

1.4 四维度预测层

无人机巡检时所拍摄的绝缘子图像的缺陷处的目标较小，分辨率低且目标所处的背景复杂，YOLOv3 算法检测时常出现漏检、定位不准的情况。为此，在 YOLOv3 网络原有的 3 个检测维度[16]基础上，添加一个 152×152 维度预测特征层，构建了图 4 所示的四维度预测层。

它的预测过程为：

1）特征挖掘模块的输出 L_7 与主干网络的 3 个残差模块的输出 $L_i(i=1,2,3)$作为四维度预测层的输入；

2）A_1 即为特征挖掘模块的输出 L_7，其他 3 支路分别由上一层经过卷积上采样操作与 $L_i(i=1,2,3)$ 进行 Concate 拼接操作，再经过 5 个卷积特征提取得到输出 $A_i(i=2,3,4)$；

3）$A_i(i=1,2,3,4)$经过两个卷积操作后，最终得到包含 4 个不同维度预测特征图 $B_i(i=1,2,3,4)$的输出 L_8；

4）将四维度预测层的输出 L_8 输入非极大值抑制算法 NMS[17]后剔除冗余框，最终得到的绝缘子缺陷检测结果。

通过添加一条维度大小为 152×152 的预测特征层 B_4，将浅层特征 L_1 的位置、细节信息与深层特征 A_3 的语义信息融合，获取小目标的位置、纹理和语义有效特征，进一步弥补特征提取过程中绝缘子缺陷处丢失的特征信息，从而提高网络对复杂背景下绝缘子缺陷小目标的检测性能。

2 实验结果与分析

2.1 实验配置与评价指标

实验在 CPU 型号为 Intel Core i7-10700k @ 3.80GHz，GPU 型号为 NVDIA GeForce RTX 2080Ti，11G 显存，32G 内存的 PC 上开展，利用 Pytorch 框架搭建模型，并使用 Cuda10.0 和 Cudnn7.6.5 对 GPU 进行加速。实验相关参数设置见表 1。选取平均精度均值 AP(mean average precision)、每秒帧数 FPS(frame per second，帧/s)和参数量 Para(parameters) 3 种客观指标衡量模型对绝缘子缺陷处的检测性能。

2.2 数据集构建

采用开源绝缘子缺陷数据集 CPLID(Chinese power line insulator dataset) 测试绝缘子缺陷检测模型，其中包含无人机拍摄的 600 张正常绝缘子图像和 248 张自爆缺陷的绝缘子图片。CPLID 中的绝缘子自爆缺陷图片较少，数据集规模不平衡，为此，添加 40 张含有自爆缺陷的绝缘子数据集。通过旋转、镜像、裁剪等图像扩充方法，最终将绝缘子数据集扩充到 4440 张，包含 3000 张正常绝缘子图片和 1440 张含有自爆缺陷的绝缘子图片。训练时将数据集按照 8:2 的比例分为训练集和验证集。

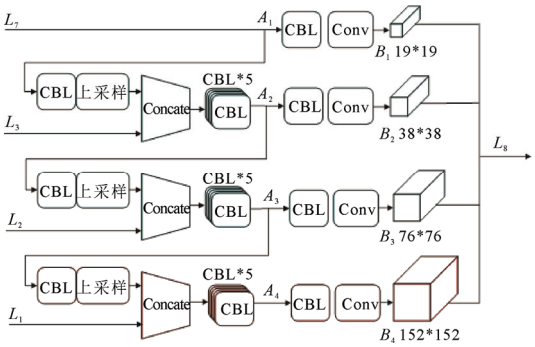


图 4 四维度预测层

Fig.4 Four scale prediction layer

表 1 实验相关参数

Table 1 Relevant parameters of the experiments

相关参数	设置值	相关参数	设置值
批处理尺寸	8	动量值	0.9
图片尺寸	608	学习率	0.001
训练周期	300	衰减系数	0.0005

2.3 网络训练

采用上述的扩充绝缘子缺陷数据集对 MDD-YOLOv3 网络进行训练。模型使用 Leaky relu 作为激活函数，它通过在函数负半段设计泄露单元有效缓解了神经元“坏死”问题。实验过程中，对控制泄露单元的参数 α 取值为 0.01，从而更有效的提取绝缘子的缺陷特征。损失函数采用原 YOLOv3 网络的损失函数，它由定位损失 l_{box}、置信度损失 l_{obj}、分类损失 l_{cls} 3 部分组成。

图 5 为 YOLOv3 和 MDD-YOLOv3 的训练损失曲线图和验证损失曲线图，可以看出 MDD-YOLOv3 网络的收敛效果更好，它的训练和验证损失的最小值比 YOLOv3 分别降低了 0.77 和 0.58。

图 6 为 YOLOv3 和 MDD-YOLOv3 的准确率曲线，可见：MDD-YOLOv3 的准确率在迭代 75 次时趋于稳定，且准确率相比于原 YOLOv3 网络有明显提升。上述结果均说明，MDD-YOLOv3 针对 YOLOv3 做出的改进策略，可以优化网络性能，提升网络检测的准确率。

2.4 实验结果与分析

2.4.1 消融实验

为了验证 MDD-YOLOv3 的有效性和合理性，在 YOLOv3 的基础上，依次加入主干网络 D-Darknet53、Dense-SPP 以及四维度预测层 3 种改进策略，在扩充数据集上开展消融实验，结果见表 2，其中“√”表示采用了对应策略。由表 2 可以看出，实验 1 是未加入改进策略的 YOLOv3 网络，其模型参数量为 23.47 MB，检测速度为 28 帧/s，绝缘子缺陷检测的 AP 值为 92.4%，实验 4 是采用了上述 3 种改进策略的 MDD-YOLOv3，其模型参数量为 13.61 MB，比 YOLOv3 下降了 42%，检测速度提升了 28.6%，AP 值比 YOLOv3 上升了 3.7%。实验 1 和 4 证明 MDD-YOLOv3 不仅降低了模型参数，还提升了模型的检测速度，能在提升模型的检测精度的前提下，满足实际应用中的实时性。

实验 2 是在 YOLOv3 的主干网络 D-Darknet53 中使用深度可分离卷积代替普通卷积，替代后的网络 AP 值比 YOLOv3 降低了 0.6%，但模型参数下降了 44%，检测速度提升了 35.7%。实验 2 以牺牲较小的检测精度为代价，大幅度降低了网络模型参数，提升了网络的检测速度。实验 3 在实验 2 的基础上加入了 Dense-SPP 模块，网络模型的参数量略微增加，AP 值较实验 2 提升了 2.3%，该效果主要源于 Dense-SPP 模块充分利用了同一特征图的多尺度信息，丰富了特征图的语义信息。实验 4 在实验 3 的基础上加入四维度预测层，在原网络 3 支预测特征层的基础上，加入一支维度为 152×152 的预测特征层，提升网络对小目标的检测精度，可以看出 AP 值与实验 3 相比增加了 2.0%。通过表 2 的实验结果可知，MDD-YOLOv3 中提出的 3 种改进策略设计合理，均有助于提升模型的检测性能，均具有较好的检测效果。

2.4.2 不同目标检测网络对比实验

消融实验充分证明了 MDD-YOLOv3 模型的合理性。为了进一步验证它的检测效果，将它和当前主流的目标检测网络 Faster R-CNN[18]、SSD[19]、RetinaNet[20]在绝缘子缺陷数据集上进行对比实验，实验结果如表 3 所示。

由表 3 可知，与经典的目标检测算法 Faster R-CNN、SSD、RetinaNet 相比，MDD-YOLOv3 的检测速度、平均准确率均为最高，模型参数量最少。以 Resnet50+FPN 为主干网络的两阶段目标检测网

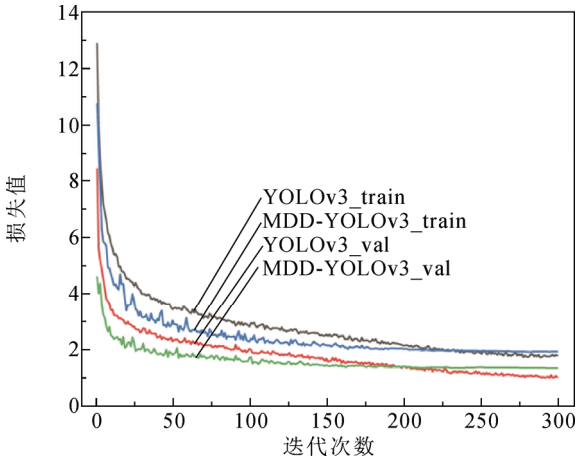


图 5 损失曲线图

Fig.5 The curve of loss

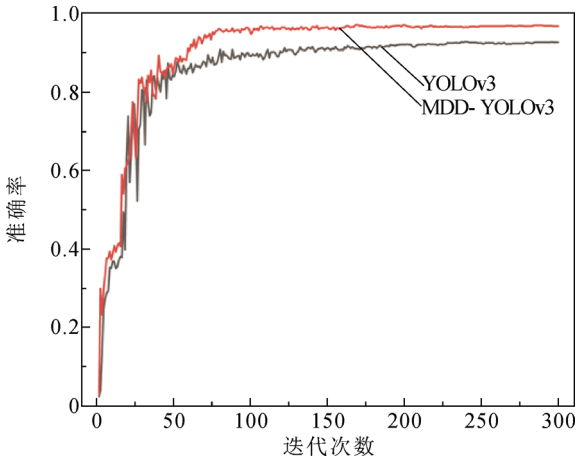


图 6 检测准确率曲线图

Fig.6 The curve of detection accuracy

表 2 消融实验结果

Table 2 Ablation experimental results

实验	D-Darknet53	Dense-SPP	四维度预测层	参数量/MB	检测速度/(帧·s^{-1})	AP 值/%
1				23.47	28	92.4
2	√			13.06	38	91.8
3	√	√		13.50	36	94.1
4	√	√	√	13.61	36	96.1

表 3 不同目标检测网络对比实验

Table 3 Comparative experiment of different target detection networks

网络模型	主干网络	参数量/MB	检测速度/(帧·s^{-1})	AP 值/%
Faster R-CNN	Resnet50+FPN	54.34	6	94.2
SSD	Resnet50	20.33	20	81.4
RetinaNet	Resnet50+FPN	40.56	11	93.9
YOLOv3	Darknet53	23.47	28	92.4
MDD-YOLOv3	D-Darknet53	13.61	36	96.1

络 Faster R-CNN 相比于传统的单阶段目标检测网络 SSD、RetinaNet、YOLOv3，其 AP 值为 94.2%，但其模型参数量较大，检测速度仅为 6 帧/s，难以满足实际应用需求。在单阶段目标检测网络中，以 Resnet50+FPN 为主干网络的 RetinaNet 的检测精度最高，检测速度为 11 帧/s，相较 SSD、YOLOv3 两种检测网络速度较慢。可见，MDD-YOLOv3 在提升网络的检测精度的同时，提高了网络的检测速度，能满足对绝缘子缺陷的实时检测需求。

为了直观展示改进网络的检测效果，图 7 给出了 YOLOv3 和 MDD-YOLOv3 的检测结果，其中①、②分别为正常和含自爆缺陷的两个横向绝缘子，③为含自爆缺陷的纵向绝缘子。可见，YOLOv3 对 2 个横向绝缘子的检测置信度均小于 0.9，对纵向绝缘子的检测置信度仅为 0.37。且存在漏检问题，YOLOv3 没有检测出②中的自爆缺陷，对③中自爆缺陷的检测置信度仅为 0.64。MDD-YOLOv3 对 3 个绝缘子的检测置信度依次为 0.91、0.97 和 0.97，它不仅准确检测出了②和③中的自爆缺陷，且检测置信度分别达到了 0.96 和 0.92。相比 YOLOv3，MDD-YOLOv3 对检测难度较大的纵向绝缘子及其自爆缺陷的检测置信度分别提高了 162.16%和 43.75%。综上，MDD-YOLOv3 不仅能高精度检测出各种角度的绝缘子，还能有效避免对自爆缺陷的漏检问题。

3 结论

1）文中针对航拍绝缘子自爆缺陷提出了轻量化检测方法 MMD-YOLOv3。设计新的主干网络 D-Darknet53，在网络检测精度仅仅降低了 0.6%的情况下，将检测速度提升了 35.7%。

2）特征挖掘模块中设计的 Dense-SPP 模块，有助于融合同一特征图的多重感受野、丰富网络特征的表达能力，其 AP 值相比之前提高了 2.3%。

3）构建的四维度预测层，能够充分利用深层的语义信息和浅层的高分辨率的特征信息，加强各级之间的融合，提高网络对小目标的检测精度，其 AP 值相比之前提高了 2.0%。

综上，通过上述 3 种改进，使得 MDD-YOLOv3 检测绝缘子自爆缺陷时的 AP 值达到了 96.1%，相比 YOLOv3 原始网络提升了 4.0%，且网络模型参数量减少了 42%，检测速度为 36 帧/s，能满足实际应用中的快速精准检测与缺陷定位的需求。



(a) YOLOv3 检测效果



(b) MDD-YOLOv3 检测效果

图 7 YOLOv3 与 MDD-YOLOv3 检测效果对比图

Fig.7 Comparison of detection effects between YOLOv3 and MDD-YOLOv3

参考文献 References

[1] 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(2)：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(2): 369-383.

[2] 隋 宇，宁平凡，牛萍娟，等. 面向架空输电线路的挂载无人机电力巡检技术研究综述[J]. 电网技术，2021，45(9)：3636-3648.
SUI Yu, NING Pingfan, NIU Pingjuan, et al. Review on mounted UAV for transmission line inspection[J]. Power System Technology, 2021, 45(9): 3636-3648.

[3] 周 宇，徐 波，宋爱国，等. 基于改进文本检测识别的绝缘子串异常定位和判别方法[J]. 高电压技术，2021，47(11)：3819-3826.
ZHOU Yu, XU Bo, SONG Aiguo, et al. Anomaly location and discrimination method of insulator string based on improved text detection and recognition[J]. High Voltage Engineering, 2021, 47(11): 3819-3826.

[4] 律方成，牛雷雷，王胜辉，等. 基于紫外成像和改进 YOLOv3 的瓷悬式绝缘子放电严重程度评估[J]. 高电压技术，2021，47(2)：377-386.
LÜ Fangcheng, NIU Leilei, WANG Shenghui, et al. Discharge severity assessment of porcelain suspension insulators based on UV images and improved YOLOv3[J]. High Voltage Engineering, 2021, 47(2): 377-386.

[5] 宁 剑，任怡睿，林济铿，等. 基于人工智能及信息融合的电力系统故障诊断方法[J]. 电网技术，2021，45(8)：2925-2933.
NING Jian, REN Yirui, LIN Jikeng, et al. Power system fault diagnosis based on artificial intelligence and information fusion[J]. Power System Technology, 2021, 45(8): 2925-2933.

[6] 邵瑰玮，刘 壮，付 晶，等. 架空输电线路无人机巡检技术研究进展[J]. 高电压技术，2020，46(1)：14-22.
SHAO Guiwei, LIU Zhuang, FU Jing, et al. Research progress in unmanned aerial vehicle inspection technology on overhead transmission lines[J]. High Voltage Engineering, 2020, 46(1): 14-22.

[7] LI X F, SU H S, LIU G H. Insulator defect recognition based on global detection and local segmentation[J]. IEEE Access, 2020, 8: 59934-59946.

[8] TAO X, ZHANG D P, WANG Z H, 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.

[9] 颜宏文，陈金鑫. 基于改进 YOLOv3 的绝缘子串定位与状态识别方法[J]. 高电压技术，2020，46(2)：423-431.
YAN Hongwen, CHEN Jinxin. Insulator string positioning and state recognition method based on improved YOLOv3 algorithm[J]. High Voltage Engineering, 2020, 46(2): 423-431.

[10] 王 凯，许 敏，孙 翔，等. 改进 YOLOv3 的绝缘子自爆缺陷检测方法[J]. 小型微型计算机系统，2022，43(12)：2564-2569.
WANG Kai, XU Min, SUN Xiang, et al. Insulator self-explosion defect detection method based on improved YOLOv3[J]. Journal of Chinese Computer Systems, 2022, 43(12): 2564-2569.

[11] 高 伟，周 宸，郭谋发. 基于改进 YOLOv4 及 SR-GAN 的绝缘子缺陷辨识研究[J]. 电机与控制学报，2021，25(11)：93-104.
GAO Wei, ZHOU Chen, GUO Moufa. Insulator defect identification via improved YOLOv4 and SR-GAN algorithm[J]. Electric Machines and Control, 2021, 25(11): 93-104.

[12] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.

[13] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 1251-1258.

[14] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]// Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 4700-4708.

[15] HE K M, ZHANG X Y, REN S Q, 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.

[16] 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. Honolulu, USA: IEEE, 2017: 2117-2125.

[17] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS-improving object detection with one line of code[C]// Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 5561-5569.

[18] REN S Q, HE K M, 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] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]// Proceedings of the 14th European Conference on Computer Vision. Amsterdam, The Netherlands: Springer, 2016: 21-37.

[20] 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, Italy: IEEE, 2017: 2980-2988.



贾晓芬
1978—，女，博士，教授
主要从事深度学习、机器学习和图像处理等方面研究
E-mail: jxfzbt2008@163.com

JIA Xiaofen
Ph.D., Professor



于业齐(通信作者)
1998—，男，硕士生
主要从事深度学习、绝缘子缺陷检测等研究
E-mail: 1771977439@qq.com

YU Yeqi
Corresponding author

收稿日期 2022-03-17 在线出版日期 2022-08-05 编辑 曹昭君