第 50 卷 第 5 期：1855-1864 高电压技术 Vol.50, No.5: 1855-1864
2024 年 5 月 31 日 High Voltage Engineering May 31, 2024
DOI: 10.13336/j.1003-6520.hve.20220387

基于改进YOLOv5-LITE轻量级的配电组件缺陷识别

颜宏文[1]，万俊杰[1]，潘志敏[2]，章健军[2]，马　瑞[3]
（1. 长沙理工大学计算机与通信工程学院，长沙 410114；2. 国网湖南超高压变电公司，长沙 410100；
3. 长沙理工大学电气与信息工程学院，长沙 410114）

摘　要：为对配电组件缺陷进行精确快速的定位和识别，提出一种基于改进 YOLOv5-LITE 轻量级的配电组件缺陷识别方法。为使模型便于部署至移动设备终端，该方法使用 ShuffleNetV2 作为骨干网提取特征构建 YOLOv5-LITE 轻量级神经网络模型，并摘除 ShuffleNetV2 的 1024 卷积和 5×5 池化，采用全局平均池化操作替代，降低网络参数量，提升模型检测速度；通过引入有利于细粒度目标检测的 152×152 特征层，实现了对大、中、小尺度的缺陷检测；在 PANet 架构中采用深度可分离卷积代替下采样使得网络更加轻量化。实验结果表明：该方法能够识别电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子 3 种缺陷，其检测精度分别达到 92%、95%、95%，网络参数量约为 YOLOv5 的 1/4，检测速度达到 2 ms/张。所提出的方法具有实时性、准确率高、轻量化等特点。
关键词：目标检测；YOLOv5；ShuffleNetV2；轻量化；配电线路；缺陷识别

Defect Identification of Distribution Components Based on Improved YOLOv5-LITE Lightweight

YAN Hongwen[1], WAN Junjie[1], PAN Zhimin[2], ZHANG Jianjun[2], MA Rui[3]
(1. School of Computer & Communication Engineering, Changsha University of Science & Technology, Changsha 410114, China;
2. State Grid Hunan Extra High Voltage Substation Company, Changsha 410100, China;
3. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: In order to accurately and quickly locate and identify the defects of distribution components, a lightweight defect identification method of distribution components based on improved YOLOv5-LITE is proposed. To make the model easy to deploy to mobile device terminals, this method uses Shufflenetv2 as the backbone network to extract features, constructs YOLOv5-LITE lightweight neural network model, and removes 1024 convolution and 5×5 Pooling of Shufflenetv2, which is replaced by global average pooling operation to reduce the amount of network parameters and improve the speed of model detection. By introducing the 152×152 feature layer, which is conducive to the detection of fine-grained objects, the defect detection of large-, medium- and small-scales is realized. Using deep separable convolution instead of downsampling in PANet architecture makes the network more lightweight. The experimental results show that this method can be adopted to identify three defects: cable separation gasket, cable and insulator falling off and acyclic insulator. The detection accuracy is 92%, 95%, and 95%, respectively. The amount of network parameters is about 1/4 of YOLOv5, and the detection speed is 2 ms/piece. The proposed method has the characteristics of real-time, high accuracy and light weight.
Key words: target detection; YOLOv5; ShuffleNetV2; lightweight; distribution line; defect identification

0　引言

配电线路是电力系统运行中的基础部分，也是将用户、配电站、发电厂相连接的纽带[1]。电力系统故障的 80%~90%发生在配网中，配电线路在运行过程中会受到雷电、风暴、磁场等因素的影响，一旦发生故障，将会对经济、工业生产、居民正常生活造成重大影响[2-4]。通过先进的无线传感技术、通信技术、边缘计算和数据分析技术，实现输配电设备从业务数字化到数字业务化的转变[5]。因此，研究配电线路故障快速定位和识别，对检修人员精准修复缺陷、提高故障识别效率具有较大应用价值。

基金资助项目：国家自然科学基金 (51977012)；国网湖南电力科技项目 (5216A32100AF)。
Project supported by National Natural Science Foundation of China (51977012), Science and Technology Project of State Grid Hunan Electric Power (5216A32100AF).

近年来，随着无人机技术的发展，无人机航拍越来越多地被应用到配电线路巡检工作中，通过分析航拍图像，及时修复缺陷，保障配电线路正常运行。文献[6-7]通过对无人机巡检所需图像数据、自主巡航技术等的分析，探索了无人机智慧巡检的可行性研究。文献[8]改进深度卷积神经网络(deep convolutional neural networks，DCNN)，设计定点化深度卷积神经网络模型自适应策略，进而延长无人机巡检的续航里程。文献[9]串联 Faster R-CNN 网络模型，迁移至无人机图像对绝缘子检测和自爆识别，并采用特征金字塔(feature pyramid networks，FPN)提取目标特征，结合区域生成网络产生候选域，提高了绝缘子自爆检测和识别精度。以上研究均从提升模型深度、复杂度入手，有效提高了配电线路的故障识别精度，但将庞大、臃肿的模型部署至移动设备终端不仅需要高性能的硬件设备支持，而且会大大降低配电线路故障识别的速度。

深度卷积神经网络在配电线路故障定位与识别领域具有巨大的优越性，当前研究主要分为两类：第 1 种是以 R-CNN[10]、Fast R-CNN[11]和 Faster R-CNN[12]为代表的两阶段目标检测模型。文献[13]提出基于迁移学习的并联卷积神经网络(parallel-CNN，P-CNN)训练方法，构建具有故障分类支路和定位支路的双支路卷积神经网络。文献[14]采用遗传算法优化支持向量机模型参数，构建电气量故障信息特征的多支持向量机模型诊断方法。但两阶段目标检测算法网络参数量大，需要占用更多资源，且检测时间较长。第 2 种是以 YOLO[15]、SSD[16]为代表的直接进行位置回归的一阶段目标检测模型。本文以 YOLOv5 算法为主体，不仅可以保持较高的准确率，而且具备检测速度快、耗时短、占用内存少的特点。

本文针对配电组件缺陷的定位与识别问题，提出一种改进型 YOLOv5-LITE 轻量级的神经网络模型，端到端实现缺陷定位与识别，引入有利于小目标检测的 152×152 尺度特征层，实现细粒度检测，并摘除 ShuffleNetV2 骨干网的 1024 卷积和 5×5 池化，采用全局平均池化操作代替，以减少模型参数。同时通过迁移学习载入预训练权重并预冻结多个卷积层，防止训练初期权值被破坏，从而提高模型精度。该模型可实现电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子 3 种缺陷的精准定位与识别。

1 材料与方法

1.1 配电线路缺陷数据获取

配电组件缺陷图像的采集地点为某市变电站现场，采集时使用携带相机的无人机距缺陷 20~80 cm 距离拍摄，通过左侧拍、右侧拍、仰拍、俯拍和正面拍 5 个角度拍摄[17]。共采集原始图像 1000 张，所采集图像大小为 608×608 像素，主要包含 3 类缺陷：电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子，如图 1 方框标注所示。

1.2 数据增广及预处理

在深度学习模型中，为了减小过拟合问题，需要大量数据样本用于模型训练；在模型训练阶段，所采集的数据越充分、越全面，模型识别效果越显著，因此通过数据增广方法扩充样本数量。本文采用的数据增广策略包括角度旋转、饱和度调整、去噪去雾、图像上下翻转和平移等形态学操作[18]，增强后得到 9700 张图像作为数据集。轻量级的 YOLOv5 模型在输入端使用了 Mosaic 数据增强方式，对 4 张缺陷图像采用随机缩放、随机裁剪、随机排布的方式进行拼接，能够提升模型分类的表现。Mosaic 数据增强对 4 张缺陷图片进行拼接，由于每张图片都有其对应的框，将 4 张图片拼接后即获得 1 张新的图片，同时获得这张图片对应的框，然后将这张新的图片传入神经网络模型学习，极大地丰富了对配电组件缺陷检测的背景，使得模型在训练过程中不会出现非信息像素，从而提高了模型训练效率。

1.3 建立图像数据库和标签数据库

使用 Labelimg 或 LabelMe 工具对配电线路图像中的电缆脱离垫片、电缆与绝缘子脱落、无环绝缘



(a) 电缆脱离垫片 (b) 电缆绝缘子脱落 (c) 无环绝缘子

图 1 3 种不同类型的缺陷

Fig.1 Three different types of defects

子 3 种缺陷进行手工标注矩形框，建立对应图像数据库和标签数据库。标注完成后将数据集按照 8:2 比例划分，其中 80%部分再按照 8:2 分为训练集和验证集，剩余的 20%作为测试集，最终得到训练集、验证集和测试集样本数分别为 6208、1552、1940 张。

2 配电线路故障识别网络

2.1 YOLOv5 网络模型

配电线路的背景复杂多样，在不同角度和光线下，可能会干扰无人机对于故障的检测，因此有必要选择一种稳健且具有高鲁棒性的网络模型。相对于 R-CNN、Fast R-CNN 和 Faster R-CNN 基于区域的两阶段目标检测模型，YOLOv5 算法属于一阶段目标检测模型，可以直接预测候选框的相对位置实现物体分类(Classification)和边界框(Bounding box)，其网络结构图如图 2 所示。YOLOv5 网络结构分为 4 个部分：输入端(Input)、骨干网(Backbone)、颈部网络(Neck)和预测(Prediction)。输入端采用 Mosaic 数据增强和自适应锚框计算。Mosaic 数据增强方式将图像以随机缩放、随机裁剪、随机排布的方式进行拼接，增强了对小目标的检测效果[19]。在网络训练中相比于初始设定长宽的锚框，自适应计算不同训练集的最佳锚框值，能够降低其和真实框(Ground truth)的差距再反向更新，减少迭代网络参数提高目标检测速度。骨干网络采用 CSPDarknet 对输入图像提取丰富的信息特征。CSPNet 解决了在深度卷积神经网络模型骨干网中网络优化的梯度信息重复问题，将梯度的变化统一集成到特征图中，因此减少了模型的参数量和计算机每秒浮点运算次数(FLOPS)，从而提高了推理的速度和准确率，且减小了模型尺寸。在 YOLOv5 中的 CSPNet 结构采用了两种 CSP 结构：第 1 种是骨干网中使用 CSP1_X，采用残差(ResNet)结构，增强卷积神经网络学习能力；第 2 种是颈部网络中使用 CSP2_X，没有采用残差结构。骨干网络对输入特征图采用 Focus 结构，Focus 结构通过切片操作把宽度 w 和高度 h 的信息整合到 c 维度，即将宽度 w 和高度 h 都缩小 2 倍，通道数 c 增加 4 倍。在 CSPNet 结构中引入 LeakyReLU 激活函数，LeakyReLU 是 ReLU 的改进版，ReLU 在训练过程中当输入值小于 0 时，激活后的值仍然为 0，使得部分神经元不会被激活，导致相应参数永远不能被更新，然而 LeakyReLU 激活函数有 1 个参数 a，控制着参数的更新。LeakyReLU 函数表达式为：

$$\text{Leaky ReLU}(a(x)) = \max(ax, x) \tag{1}$$

式中：x 为输入值；a 取值一般为 0.01。

YOLOv5 的颈部网络采用 FPN+PANet 结构，FPN 主要通过融合高底层特征提升目标检测的效果，尤其可提高对小目标的检测。PANet 在 FPN 的基础上引入自低向上路径增强(bottom-up path augmentation)结构，可以充分利用网络浅层特征进行分割，使得顶层特征图(feature map)也可以享受底层带来的丰富位置信息，提升对大物体的检测效果，从而使得模型能够识别不同大小和尺度的同一个物

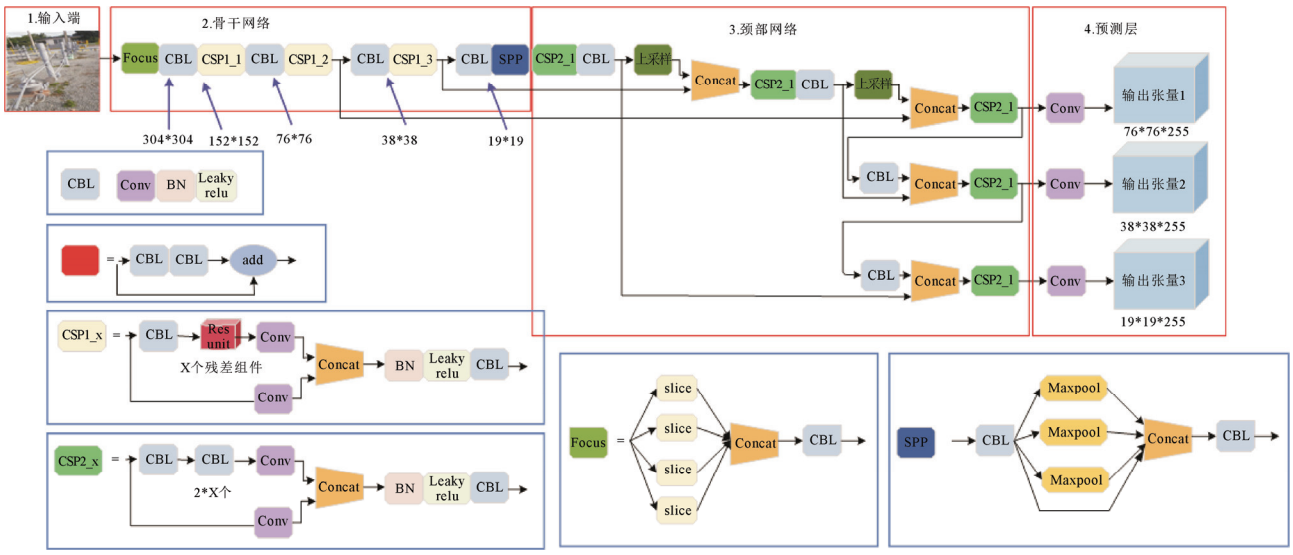


图 2 YOLOv5 网络模型架构

Fig.2 YOLOv5 network model architecture

体。FPN+PANet 结构如图 3 所示，其中，P 表示两个特征图拼接生成新的特征图，N 表示对新生成的特征图进行路径聚合网络处理。

YOLOv5 损失函数 L 包括边界回归损失 L_{coord}、置信度预测损失 L_{conf} 和类别预测损失 L_{cls}。YOLOv5 采用 GIoU Loss 计算边界回归(bounding box)损失，BECLogits 损失函数计算置信度(objectness score)损失，交叉熵损失函数(BCEclsloss)计算类别预测(class probability score)损失。其损失计算式为：

$$L=L_{\text{coord}}+L_{\text{conf}}+L_{\text{cls}} \tag{2}$$

$$L_{\text{coord}}=1-\sigma_{\text{GIoU}} \tag{3}$$

$$\sigma_{\text{GIoU}}=\sigma_{\text{IoU}}-\frac{|C/(A\cup B)|}{|C|} \tag{4}$$

$$\begin{aligned}L_{\text{conf}}=&\sum_{i=0}^{S\times S}\sum_{j=0}^{B}I_{ij}^{\text{obj}}(\hat{C}_i\lg(C_i)+(1-\hat{C}_i)\lg(1-C_i))-\\&\sum_{I=0}^{S\times S}\sum_{j=0}^{B}I_{ij}^{\text{nobj}}(\hat{C}_i\lg(C_i)+(1-\hat{C}_i)\lg(1-C_i))\end{aligned} \tag{5}$$

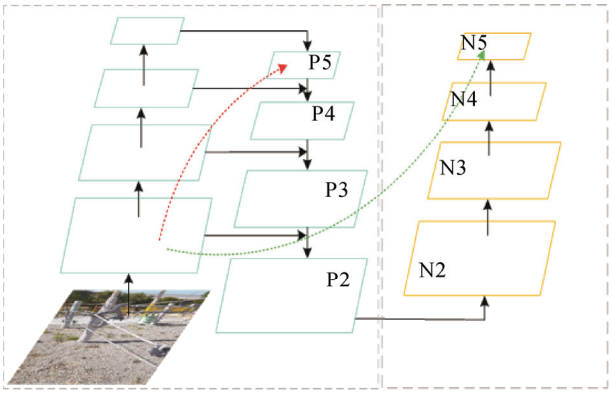
$$\begin{aligned}L_{\text{cls}}=&\sum_{t=0}^{S\times S}\sum_{j=0}^{B}I_{ij}^{\text{obj}}\sum_{C\in C_{\text{total}}}(\hat{P}_i(C)\lg(P_i))+\\&(1-\hat{P}_i(c)\lg(1-P_i(C)))\end{aligned} \tag{6}$$

式中：σ_{IoU} 为交并比；σ_{GIoU} 为广义交并比；A 和 B 为候选框的个数；C 代表类别；C_{total} 为总类别数，S 为网络大小；I 表示特征图(feature map)的第 i 个方格；j 表示该方格预测出的第 j 个预测框；上标 obj 与 nobj 表示第 i 个方格中有对象与无对象；C_i、$\hat{C}_i$ 分别表示预测和真实框的类别；P_i、$\hat{P}_i$ 分别表示预测目标置信度和实际目标置信度。

2.2 轻量级 ShuffleNetV2 网络模型

深度卷积神经网络在图像分类领域已经极大地提高了准确度，但除准确度外，计算复杂度也是神经网络需要考虑的重要指标，过复杂的网络可能速度很慢，对于一些特定场景如无人车领域需要低延迟模型，另外移动设备终端也需要既快又准确的小模型。因此为了达到速度–精度的权衡，一些轻量级架构如 MobileNet、ShuffleNet 模型被提出，它们在速度和精度之间做了很好的平衡。然而在同等复杂度下，ShuffleNetV2 模型比 ShuffleNet、MobileNetv2 更准确。

在设计轻量化神经网络领域，当前研究主要有两种方法：压缩已训练好的模型和直接训练轻量化网络模型；在线子类知识蒸馏(OSKD)是典型的压缩已训练好的模型，能够提高分类性能[20]。本方法采用直接训练轻量化 ShuffleNetV2 网络模型，并提出如下设计高效网络的 4 条准则[21]，使其具有较好的鲁棒性。当检测不同设备或环境下的配电线路组件缺陷时，也能够精准识别。



(a) FPN骨干网 (b) PANet骨干网

图 3 FPN+PANet 结构

Fig.3 FPN + PANet structure

1）相同输入、输出通道宽度可以最小化内存访问成本(memory access cost，MAC)。

2）过多的组卷积会增加内存访问成本。

3）网络内部碎片化操作会降低并行度。

4）减少 Element-wise 操作，如 add、Relu 等。

2.3 改进的 YOLOv5-LITE 网络模型设计

YOLOv5 网络的骨干网采用 CSPDarknet53 提取特征，虽然提升了检测的精度，但模型计算复杂，需要耗费较多的内存空间，不利于部署至无人机用于配电线路故障的实时监测。本研究提出一种基于 YOLOv5 的轻量级网络，在传统的 YOLOv5 模式基础上，将 ShuffleNetV2 架构替代 CSPDarknet53 作为特征提取网络，构建 YOLOv5-LITE 轻量级网络模型。ShuffleNetV2 既继承了 ShuffleNet 分组卷积和通道重排的特点[22]，又遵循了设计轻量级网络的 4 条准则。在同等条件下，ShuffleNetV2 相比其他模型速度快，且准确度更好。YOLOv5 模型输入由 ShuffleNetV2 提取的目标特征量，根据每次迭代返回的损失值，自适应地调整网络模型的参数，等待损失值收敛趋于稳定，便可得到评估指标最佳的检测模型。

配电线路作为识别目标，因此引入有利于小目标检测的 152×152 尺度特征层，实现细粒度检测。从 YOLOv5-LITE 轻量级神经网络模型的骨干网 ShuffleNetV2 中，提取 19×19(特征层 P5′)、38×38(特征层 P4′)、76×76(特征层 P3′)和 152×152(特征层 P2′)

共 4 个尺度特征，如图 4 所示。其中 P5′大感受野适用于大目标检测，P4′适用于中等目标检测，在 P3′基础上进行上采样，融合 P2′特征层实现对小目标的缺陷检测。

在特征传输过程，19×19 尺度特征层经过 SPP 结构采用 1×1、5×5、9×9 和 13×13 的最大池化方式，进行多尺度融合得到特征层 P5′。在特征融合获得更加丰富的特征图时，为了防止网络过于冗余，对特征金字塔(FPN)融合后输出的 152×152 特征层进行剪枝操作，即特征金字塔输出的 152×152 特征层不再进行 YOLO Head 的预测输出，而是直接在 PANet 结构进行上采样。因此改进的算法仍保留 YOLO Head 的 19×19、38×38、76×76 共 3 个尺度的特征层预测输出。

YOLOv5-LITE 的骨干网增加 152×152 特征层负责小目标检测时，必然会带来网络数量的增加，为降低网络参数，在 PANet 结构使用深度可分离卷积(Depthwise separable convolution)代替原模型的下采样(Downsample)，实现各层的特征信息交互，有效减少模型的网络计算量和参数。由于采集的数据具有 3 个类别缺陷，因而摘除 ShuffleNetV2 骨干网的 1024 卷积和 5×5 池化操作，采用全局平均池化操作代替，在节省内存消耗的同时也提高了模型的速度和精度。

3 算例仿真及结果分析

3.1 实验条件

3.1.1 实验平台

本研究在 Pythono3.8 环境下使用 Pytorch 框架来改进 YOLOv5 网络模型实现整个算法，部分实验环境如表 1 所示。

3.1.2 网络模型训练和评估指标

通过构建改进的 YOLOv5-LITE 目标检测网络与原模型、其他模型进行对比实验，并在相同条件和验证集上验证模型的效果。首先对采集的原始图像进行预处理和数据增广，然后对所有样本使用 Labelimg 工具对其中的缺陷部位进行方框标记，包含 3 种缺陷：电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子，其类别标签分别标记为 disengage gasket、drop、no buckle 并生成对应的 XML 文档，每个 XML 文档包含缺陷的 4 个位置属性和 1 个类别属性，最后生成对应的图像数据库和标签数据库。将图像数据库和标签数据库分别采用使用预训练权重和不使用预训练权重的训练方法进行网络模型的

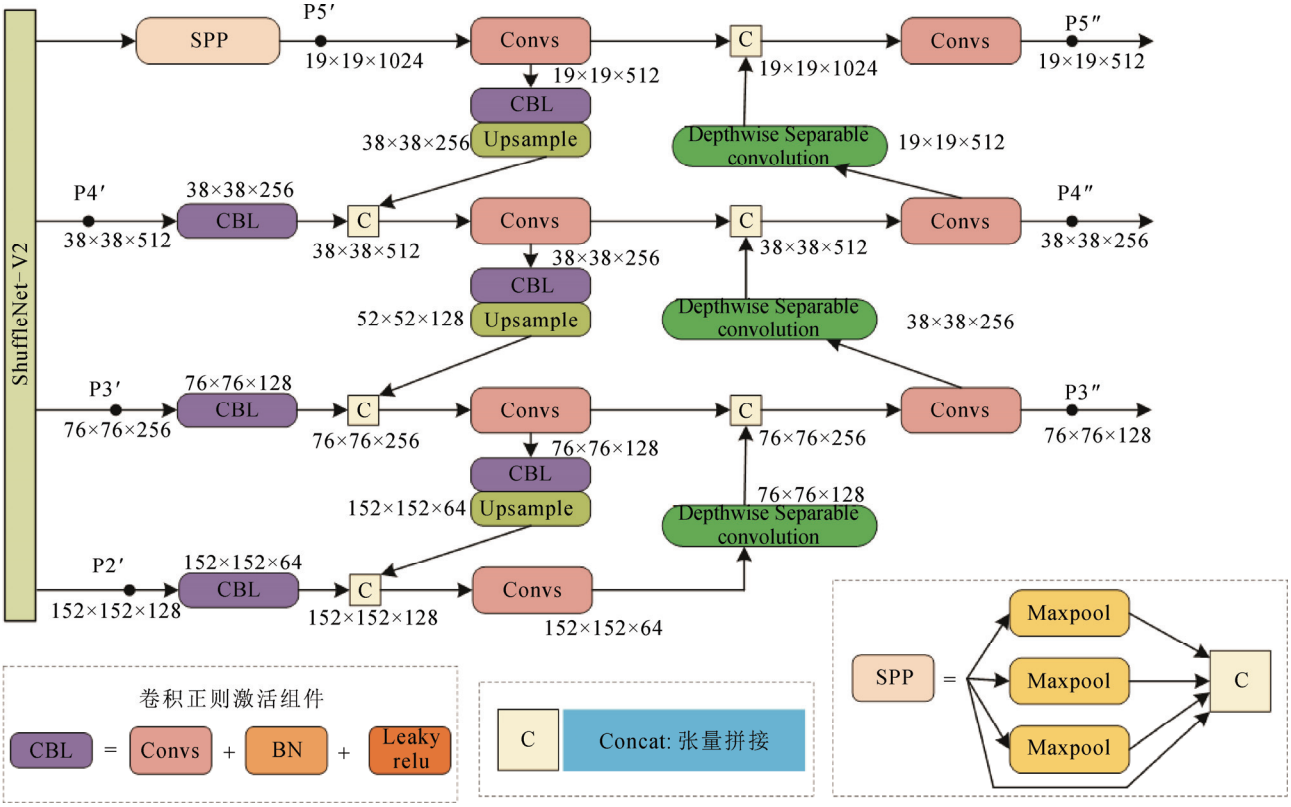


图 4 改进的 YOLOv5-LITE 网络结构图

Fig.4 Improved YOLOv5-LITE network structure diagram

训练，防止整张图像输入模型中其他背景特征量对模型学习产生干扰；再通过 ShuffleNetV2 架构提取出具备内容丰富、属性全面的配电组件缺陷目标特征量，保证特征量选取的合理性，进而保证模型学习精度并提高学习效率。模型训练时，为防止网络过拟合采用早停法训练技巧。配电线路缺陷检测流程如图 5 所示。

为客观评估不同模型对配电线路故障检测效果，使用准确度(Precision)、召回度(Recall)、调和均值 F_1 值、网络参数量、权重大小和检测速度来评估训练后的模型，其准确度、召回度和 F_1 值计算式如(7)—式(9)所示：

$$V_{\text{pre}}=\frac{V_{\text{TP}}}{V_{\text{TP}}+V_{\text{FP}}}\times 100\% \tag{7}$$

$$V_{\text{rec}}=\frac{V_{\text{TP}}}{V_{\text{TP}}+V_{\text{FN}}}\times 100\% \tag{8}$$

$$F_1=\frac{2V_{\text{pre}}V_{\text{rec}}}{V_{\text{pre}}+V_{\text{rec}}} \tag{9}$$

式中：V_{pre} 为精确率；V_{rec} 为召回率；V_{TP} 为真实的正样本数量；V_{FP} 为虚假的正样本数量；V_{FN} 为虚假的负样本数量。平均准确率(average precision，AP，用 σ 表示)是对不同召回率点上的准确率进行平均，AP 的值越大，说明模型的平均准确率越高，其计算式如(10)所示：

$$\sigma=\int_0^1 V_{\text{pre}}V_{\text{rec}}\mathrm{d}r \tag{10}$$

对于网络训练参数设置，在使用预训练权重时，模型冻结阶段超参数迭代总轮次(epochs)为 150，批次大小(batch-size)为 8，权重初始学习率为 0.0001，余弦退火超参数为 0.114，学习率动量(momentum)为 0.873，权重衰减系数为 0.0005，解冻阶段超参数迭代总轮数为 150，批次大小为 4，权重学习率为 0.001，余弦退火超参数为 0.114，学习率动量(momentum)为 0.873，权重衰减系数为 0.0005，冻结和解冻阶段总训练轮次为 300；在不使用预训练权重时，模型训练总轮次也为 300，批次大小(batch-size)为 2，权重初始学习率为 0.001，余弦退火超参数为 0.114，学习率动量为 0.873，权重衰减系数为 0.0005。其使用预训练权重和不使用预训练权重两种训练方式均采用 BN(batch normalization)正则化对网络权值更新，在训练集上每训练一轮(epoach)均保存一次权值文件，第 300 轮得到损失值最低的权重文件。训练集和验证集损失曲线如图 6 所示。

图 6 给出了训练集、验证集损失和平滑训练、平滑验证损失，采用平滑损失是为了防止图像在训练时梯度过大。在冻结阶段前 150 轮训练时，训练集和验证集在前 50 轮损失持续下降，50~150 轮损失总体呈现减少趋势；在第 150 轮训练时由于解冻

表 1 实验环境

Table 1 Experimental environment

配置	参数
GPU 个数	2
操作系统	Windows10
开发平台、环境	PyCharm、Python3.8
加速环境	cuda11.1、CUDNN11.1
其他	Numpy1.21.2、Pycocotools

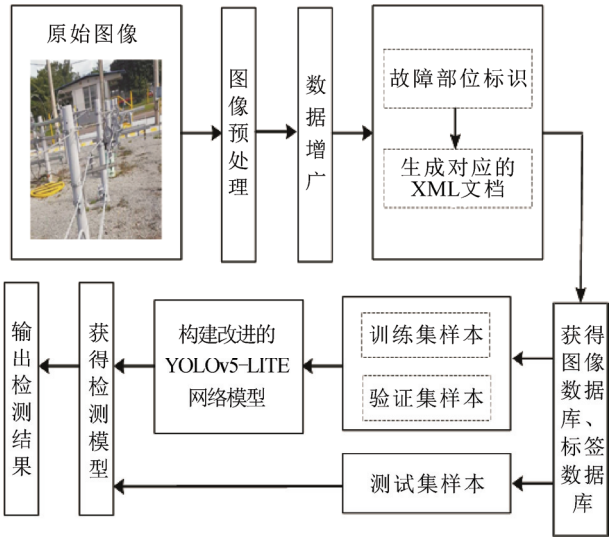


图 5 配电线路缺陷检测流程图

Fig.5 Distribution line fault detection flow chart

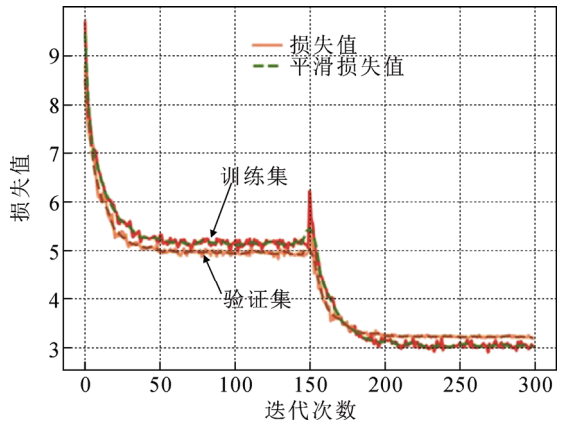


图 6 训练集和验证集损失曲线图

Fig.6 Loss curve of training set and verification set

训练使得训练集损失升高，验证集损失仍在下降；在 150 轮训练后，训练集和验证集损失逐渐下降至不再大幅度变化，模型收敛。

3.2 迁移学习并冻结部分层的检测结果

以 YOLOv5-LITE 模型为对象网络，将骨干网提取特征量分别采用两种训练方式：即使用迁移学习载入预训练权重并冻结部分层的训练方式和不使用预训练权重的训练方式。使用迁移学习载入预训练权重的训练方式为载入 COCO 数据集的 ShuffleNetV2 权重文件，初始训练时冻结 YOLOv5-LITE 中的 ShuffleNetV2 网络层，此时模型主干被冻结，特征提取网络不发生变化，仅对网络微调；在模型不被冻结，特征提取网络会发生改变，网络所有参数都会发生改变。表 2 比较了两种训练方式的结果。

实验结果表明，不使用预训练权重的训练方式在交并比(IoU)分别为 0.5、0.75 时平均精度分别为 88.3%、45.2%，在同等条件下使用预训练权重的训练方式平均精度分别为 93.6%、48.5%，因而可以发现精度均提升约 4%，同时 F_1 值和准确率均有一定的提升。

3.3 不同骨干网络特征提取实验对比

为实现对配电组件缺陷快速识别定位，保证电力稳定运行、传输，将轻量级的目标检测算法部署至移动设备终端，便于检修人员精准修复缺陷。因而以 ShuffleNetV2 作为骨干网络设计 YOLOv5-LITE 轻量级网络模型，为验证设计 YOLOv5-LITE 的合理性，分别以 CSPDarkNet-53、EfficientNet、MobileNetV2、MobileNetV3 作为骨干网在相同测试集上进行对比实验，实验结果如表 3 所示。通过表 3 可以看出，将 MobileNetV2、MobileNetV3 替换 YOLOv5 模型的 CSPDarkNet-53 作为骨干网络，在检测速度、每秒多少次浮点运算(GFLOPs)、网络参数都有大幅度改善，但在 mAP=0.5(mAP@0.5)和 mAP 在 σ_{IoU} 阈值从 0.5 到 0.95(mAP@0.5:0.95)范围内的精度均低于原 YOLOv5 网络。采用 EfficientNet 作为骨干网在精度上有略微提升，但其检测速度和 GFLOPs 需要更长时间，不利于对配电线路故障的实时检测。然而，采用 ShuffleNetV2 作为骨干网检测精度能够和原模型相当，比 MobileNetV2、MobileNetV3 作为骨干网精度提升 0.3 个百分点和 1.2 个百分点，对单张 640×640 像素图像的检测速度高达 2.0 ms/张，且网络参数比原 YOLOv5 模型减少了 78.23%。因此将 ShuffleNetV2 作为 YOLOv5 骨干网络，并引入有利于小目标检测的 152×152 尺度特征层，构建 YOLOv5-LITE 轻量级神经网络迁移至嵌入式上应用具有明显的优势，解决了目标检测算法部署至无人机难于对配电线路的实时检测问题。

表 2 两种训练方式结果比较

Table 2 Comparison of results of two training methods

训练方式及 σ_{IoU} 值	F_1 值	mAP/%	准确率/%
使用预训练权重且 σ_{IoU} =0.5	0.92	93.6	94.1
不使用预训练权重 σ_{IoU} =0.5	0.85	88.3	90.6
使用预训练权重且 σ_{IoU} =0.75	0.56	48.5	50.3
不使用预训练权重 σ_{IoU} =0.75	0.49	45.2	47.8

3.4 方法对比

将目标检测算法迁移至嵌入式设备终端使得无人机能够快速、准确识别配电线路故障，需要考虑算法的轻量化、占用内存少和推理时间短的特点。与两阶段目标检测算法相比，一阶段目标检测算法(one-stage)算法参数量少，检测速度更快。因此本文提出改进 YOLOv-LITE 轻量级的配电组件缺陷识别神经网络模型，其改进方式如下：①骨干网络的替换。将轻量化 ShuffleNetV2 架构替换 YOLOv5 原 CSPDarkNet-53 网络，以减少网络参数。②引入有利于小目标检测的 152×152 特征层，实现对细粒度目标的检测，解决了小目标检测精度低的问题。③在 PANet 结构中，使用深度可分离卷积替代下采样，

表 3 不同骨干网络检测结果对比

Table 3 Comparison of detection results of different backbone networks

网络模型	骨干网络	检测精度/%					检测速度/(ms·张$^{-1}$)	GFLOPs	网络参数
		mAP@0.5	mAP@0.5:0.95	电缆脱离垫片	电缆绝缘子脱离	无环绝缘子			
YOLOv5	CSPDarkNet-53	93.8	52.0	89.2	99.1	93.2	4.2	16.3	7 059 304
YOLOv5-LITE	ShuffleNetV2	93.6	50.8	90.1	98.8	91.8	2.0	3.6	1 536 480
	EfficientNet	94.2	42.0	92.0	92.0	99.0	4.5	7.9	5 368 837
	MobileNetV3	93.3	49.4	88.8	99.6	91.5	2.8	6.3	3 543 926
	MobileNetV2	92.4	47.5	87.6	98.3	91.2	2.5	5.6	2 794 275

提升模型检测的精度。④由于采集的数据具有 3 个缺陷类别，因而摘除 ShuffleNetV2 骨干网的 1024 卷积和 5×5 池化操作，采用全局平均池化操作代替。为验证改进型 YOLOv5-LITE 算法的优越性，与原 YOLOv5 模型、YOLOX-Tiny、两阶段目标检测(faster R-CNN)算法在相同测试集 1940 张图像进行对比实验，实验结果如表 4 所示。

相比于两阶段目标检测算法，一阶段目标检测算法在检测速度和网络参数量均有所改善且检测精度只比 Faster R-CNN 降低不到 1%，因而更利于迁移至无人机对配电线路故障的实时检测。本文提出的 YOLOv5-LITE 算法在网络参数均比其他模型大幅度减少，只需要 2 ms 就可以完成检测，网络参数约为 YOLOv5 的 1/4，表明将 ShuffleNetV2 作为骨干网并摘除 ShuffleNetV2 的 1024 卷积和 5×5 池化操作，采用全局平均池化操作代替具有明显的可靠性，能够有效提高模型检测速度。从表 4 可以看出，YOLOv5-LITE 模型对电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子检测精度分别为 90.1%、98.8%、91.8%，3 种缺陷的检测精度均超过 90%，说明改进特征金字塔(FPN)引入有利于细粒度目标检测的 152×152 特征层，实现了对大、中、小尺度的故障预测，提升了模型对小目标的检测精度。

将 YOLOv5-LITE 训练好的权重对测试集代表性图像进行诊断，其诊断效果如图 7 所示。可以看出，图像中电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子 3 种缺陷都完成了定位与识别，漏检率为 0。每个配电线路缺陷的位置都被方框标记了出来，并使用不同颜色的方框对不同类型缺陷的状态进行了识别。其中最左边的诊断图是配电线路中电缆脱离垫片，中间的诊断图是电缆与绝缘子脱离，最右边的诊断图是无环绝缘子。总体来看，本文提出的改进型 YOLOv5-LITE 轻量级神经网络比原模型 YOLOv5 具有更高的检测精度和速度，对背景复杂的小目标缺陷检测有较高的识别率，对不同配电设备识别也具有良好的泛化性能。

表 4 不同模型检测结果对比

Table 4 Comparison of test results of different models

算法	F_1 值	召回率/%	检测精度/%					检测速度/(ms·张$^{-1}$)	GFLOPs	网络参数
			mAP@0.5	mAP@0.5:0.95	电缆脱离垫片	电缆绝缘子脱离	无环绝缘子			
Faster R-CNN	0.93	96.0	94.7	52.8	91.8	99.3	93.0	22.3	24.4	7 322 584
SSD	0.89	93.5	92.6	49.4	88.5	98.1	91.4	2.8	12.9	6 869 431
YOLOv5	0.94	96.3	93.8	52.0	89.2	99.1	93.2	4.2	4.2	7 059 304
YOLOX-Tiny	0.91	93.8	92.9	49.3	88.0	99.9	91.0	3.1	6.8	5 061 935
YOLOv5-LITE	0.92	98.0	93.6	50.8	90.1	98.8	91.8	2.0	3.6	1 536 480



(a) 电缆脱离垫片诊断图 (b) 电缆与绝缘子脱落诊断图 (c) 无环绝缘子诊断图

图 7 配电组件缺陷检测效果图

Fig.7 Effect drawing of defect detection of distribution components

4 结论

本文提出了一种基于改进 YOLOv5-LITE 轻量级的配电组件缺陷识别方法。通过建立仿真模型进行分析验证，得到以下结论：

1）利用 ShuffleNetV2 作为骨干网构建 YOLOv5-LITE 轻量级神经网络模型，并摘除 ShuffleNetV2 的 1024 卷积和 5×5 池化，采用全局平均池化操作替代，能够大幅度减少模型网络参数提高检测速度，只需要约 2 ms 就可以实时完成对 1 张图像的检测。

2）文中改进特征金字塔(FPN)引入有利于细粒度目标检测的 152×152 特征层，实现了对大、中、小尺度的缺陷检测，对 PANet 架构中使用深度可分离卷积替代下采样使得网络更加轻量化，更有利于部署至移动设备终端和无人机。

3）本文提出的轻量化神经网络模型能够端到端的实现对配电组件缺陷的实时检测，能够识别电缆脱离垫片、电缆与绝缘子脱落、无环绝缘子 3 种故障，其检测精度分别达 92%、95%、95%。与 YOLOv5 原模型对比，本文提出的方法网络参数约为 YOLOv5 的 1/4，检测速度达到 2 ms/张，模型的检测精度和速度均有所提高。通过与其他模型对比实验，验证了该方法具有明显的优势。

参考文献 References

[1] 施 微，黄 磊，徐 箭，等. 基于有限同步量测数据的电力系统故障检测、辨识与定位[J]. 电网技术，2015，39(4)：1067-1074.
SHI Wei, HUANG Lei, XU Jian, et al. Fault detection, identification and location based on measurement data from finite synchronized phasor measurement[J]. Power System Technology, 2015, 39(4): 1067-1074.

[2] DUTTA P, ESMAEILIAN A, KEZUNOVIC M. Transmission-line fault analysis using synchronized sampling[J]. IEEE Transactions on Power Delivery, 2014, 29(2): 942-950.

[3] 江雪晨，王大志，宁 一，等. 电网故障最优诊断的查询方法[J]. 高电压技术，2017，43(4)：1311-1316.
JIANG Xuechen, WANG Dazhi, NING Yi, et al. Query method for optimal diagnosis of power system faults[J]. High Voltage Engineering, 2017, 43(4): 1311-1316.

[4] 郭学英，阴昌华，贾晶晶，等. 采用正弦原子分解的不带并补线路故障判别方法[J]. 高电压技术，2019，45(2)：525-532.
GUO Xueying, YIN Changhua, JIA Jingjing, et al. Fault identification method of transmission lines without shunt reactors by using sine atomic decomposition[J]. High Voltage Engineering, 2019, 45(2): 525-532.

[5] 江秀臣，刘亚东，傅晓飞，等. 输配电设备泛在电力物联网建设思路与发展趋势[J]. 高电压技术，2019，45(5)：1345-1351.
JIANG Xiuchen, LIU Yadong, FU Xiaofei, et al. Construction ideas and development trends of transmission and distribution equipment of the ubiquitous power internet of things[J]. High Voltage Engineering, 2019, 45(5): 1345-1351.

[6] 温新叶，杨忠伟，陈 昌. 输电线路无人机智能巡检应用研究[J]. 中国设备工程，2021(23)：31-32.
WEN Xinye, YANG Zhongwei, CHEN Chang. Application research on intelligent inspection of transmission line UAV[J]. China Plant Engineering, 2021(23): 31-32.)

[7] 赵振华，杨 洋，高 培. 基于 AI 图像识别的输电线路无人机激光清障系统设计[J]. 电子设计工程，2021，29(24)：179-183.
ZHAO Zhenhua, YANG Yang, GAO Pei. Design of UAV laser obstacle clearance system for transmission line based on AI image recognition[J]. Electronic Design Engineering, 2021, 29(24): 179-183.

[8] 戴永东，姚建光，李 勇，等. 基于定点化自适应选择卷积神经网络的电力缺陷识别方法[J]. 高电压技术，2021，47(11)：3827-3835.
DAI Yongdong, YAO Jianguang, LI Yong, et al. Power defect recognition method based on fixed-point adaptive selection convolution neural network[J]. High Voltage Engineering, 2021, 47(11): 3827-3835.

[9] GHASHGHAEI S, AKHBARI M. Fault detection and classification of an HVDC transmission line using a heterogenous multi-machine learning algorithm[J]. IET Generation, Transmission & Distribution, 2021, 15(16): 2319-2332.

[10] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE, 2014: 580-587.

[11] GIRSHICK R. Fast R-CNN[C]// Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 1440-1448.

[12] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C] // Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press, 2015: 91-99.

[13] 王 浩，杨东升，周博文，等. 基于并联卷积神经网络的多端直流输电线路故障诊断[J]. 电力系统自动化，2020，44(12)：84-92.
WANG Hao, YANG Dongsheng, ZHOU Bowen, et al. Fault diagnosis of multi-terminal HVDC transmission line based on parallel convolutional neural network[J]. Automation of Electric Power Systems, 2020, 44(12): 84-92.

[14] 吴笑民，曹卫华，王典洪，等. 多支持向量机模型的输电线路故障诊断方法[J]. 高电压技术，2020，46(3)：957-963.
WU Xiaomin, CAO Weihua, WANG Dianhong, et al. Fault diagnosis method based on multi-support vector machine model for transmission lines[J]. High Voltage Engineering, 2020, 46(3): 957-963.

[15] 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. Las Vegas, USA: IEEE, 2016: 779-788.

[16] 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.

[17] HU X L, LIU Y, ZHAO Z X, et al. Real-time detection of uneaten feed pellets in underwater images for aquaculture using an improved YOLO-V4 network[J]. Computers and Electronics in Agriculture, 2021, 185: 106135.

[18] 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.

[19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[J]. 2020. DOI: 10.48550/ arXiv. 2004.10934.

[20] TZELEPI M, PASSALIS N, TEFAS A. Online subclass knowledge distillation[J]. Expert Systems with Applications, 2021, 181: 115132.

[21] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[C]// Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer, 2018: 122-138.

[22] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C] // Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 6848-6856.



YAN Hongwen
Ph.D., Professor
Corresponding author

颜宏文(通信作者)
1968—，女，博士，教授，硕导
主要研究方向为智能电网中的数据挖掘
E-mail: yanhongwen7@126.com

收稿日期 2022-03-25 修回日期 2022-09-30 编辑 卫李静