第 50 卷 第 11 期：5047-5059 高电压技术 Vol.50, No.11: 5047-5059
2024 年 11 月 30 日 High Voltage Engineering November 30, 2024
DOI: 10.13336/j.1003-6520.hve.20230945

基于 LEE-YOLOv7 的输电线路边缘端实时缺陷检测方法

胡晨龙[1]，裴少通[1]，刘云鹏[1,2]，杨文杰[1]，杨　瑞[1]，张行远[1]，刘海峰[3]
（1. 华北电力大学河北省输变电设备安全防御重点实验室，保定 071003；2. 华北电力大学新能源电力系统国家重点实验室，北京 102206；3. 国网河北省电力有限公司超高压分公司，石家庄 050070）

摘　要：边缘计算设备已广泛应用于无人机输电线路巡检中，但边缘端设备较低的功率及算力限制了其检测速度与精度，针对以上问题，该文对 YOLOv7 目标检测算法进行改进，提出一种基于 LEE-YOLOv7 的输电线路边缘端缺陷诊断方法。首先，采用 Mosaic-9 数据增强方法改进训练阶段的输入端，提高网络的泛化能力；而后引入 LCnet 网络改造主干网络部分，减少冗余参数，轻量化网络；然后，采用 Meta-ACON 激活函数及 Wise-IoU 损失函数优化网络；最后在推理过程中使用 Deepstream 技术调用 TensorRT 模块实现模型重构、优化及加速。经实验验证，LEE-YOLOv7 对 10 种常见输电线路多尺寸缺陷的识别平均准确率达到 92.3%，相比原版 YOLOv7 算法提高了 2.8%，且检测速度提升了 38 帧/s，达到 53 帧/s。采用 Deepstream 调用 TensorRT 模块进行推理过程的优化加速后，在 Nvidia Jetson Xavier NX 边缘端模块上，实现了 91.2%的平均准确度及 79 帧/s 的检测速度，满足了边缘端准确实时的输电线路缺陷检测要求。

关键词：边缘计算；输电线路；Deepstream；缺陷检测；深度学习；TensorRT

Real-time Edge End Defect Detection Method for Transmission Line Based on LEE-YOLOv7

HU Chenlong[1], PEI Shaotong[1], LIU Yunpeng[1,2], YANG Wenjie[1], YANG Rui[1], ZHANG Hangyuan[1], LIU Haifeng[3]
(1. Hebei Provincial Key Laboratory of Power Transmission Equipment Security Defense, North China Electric Power University, Baoding 071003, China; 2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 3. Ultra High Voltage Branch, State Grid Hebei Electric Power Company, Shijiazhuang 050070, China)

Abstract：Edge computing devices have been widely used in unmanned aerial vehicle (UAV) power transmission line inspections. However, the limited power and computational capabilities of edge devices hinder the detection speed and accuracy. To address these challenges, we improve the YOLOv7 target detection algorithm and propose an edge-end defect detection method for transmission lines based on the LEE-YOLOv7. Firstly, the Mosaic-9 data enhancement method is used to improve the inputs in the training phase to improve the generalization ability of the network. Then, the LCnet network is introduced to transform the backbone network part, to reduce the redundant parameters and to lighten the network. Subsequently, the Meta-ACON activation function and Wise-IoU loss function are applied to optimize the network. Finally, during the inference process, the Deepstream technology is utilized to invoke the TensorRT module, achieving model reconstruction, optimization, and acceleration. The experimental results demonstrate that the LEE-YOLOv7 achieves an average accuracy of 92.3% in identifying ten common types of power transmission line defects with varying sizes. Compared to the original YOLOv7 algorithm, the proposed approach improves accuracy by 2.8% and increases detection speed by 38 frames per second, reaching 53 frames per second. After optimizing the inference process using Deepstream and TensorRT on the Nvidia Jetson Xavier NX edge module, the approach achieves an average accuracy of 91.2% and 79 frames per second for defect detection, satisfying the requirements of accurate real-time transmission line defect detection at the edge end.

Key words：edge computing; transmission lines; Deepstream; defect detection; deep learning; TensorRT

基金资助项目：中央高校基本科研业务专项基金 (2020MS093)。
Project supported by Fundamental Research Funds for the Central Universities (2020MS093).

0 引言

为确保输电线路安全稳定运行，需要对输电线路开展定期巡检以消除潜在故障或隐患[1]，大部分输电线路架设在人烟稀少的城市边缘区域或地形复杂的山地区域，采用传统的人工巡检模式成本及难度较高。随着人工智能、边缘计算技术的发展，无人机巡检技术被广泛应用于当前输电线路巡检中，目前，中国国家电网已经形成“人巡为辅，机巡为主”的自动化巡检格局[2]：采用集中式云端运算巡检模式，由无人机巡线获取图像数据，返航后人工将数据上传至云服务器，最后通过云端深度学习算法对图像数据进行缺陷检测并反馈至现场工作人员。

目前，应用于输电线路巡检云服务器端缺陷检测的主流深度算法包括以区域卷积神经网络系列(region-convolution neural network，RCNN) [3-5]、YOLO(you only look once)系列[6-12]为代表的单、双阶段卷积神经网络(convolution neural network，CNN)目标检测算法，以检测变换器(detection tranformer，DETR)系列[13]为代表的 Transformer 检测算法以及衍生算法如：李帷韬等提出的采用空洞卷积网络、深度 Q 网络及 Transformer 的缺陷智能检测方法[14]；赵振兵团队提出的基于递归特征金字塔及 NAS 空洞卷积结合的 Cascade RCNN 输电线路缺陷检测方法[15]；郝帅等提出的基于空间与通道卷积注意力及自适应加权融合模块的 YOLOv5 输电线路故障检测方法[16]。

随着当前巡检模式的推广及大量应用，也出现了新的问题。首先，随着无人机大规模投入使用，大量数据同时上传，产生了带宽拥挤问题；云服务器需要对大量数据进行检测并反馈回现场，造成云服务器负载过大、算力不足及数据处理与传输时间过长导致的反馈不及时问题。为解决这些问题，采用边缘计算设备在现场对无人机航拍影像进行检测、诊断的边端智能巡检方案应运而生[17-23]。

由于边缘端设备具有体积小、功耗低的特点，其算力及内存较小，常规的深度学习检测算法部署在边缘端设备时，会出现识别速度极慢及识别滞后问题，在利用边缘端设备进行输电线路无人机巡检时，对算法的实时性及准确率均有较高的要求，故必须对算法模型进行轻量化及边缘端加速，目前已经有少量研究针对输电线路边缘端智能巡检展开。马富齐等采用 MobileNetv3 提取特征，而后采用单发多箱探测器(single shot multibox detector，SSD)算法实现覆冰厚度辨识与检测[24]；金潮伟采用 Core 卷积组子网络替代 VGG 网络对 SSD 算法进行改进，实现了对输电线路设备缺陷的检测[25]；刘闽等利用 R-D(RepVGG-Divers branch block)模块及空间金字塔池化(spatial pyramid pooling，SPP)方法对 YOLOv5 算法进行改进，而后采用 ResRep 进行剪枝，实现了推理速度大幅提升[26]，但上述方法仍存在一些问题，例如：部分方法的网络轻量化后仍含有大量消耗运算能力的拼接结构、方法并未针对边缘端设备做硬件层面的优化，内存使用不合理。

本文针对上述问题及输电线路边缘检测需要高速高准确率的实时检测算法模型的需求，在 YOLOv7 算法的基础上，首先引入马赛克-9(Mosic-9)数据增强方法改进输入端，提高了模型的鲁棒性和泛化能力；而后采用轻量卷积网络(light convolution net，LCNet)替换主干网络并引入 Meta-ACON 激活函数及 Wise-IoU 损失函数对 YOLOv7 网络进行改进，形成了轻量化边缘端电力(light-edge-electric，LEE)YOLOv7，最后采用 Deepstream 调用 TensorRT 的分组卷积及内存复用技术对部署在 Jetson Xavier NX 边缘端平台的模型进行重构和优化加速，提高了模型的推理速度并减少了内存占用，实现了高精准度边缘端实时输电线路缺陷检测。

1 LEE-YOLOv7 网络

1.1 YOLOv7 算法

YOLO 系列算法是当前单阶段(One-stage)目标检测的典型算法，从 YOLOv1 开始就以较快的推理速度被广泛应用于遥感、医学、机器人视觉等领域[27]，YOLOv7 算法[28]是目前 YOLO 系列最先进的算法，由于帧率为 5~160 帧/s 时 MSCOCO 数据集上的推理速度及检测精度超越了所有已知目标检测算法，故适合作为输电线路边缘端实时缺陷检测算法，因此本文将其作为基础算法，按照输电线路的边缘端巡检的需求进行改进，形成了 LEE-YOLOv7 网络，见图 1。

YOLOv7 网络结构同 YOLO 系列其他算法相似，如附录图 A1 所示，由输入(Input)、主干网络(Backbone)、颈部网络(Neck)、预测头(Head)4 部分组成。

输入端(Input)：整体复用了 YOLOv5 算法的结

构，采用 Mosic-4 数据增强，即将 4 张输入图片随机堆叠，扩充了同时输入的数据量，从而变相增加了批量大小(Batch-size)。

主干网络(Backbone)：又称特征提取网络，主要作用为提取目标信息特征，相较于 YOLOv5，YOLOv7 采用了高效率的 Extended-ELAN (E-ELAN)+MP 结构，通过扩展、随机打乱及合并基数操作实现了在不破坏原有梯度路径的情况下可以不断增强网络的学习能力，同时提高了主干网络的特征提取能力。

颈部网络(Neck)及预测头(Head)：整体作用为根据 Backbone 层特征进行预测框生成及类别预测，Neck 部分采用特征金字塔(feature pyramid network，FPN)+路径聚合网络(path aggregation network，PANet)结构，引入重参数化(reparameterization，Rep)结构，有效提高了算法的检测效率。预测头同 YOLOv5 相同，采用基于锚框(Anchor Based)结构。

1.2 YOLOv7 算法改进

1.2.1 Mosic-9 数据增强

Mosaic 增强是一种广泛使用的图像处理技术，通过将图像分成多个块或者将多个图像合成一个图像来提高图像质量，从而增强网络的鲁棒性和准确性。

由于无人机航拍的输电线路巡检图像通常包含大量背景、特征信息以及多种尺寸的目标，这对算法的泛化能力及训练时输入图像的特征、背景信息的多样性提出了较高的要求，故本文采用 Mosaic-9 增强方法来优化原版 YOLOv7 的 Mosaic-4 增强方法，其原理如图 2 所示。在输入时，随机选择 9 张输入数据中的图片并采用不同的增强方法(如剪裁、旋转等)，然后将它们拼接成 1 张图片，最后将其输入到网络中。相对于原版的 Mosaic-4 增强方法，采用 Mosaic-9 增强方法拼接的图像包含更多的特征信息、背景信息以及不同尺度的目标，增强了数据样本的多样性特征信息及背景信息，可以有效提高网络的泛化能力并减少模型过拟合。

1.2.2 LCnet 网络

YOLO 系列算法在 Backbone 部分采用 CSPDarknet、EfficentNet、CSPResnet 等网络结构，此类网络结构均针对 NVIDIA-GPU 端高性能平台进行设计，为提高准确率采用了大量浮点运算及乘加操作，导致模型具有很大参数(Parameters)及浮点运算量(GFLOPs)，这类模型对于输电线路缺陷边缘检测设备常采用的 Nvidia Jetson Xavier NX、Nvidia Jetson Xavier Nano 等边缘计算模块过于复杂，推理速度很难达到实际需求。

如图 1 所示，LCNet 是由多个深度可分离卷积(depthwise separable convolution，DepthSepConv)及 GFF 模块堆叠而成的单分支结构，其相较于多分支架构具有更快的推理速度，可以实现在移动端、边缘端运行时精度及速度的平衡，LCNet 的基本模块

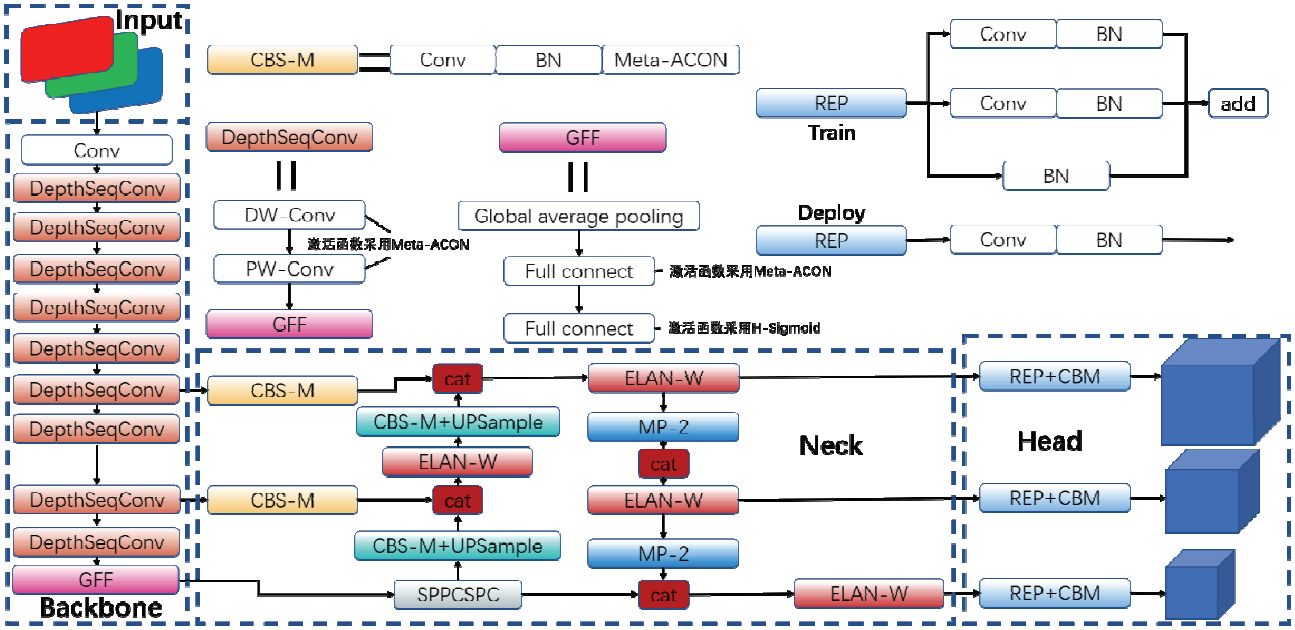


图 1 LEE-YOLOv7 网络结构图

Fig.1 LEE-YOLOv7 network structure diagram

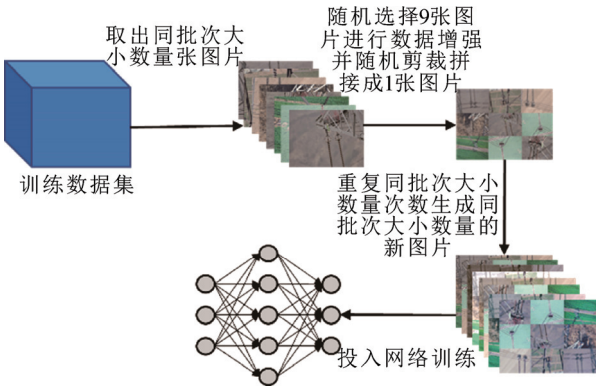


图 2 Mosaic-9 原理图

Fig.2 Mosaic-9 schematic diagram

DepthSepConv 基本原理如图 3 所示，其由深度卷积(depthwise conv，DW 卷积)、逐点卷积(pointwise Conv，PW 卷积)及 Swish 激活函数组成。

由图 3 原理图可知，传统卷积操作时，卷积核的通道数与输入特征矩阵的通道数相同，卷积核的个数与输出特征矩阵相同，故普通的卷积计算量 J_{Conv} 可表示为：

$$J_{\mathrm{Conv}} = C_{\mathrm{in}} C_{\mathrm{out}} HWC_H C_W \tag{1}$$

式中：C_{in}、C_{out} 为输入、输出特征图通道数；H、W 为输入特征图大小；C_H、C_W 为卷积核大小。

而对于 DepthSeqConv 中的深度卷积(DW 卷积)，每个卷积核都对输入特征图的一个通道单独卷积，则在 DW 卷积中输出特征图、输入特征图及卷积核数相同；逐点卷积(PW 卷积)则负责提升通道数，采用 n 个卷积核对应 1 个输入特征图的通道，则 DepthSeqConv 的计算量 J_{DSConv} 为：

$$J_{\mathrm{DSConv}} = C_{\mathrm{in}} C_{\mathrm{out}} HC_H C_W + HWC_H C_W \tag{2}$$

与普通卷积对比可知，DepthSeqConv 的计算量只有普通卷积的 $1/H+1/(C_{\mathrm{in}}\cdot C_{\mathrm{out}})$，当使用 3×3 卷积时，2 者计算量相差了 8~9 倍，且 DepthSeqConv 层不含有跳跃连接，故不需要进行拼接(concatenate，concat)、元素添置(elementwise-add)等会显著降低模型推理速度的拼接操作。由上可知，采用 LCNet 替换 Backbone 部分可以大幅度减少模型的参数和浮点运算量，实现模型的轻量化，从而提高模型的推理速度达到输电线路边缘检测的需要。

1.2.3 Meta-ACON 激活函数

当前深度学习网络中常用的线性整流函数为 ReLU 激活函数，本质上是最大值函数(MAX)，其计算式如式(3)所示。

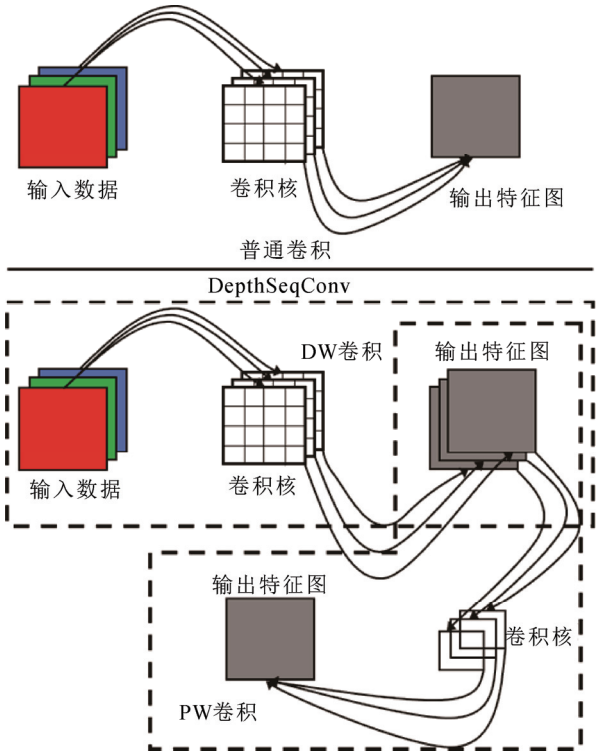


图 3 DepthSeqConv 原理图

Fig.3 DepthSeqConv schematic diagram

$$f_{\mathrm{ReLU}}(x)=\mathrm{MAX}(0,x) \tag{3}$$

式中：x 为函数自变量。

对 ReLU 激活函数进行平滑化，得到了平滑 ReLU 函数即 SmoothReLU，如式(4)所示：

$$f_{\mathrm{SmoothReLU}}(x_1,\ldots,x_n)=\sum_{i=1}^{n} x_i \mathrm{e}^{\beta x_i} \Big/ \sum_{i=1}^{n} \mathrm{e}^{\beta x_i} \tag{4}$$

式中：β为平滑因子，当β趋近于无穷大时，SmoothReLU 即转换为标准的 ReLU 函数，当β趋近于 0 时则转换为算术平均函数；x_i 和 x_n 为取第 i 和 n 个 x 的值。

由于常见的激活函数均为 2 个输入参数，故设参数为 p_1x 及 p_2x，p_1 及 p_2 为可学习参数，且 $p_1\neq p_2$，则 Smooth ReLU 可转换为 ACON-C 激活函数，即：

$$\begin{aligned} f_{\text{ACON-C}} &= f_{\mathrm{SmoothReLU}}(p_1x,p_2x)= \\ &(p_1-p_2)x\sigma(\beta(p_1-p_2)x)+p_2x \end{aligned} \tag{5}$$

式中：σ为 Sigmoid 函数。

当取 p_1=1，p_2=1 时，可得 ACON-A 即 Swish 激活函数为：

$$f_{\text{ACON-A}} = f_{\mathrm{Swish}}(0,x) = x\times\sigma(\beta x) \tag{6}$$

由于 ACON 系列激活函数均通过β来控制神经元的激活，则引入自适应函数θ：

$$\theta = \sigma W_1 W_2 \sum_{h=1}^{H}\sum_{w=1}^{W} x_{c,h,w} \tag{7}$$

式中：W_1、W_2 分别代表 2 组与卷积层通道相关的超参数，其中 $W_1 \in \mathbf{R}^{C\times C/r_0}$，$W_2 \in \mathbf{R}^{C/r_0\times C}$；$C$ 为通道参数；c、h、w 分别为卷积层维度 C、H、W 编号。

函数首先将 x 在 H、W 维度求均值，而后通过 2 个卷积层将所有像素统一权重，最后利用 sigmoid 函数控制是否激活。

由式(5)和式(7)，可得到 Meta-ACON 激活函数为：

$$f_{\text{Meta-ACON}} = (p_1 - p_2)x\sigma(\beta(p_1 - p_2)x) + p_2 x \quad (8)$$

由于采用 LCNet 对 Backbone 部分进行替换后，可能会导致模型精度下降，而进行输电线路边缘端缺陷检测对精度有较高的需求，故如附图 A1 及图 1 所示，本文设计的 LEE-YOLOv7 将原版 YOLOv7 的 Neck 部分中 CBS 模块原有 SiLU 激活函数及 LCNet 的 DepthSeqConv 模块原有 Swish 激活函数替换为 Meta-ACON 激活函数，可以有效提高算法的识别准确率。

1.2.4 Wise-IoU 损失函数

原始 YOLOv7 算法使用的是完整交互比(complete-intersection over union，CIoU)损失函数进行预测框回归计算，CIoU 表达式如下所示：

$$\begin{cases} L_{\text{CIoU}} = 1 - L_{\text{IoU}} + \dfrac{\gamma^2(b,b^{\text{gt}})}{c^2} + \alpha v \\ v = \dfrac{\pi^2}{4}\left(\arctan\dfrac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan\dfrac{w}{h}\right)^2 \\ \alpha = \dfrac{v}{(1 - L_{\text{IoU}}) + v} \\ L_{\text{IoU}} = \dfrac{W_{\text{i}}H_{\text{i}}}{S} \end{cases} \quad (9)$$

式中：W_{i}、H_{i} 为重叠区域的宽度及高度；S 为两区域整体面积；w^{gt}、h^{gt}、w、h 分别为目标框及锚框的宽度及高度；$\gamma^2(b,b^{\text{gt}})$、$c$ 为两框中心点之间距离及两框最小外接矩形的对角线距离。CIoU 可以很好地反应边界框回归的重叠面积、中心点距离以及长宽比，但式中参数 v 代表长宽比的差异，而不是宽高比与其置信度的差异，从这一点上，在个别情况下会阻碍模型的有效优化。

本文选择 Wise-IoU 损失函数代替 CIoU 损失函数进行目标框回归的损失计算，Wise-IoU 损失函数表达式如下：

$$\begin{cases} L_{\text{WIoU}} = \exp\left(\dfrac{(x_{\text{ba}} - x_{\text{gt}})^2 + (y_{\text{ba}} - y_{\text{gt}})^2}{(W_{\text{g}}^2 + H_{\text{g}}^2)^*}\right) \times (1 - L_{\text{IoU}}) \\ L_{\text{IoU}} = \dfrac{W_{\text{g}}H_{\text{g}}}{S} \end{cases} \quad (10)$$

式中：x_{ba}、y_{ba}、x_{gt}、y_{gt} 分别表示锚框及目标框的中心点坐标；*表示计算图分离操作；W_{g}、H_{g} 为重叠区域的宽度及高度。

由于 Wise-IoU 通过距离度量构建了距离注意力，具有两层注意力机制，解决了 CIoU 将长宽比加入损失函数设计不合理的问题；同时，由于距离、纵横比等几何因素会增加对质量低的样本的惩罚，进而导致模型的泛化能力降低，Wise-IoU 通过分离最小包围框的宽高，削弱了几何因素的惩罚，故采用 Wise-IoU 替换 CIoU，实现了较少的训练干预，借此提高模型的泛化能力。

1.3 模型网络重构及优化

由于输电线路边缘端缺陷检测对算法模型实时性、推理速度的要求，需要对部署在边缘端设备的算法进行进一步优化及加速，故本文采用 DeepStream SDK 调用 TensorRT 深度学习推理引擎中的分组卷积及内存重用技术，实现对算法模型在推理过程中进行重构及优化加速，实现该模型计算效率的提升及计算量、内存占用量的降低。

1.3.1 分组卷积

分组卷积操作是一种卷积计算方法，通过将输入通道划分为多个小组，每个小组仅与一部分卷积核进行卷积操作，同 LCNet 的主要模块 DepthSeqConv 类似，分组卷积通过减少卷积计算量来实现达到减少计算量及模型占用内存的目的。

传统卷积操作针对整个输入数据进行计算，其计算量可根据式(1)求得，在输入数据及卷积核大小很大时，计算量及内存占用极大，很难应用于边缘段部署。

分组卷积则将输入通道分为 G 个小组，其计算量 J_{GConv} 可表示为：

$$J_{\text{GConv}} = \frac{C_{\text{in}}}{G} \cdot \frac{C_{\text{out}}}{G} HWC_H C_W G \quad (11)$$

由式(11)可知，通过分组卷积，计算量可减少为原来的 $1/G$ 倍，可显著提高模型计算效率，同时分组卷积还可以提高模型的并行计算能力及部署灵活性。

本文在模型部署于边缘端设备后进行推理的过程中引入分组卷积操作，将模型 Neck 部分的具有较大输入通道数的卷积层重构为分组卷积，进而提升模型的推理速度。

1.3.2 内存重用技术

内存重用技术是通过在模型推理过程中重用

已经分配的内存来避免内存分配及释放产生的大量性能开销，从而提高模型推理的速度，内存重用技术的原理如图 4 所示。

在输入数据进行第一个卷积操作后，结果存储在 GPU 内存中，常规模式下内存会在结果传输给下一个卷积层后释放并重新分配一个内存用以接收第二个卷积操作结果。采用内存重用技术，在结果传递给第二个卷积层后内存不会被释放，而是继续用于承接第二个卷积操作结果，从而有效减少频繁的内存释放分配造成的计算性能损失。

2 实验及分析

2.1 输电线路综合缺陷数据集

本文通过无人机拍摄、爬虫爬取互联网数据及各省市超高压或线路检修部分提供等方式获取了由无人机在不同角度、不同环境、不同巡检场景下拍摄的输电线路原始图像 22 万余张，并从中筛选得到清晰、无重复的输电线路缺陷航拍图像 5 923 张。在此基础上，对已有图像进行反转、镜像、缩放、裁剪、调整亮度等数据增强操作方法扩充样本数。最后用 LabelImg 标注软件进行手动标注，构建了包含 10 类常见缺陷的输电线路综合缺陷数据集，包括总计 10 156 张图片。其中螺母缺失、销钉缺失及销钉未闭锁为小目标类。数据集中训练集与测试集比例 8:2，缺陷种类及数量如图 5 及表 1 所示。

由图 5 可看出，数据增强后的数据集小目标数据量得到较大提高，总体样本数量相较于原始数据集更平衡，可以有效提高算法的鲁棒性及对螺母缺失、销钉缺失、销钉未锁等小目标缺陷识别的准确性。

2.2 性能评价指标

由于 LEE-YOLOv7 提出的目的在于轻量化模型的同时保证较高的检测精度，故本文采用帧率及推理时间对算法的速度进行评估；采用浮点运算量(FLOPs)及模型权重大小对算法的空间、时间复杂度进行评价；采用平均精度均值(mean average precision，mAP)对检测精度进行评估：

帧率指算法每秒钟可以处理的图像帧数，用于衡量算法的性能及效率，可直接反应算法的实时性和响应速度，同时本文通过式(12)利用帧率 N 计算单张图片推理时间为：

$$T_{\text{inference}} = 1/N \tag{12}$$

mAP 指所有类别的平均精度(average precision，AP)的平均值，用以衡量目标检测算法的综合

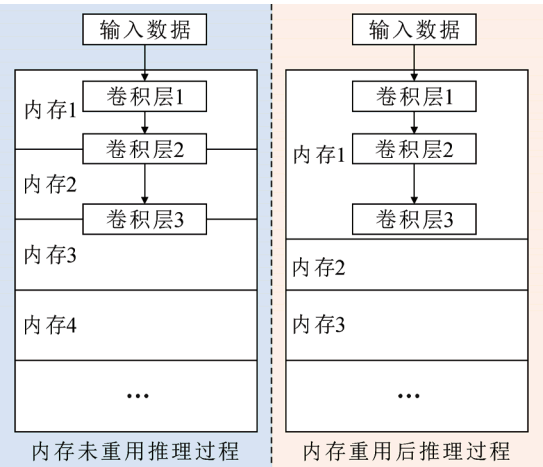


图 4 内存重用技术原理

Fig.4 Principle of memory reuse technology

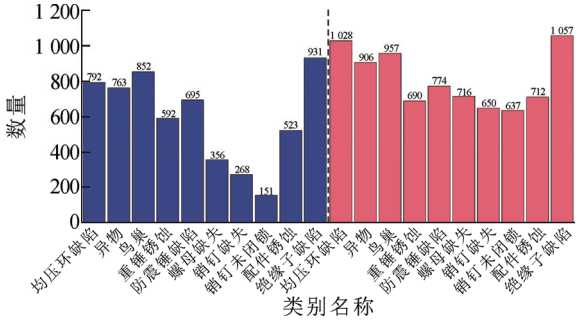


图 5 输电线路综合数据集

Fig.5 Comprehensive data set of digital power lines

表 1 数电线路综合数据集

Table 1 Comprehensive data set of digital power lines

缺陷类型	原始数据数量	扩充后训练集数量	扩充后测试集数量
均压环缺陷 RingDefect	792	1 028	257
异物 ForeignObject	763	906	226
鸟巢 BirdNest	852	957	239
重锤锈蚀 HeavyHamRust	592	690	172
防震锤缺陷 ShockHamDefect	695	774	193
螺母缺失(小目标) MissingNut	356	716	179
销钉缺失(小目标) MissingPin	268	650	162
销钉未锁(小目标) UnlockedPin	151	637	159
配件锈蚀 FittingRust	523	712	178
绝缘子缺陷 InsulatorDefect	931	1 057	264

性能，mAP 通过式(13)计算得到：

$$\begin{cases} X_{\mathrm{mAP}}=\dfrac{1}{n}\sum\limits_{i=1}^{n}X_{\mathrm{AP}_i} \\ X_{\mathrm{AP}}=\sum\limits_{i=1}^{n}\Delta R_i\times P_i \\ \Delta R_i=R_i-R_{i-1},R_0=0,P_0=1 \\ R=\dfrac{T_{\mathrm{P}}}{T_{\mathrm{P}}+\mathrm{F_N}} \\ P=\dfrac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}} \end{cases} \tag{13}$$

式中：R 为召回率；P 为查准率；T_{P}、F_{P}、F_{N} 分别为模型将正例判断为正例的数量、将负例判断为正例的数量、将正例判断为负例的数量。

本文采用 mAP@0.5 及 mAP@0.95，即在如式(9)所示交互比(intersection over union，IoU)阈值为 0.5 及 0.95 时的平均精度均值(mAP)作为检测精度的评价指标。

2.3 实验环境搭建及网络训练

2.3.1 实验环境搭建

本实验目标检测算法的训练环境及边缘端部署环境如表 2 所示。

本文基于边缘端模块、大疆 M210 无人机、图传模块搭建了 1 套可测试多种算法在实地输电线路进行缺陷识别的运行效果测试的实验系统，无人机信息传输模块将视频编码为 H.264 视频流，通过用户数据报协议(user datagram protocol，UDP)协议传输到边缘端模块，用边缘段模块部署深度学习算法(如 LEE-YOLOv7、YOLOv7 等)对无人机传入的数据进行实时识别诊断。

2.3.2 网络训练

本文网络训练的超参数设置如表 3 所示。

LEE-YOLOv7 及 YOLOv7 训练 Loss 曲线如图 6 所示。

由图 6 可见，由于 LEE-YOLOv7 采用 Wise-IoU 优化了 CIoU 损失函数，其收敛速度显著高于 YOLOv7。

YOLOv7 及 LEE-YOLOv7 对每个类别的检测的混淆矩阵如附图 A2 所示。由混淆矩阵可以看到，LEE-YOLOv7 对各个类别的查准率均达到 80%以上，具有较高的检测精度。

LEE-YOLOv7 及 YOLOv7 对实际现场拍摄图片检测效果如附图 A3 所示，LEE-YOLOv7 对遮挡类及背景复杂的相较于 YOLOv7 识别效果更精准，对小目标的识别准确率也较高。

表 2 算法训练环境及边缘端部署环境

Table 2 Algorithm training environment and edge-side deployment environment

硬件/软件/环境/项目名称	训练服务器	边缘端模块（Jetson Xavier NX）
CPU	E5 2690v4 x2 14C 28T 35 MB Cache	Nvidia Carmeal ARM v8.2 6C6T 6MB L2+4MB L3
GPU	GTX 1080ti x4	384 NVIDIA CUDA Core+48 Tensor Core
内存(RAM)	64GB DDR4 ECC	8GB LPDDR4
系统环境	Ubuntu 20.04 Focal Deepstream 6.1 Pytorch1.11 Cuda11.3+Cudnn8.7.0 Python 3.9.0	Jetpack 5.1.1 Deepstream 6.1 Cuda11.4 Python 3.8.10

表 3 网络训练超参数

Table 3 Network training hyperparameters

参数名称	参数设置
训练次数(epochs)	300
批次大小(batch-size)	64
初始学习率(learn-rate)	0.000 1
学习率动量(momentum)	0.937
权重衰减系数	0.000 5

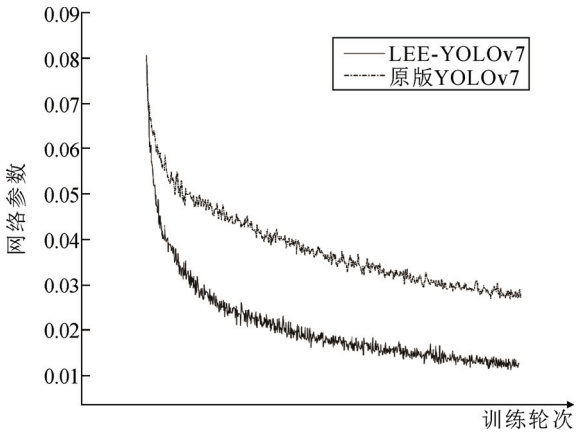


图 6 Loss 曲线图

Fig.6 Loss graph

2.4 主干网络替换对比实验

在进行输电线路缺陷诊断时需要将算法模型部署于边缘端设备，故对模型的轻量化具有很高的需求。为验证提出的 LCNet 替换主干网络对模型进行轻量化方法的合理性，本文分别将 YOLOv7 的主干网络替换为 ShuffleNetv2、MobileNetv2、MobileNetv3、EfficientNetv2 及 LCNet，并对以上 6 种网络进行对比实验，以验证采用轻量化网络替换主干网络后对

网络空间、时间复杂度及计算量、推理时间的影响。

实验中的 6 个网络均只针对主干网络进行改动，测试环境为边缘端模块 Jetson Xavier NX。

由表 4 可知，对 YOLOv7 进行主干网络替换形成的 5 种轻量化模型相比于原版 YOLOv7 模型检测速度均得到了提升、模型参数数量及运算量显著降低，但精度上也产生了不少的损失。其中，EfficientNetv2 的精度损失最小，但推理速度、GFLOPs、权重模型大小等参数均远逊于其他 4 种轻量化网络，帧率仅为 17，不能满足在边缘端部署并进行实时检测的需求；而 LCNet 虽然精度最低为 83.3%，但帧率达到 47，远高于其他 4 类轻量化网络，已初步满足实时检测的需求。

实验结果表明，采用 LCNet 对 YOLOv7 进行改进，可在精度降低不明显的情况下，实现模型的轻量化从而实现模型边缘端部署及在边缘端进行实时检测，实验结果证明了本文提出模型应用于输电线路边缘端进行实时缺陷检测的有效性。

对于主干网络替换为LCNet带来的模型精度大幅下降问题，本文后续通过引入 Meta-ACON 激活函数、Wise-IoU 损失函数及 Mosic-9 数据增强等方法进行补正。

2.5 LEE-YOLOv7 消融实验

为验证 LEE-YOLOv7 中各模块的作用，证明本文提出方法及采用 Mosic-9 等算法提高模型精度的有效性，进行了消融实验，在使用相同的超参数及训练流程的情况下，依次加入 Mosic-9 数据增强方法、LCNet 替换主干网络、Meta-ACON 激活函数及 Wise-IoU 损失函数，实验结果如表 5 所示：

1）采用 LCNet 替换主干网络，减少了 Backbone 部分模型参数及 FLOPs，去除了降低推理速度的操作，导致模型的 mAP@0.5 下降 6.4%，但推理速度大幅提高，检测速度提高了 32 帧/s，且模型权重减少 29.6 MB，显著提高了算法的运行速度。

2）加入 Mosic-9 数据增强方法后，增加了小目标输入数量，解决了不同尺度目标间不平衡问题，提高了小目标识别准确率，使算法的 mAP@0.5 从 83.1%提高到 84.9%，提高了 1.8%。

3）引入 Meta-ACON 替换部分激活函数后，模型 mAP@0.5 上升了 3.2%，提高了 8，单张图片推理时间减少 3.1 ms，这是由于 Meta-ACON 使模型可以对每个特征图学习标准化范围及偏置，可以有效提高网络性能。

4）采用 Wise-IoU 替换 CIoU 损失函数，由于减少了对模型训练的干预，有效提升了模型的泛化能力，在保证推理速度没有明显下降的情况下，使模型的 mAP 提升 4.2%，最终的模型在准确率及推理速度上均优于原版 YOLOv7 模型。

2.6 检测算法对比实验

为验证本文提出的 LEE-YOLOv7 在同类方法

表 4 主干网络替换对比实验

Table 4 Backbone Network Replacement Comparison test

主干改进	mAP@0.5/%	mAP@0.95/%	检测速度/(帧·s^{-1})	GFLOPs	模型权重大小//MB
无改进	89.5	51.4	15	104.7	71.5
MobileNetv2	85.1	49.7	29	67.3	65.2
MobileNetv3	85.6	50.5	26	70.2	63.1
ShuffleNetv2	83.7	48.9	38	56.2	47.9
EfficientNetv2	88.6	51.2	17	98.9	69.6
LCNet	83.1	48.4	47	48.1	41.9

表 5 LEE-YOLOv7 消融实验结果

Table 5 Results of LEE-YOLOv7 ablation experiments

LCNet	Mosic-9	Meta-ACON	Wise-IoU	mAP@0.5/%	mAP@0.95/%	检测速度/(帧·s^{-1})	GFLOPs	模型权重大小/MB
				89.5	51.4	15	104.7	71.5
√				83.1	48.4	47	48.1	41.9
√	√			84.9	50.1	47	48.9	41.9
√	√	√		88.1	50.9	55	45.2	39.7
√	√	√	√	92.3	52.9	53	46.3	40.1

中的优势，在构建的输电线路综合缺陷数据集对 YOLOv6、YOLOv5、Faster RCNN、DETR、YOLOv7 及 2 种输电线路缺陷诊断方法[29-30]采用相同的超参数进行训练并在边缘段设备进行测试，测试结果如表 6 所示。

由表 6 可以看出，Faster RCNN 在各项参数上均劣于其他算法，特别是推理时间长、帧率低，并不适用于边缘端设备部署；YOLOv5 算法是最流行的目标检测算法之一，在精度及速度上达到了很好的平衡；DETR 算法由于 TransFormer 会在 Backbone 特征图上进行个体注意力(Self-Attention)，故对输电线路大目标缺陷的识别效果好，效果较 YOLOv5 提升明显，但对输电线路小目标缺陷的识别准确率相对较低。YOLOv6 在 YOLOv5 的基础上加入了 anchor free 检测头，并采用了 SIoU loss，在精度及速度上相较于 YOLOv5 提升明显。文献[29]提出的 YOLOv5-Lite 算法实现了在边缘端上以 62 帧/s 的速度进行缺陷检测，但检测精度较低，mAP@0.5 仅为 71.1%，对小目标的识别率仅为 46.9%，不能满足精准实时检测的需要；文献[30]提出的改进 YOLOv5 为实现提高小目标检测精度及网络轻量化目标进行改进的目标检测算法，小目标检测率相较于原版 YOLOv5 提高了 6.54%，达到 65.67%；而本文提出的 LEE-YOLOv7 算法，在 mAP 最高的情况下，实现了在边缘端设备上 53 帧/s 的检测速度，远超于其他检测算法，可以满足输电线路高实时性、高性能、高准确率边缘端检测的需求。

2.7 模型网络重构及优化消融实验

采用分组卷积及内存重用技术对模型进行优化后并在边缘端设备进行测试的消融实验结果如表 7 所示。

由表 7 可知，采用分局卷积对 LEE-YOLOv7 进行优化后，mAP 产生小幅下降，下降 1.6%，这是由于分组卷积会丢失一部分特征信息，从而导致精度下降，但检测速度提高到 68 帧/s，提高了 15，推理时间减少 4.2 ms，且模型 GFLOPs 减少 0.4，模型体积显著缩小；通过内存复用技术后，LEE-YOLOv7 在精度未损失的情况下，检测速度达到 79 帧/s。

综合以上结果可发现，采用分组卷积及内存重用技术对 LEE-YOLOv7 进行优化后，算法在边缘端设备上的推理速度提高了 25.9%，达到 1.5 ms/张，检测速度达到 79 帧/s，可以实现边缘端实时视频流检测，可以满足无人机电力巡检对实时性的需求。

3 结论

本文提出了一种基于 LEE-YOLOv7 的输电线路边缘端检测方法，通过多种实验分析，主要结论如下：

1）提出的 LEE-YOLOv7 算法实现了较原版 YOLOv7 更快的收敛速度，推理速度提高了 253%，且 mAP@0.5 提高了 2.8%，达到 92.3%，实现了对背景复杂、遮挡的缺陷更好的检测效果。

表 6 算法对比实验

Table 6 Algorithm comparison test

算法	小目标类 mAP@0.5/%	大目标类 mAP@0.5/%	mAP@0.5/%	mAP@0.95/%	检测速度/(帧·s^{-1})	GFLOPs	模型权重大小/MB
YOLOv5	59.13	93.51	83.2	46.3	27	49.0	70.2
YOLOv6	65.27	95.74	86.5	49.6	19	85.8	130.1
DETR	60.43	96.67	85.8	49.2	8	101.21	159
Faster RCNN	53.27	85.03	75.1	41.9	4	79.2	65.1
YOLOv7	73.74	96.26	89.5	51.4	15	104.7	71.5
YOLOv5-Lite[29]	46.90	81.47	71.1	37.2	62	3.6	25.1
改进 YOLOv5[30]	65.67	94.86	86.1	49.6	38	10.8	30.7
LEE-YOLOv7	79.64	97.73	92.3	52.9	53	46.3	40.1

表 7 Deepstream 技术优化消融实验

Table 7 Deepstream technology optimized ablation experiments

分组卷积	内存重用	mAP@0.5/%	mAP@0.95/%	检测速度/(帧·s^{-1})	GFLOPs
		92.3	52.9	53	2.3
√		91.2	52.3	68	1.9
√	√	91.2	52.3	79	1.9

2）提出的 LEE-YOLOv7 算法相较于多种经典算法及同类输电线路缺陷检测方法，实现了在边缘端最高的检测精度及高达 53 帧/s 的检测速度。

3）提出的采用 Deepstream 技术调用 TensorRT 深度学习推理引擎重构优化算法模型在边缘端设备上的检测速度及性能，实现了在检测精度基本未变的情况下，检测速度较未优化前提升了 49%，帧率达到了 79，且空间复杂度减少了 17%，实现了在边缘端设备上实时的输电线路缺陷检测，显著提高了输电线路边缘巡检的效率。

附录见本刊网络版(http://hve.epri.sgcc.com.cn)。

参考文献 References

[1] NGUYEN V N, JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: a review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107-120.

[2] 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.

[3] 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.

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

[5] 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.

[6] 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.

[7] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]// Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 7263-7271.

[8] FARHADI A, REDMON J. Yolov3: An incremental improvement[C]// Computer vision and pattern recognition. Berlin/Heidelberg, Germany: Springer, 2018, 1804: 1-6.

[9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[M/OL]. arXiv, 2020 [2023-03-10]. https://arxiv. org/abs/2004.10934.

[10] WANG C Y, YEH I H, LIAO H Y M. You only learn one representation: Unified network for multiple tasks[M/OL]. arXiv 2021 [2023-03-10]. https://arxiv.org/abs/2105.04206.

[11] GE Z, LIU S T, WANG F, et al. YOLOX: exceeding YOLO series in 2021[M/OL]. arXiv 2021[2023-03-10]. https://arxiv.org/abs/2107.08430.

[12] LI C Y, LI L L, JIANG H L, et al. YOLOv6: a single-stage object detection framework for industrial applications[M/OL]. arXiv 2022[2023-03-10]. https://arxiv.org/abs/2209.02976.

[13] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]// Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer, 2020: 213-229.

[14] 李帷韬，侯建平，张 倩，等. 基于强化学习和 Transformer 的输电线路缺陷智能检测方法[J]. 高电压技术，2023，49(8)：3373-3384.
LI Weitao, HOU Jianping, ZHANG Qian, et al. Research on intelligent detection method of transmission line defects based on reinforcement learning and transformer[J]. High Voltage Engineering, 2023, 49(8): 3373-3384.

[15] 赵振兵，熊 静，李 冰，等. 基于改进 Cascade R-CNN 的典型金具及其部分缺陷检测方法[J]. 高电压技术，2022，48(3)：1060-1067.
ZHAO Zhenbing, XIONG Jing, LI Bing, et al. Typical fittings and its partial defect detection method based on improved cascade R-CNN[J]. High Voltage Engineering, 2022, 48(3): 1060-1067.

[16] 郝 帅，杨 磊，马 旭，等. 基于注意力机制与跨尺度特征融合的 YOLOv5 输电线路故障检测[J]. 中国电机工程学报，2023，43(6)：2319-2330.
HAO Shuai, YANG Lei, MA Xu, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion[J]. Proceedings of the CSEE, 2023, 43(6): 2319-2330.

[17] 余沿臻，邱志斌，周银彪，等. 基于卷积神经网络与 ECOC-SVM 的输电线路异物检测[J]. 智慧电力，2022，50(3)：87-92，107.
YU Yanzhen, QIU Zhibin, ZHOU Yinbiao, et al. Foreign body detection for transmission lines based on convolutional neural network and ECOC-SVM[J]. Smart Power, 2022, 50(3): 87-92, 107.

[18] 韩 青，高昆仑，赵 婷，等. 边云协同智能技术在电力领域的应用[J]. 物联网学报，2021，5(1)：62-71.
HAN Qing, GAO Kunlun, ZHAO Ting, et al. Application of edge-cloud collaborative intelligence technologies in power grids[J]. Chinese Journal on Internet of Things, 2021, 5(1): 62-71.

[19] 汤 璐，王淑青，金浩博，等. 基于改进 Xception 方法的绝缘子识别[J]. 智慧电力，2022，50(2)：69-74.
TANG Lu, WANG Shuqing, JIN Haobo, et al. Insulator identification based on improved Xception method[J]. Smart Power, 2022, 50(2): 69-74.

[20] 姚 楠，刘子全，秦剑华，等. 基于电力物联网的边缘计算任务卸载优化[J]. 科学技术与工程，2022，22(16)：6577-6584.
YAO Nan, LIU Ziquan, QIN Jianhua, et al. Offloading optimization of the edge computing task based on the power internet of things[J]. Science Technology and Engineering, 2022, 22(16): 6577-6584.

[21] 周振宇，陈亚鹏，潘 超，等. 面向智能电力巡检的高可靠低时延移动边缘计算技术[J]. 高电压技术，2020，46(6)：1895-1902.
ZHOU Zhenyu, CHEN Yapeng, PAN Chao, et al. Ultra-reliable and low-latency mobile edge computing technology for intelligent power inspection[J]. High Voltage Engineering, 2020, 46(6): 1895-1902.

[22] 官国飞，宋庆武，刘 恢，等. 基于边缘计算的配网管理和运维体系研究[J]. 电网与清洁能源，2020，36(10)：90-96.
GUAN Guofei, SONG Qingwu, LIU Hui, et al. Research on distribution network management and operation and maintenance system based on edge computing[J]. Power System and Clean Energy, 2020, 36(10): 90-96.

[23] 胡金磊，朱泽锋，林孝斌，等. 变电站无人机机巡边缘计算框架设计及资源调度方法[J]. 高电压技术，2021，47(2)：425-433.
HU Jinlei, ZHU Zefeng, LIN Xiaobin, et al. Framework design and resource scheduling method for edge computing in substation UAV inspection[J]. High Voltage Engineering, 2021, 47(2): 425-433.

[24] 马富齐，王　波，董旭柱，等. 面向输电线路覆冰厚度辨识的多感受野视觉边缘智能识别方法研究[J]. 电网技术，2021，45(6)：2161-2169.
MA Fuqi, WANG Bo, DONG Xuzhu, et al. Receptive field vision edge intelligent recognition for ice thickness identification of transmission line[J]. Power System Technology, 2021, 45(6): 2161-2169.

[25] 金潮伟. 基于边缘计算和改进 SSD 算法的输电线路设备缺陷智能诊断[D]. 北京：华北电力大学(北京)，2021.
JIN Chaowei. Intelligent diagnosis of defects of high voltage equipment based on edge computing and improved SSD algorithm[D]. Beijing, China: North China Electric Power University (Beijing), 2021.

[26] 刘　闽，李　喆，李曜丞，等. 基于重参数化 YOLOv5 的输电线路缺陷边缘智能检测方法[J]. 高电压技术，2024，50(5)：1954-1966.
LIU Min, LI Zhe, LI Yaocheng, et al. Transmission line defect edge intelligent inspection method based on re-parameterized YOLOv5[J]. High Voltage Engineering, 2024, 50(5): 1954-1966.

[27] DAI L Y, LIU G, HUANG L, et al. Feature transfer method for infrared and visible image fusion via fuzzy lifting scheme[J]. Infrared Physics & Technology, 2021, 114: 103621.

[28] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE, 2023.

[29] 颜宏文，万俊杰，潘志敏，等. 基于改进 YOLOv5-LITE 轻量级的配电组件缺陷识别[J]. 高电压技术，2024，50(5)：1855-1864.
YAN Hongwen, WAN Junjie, PAN Zhimin, et al. Defect identification of distribution components based on improved YOLOv5-LITE lightweight[J]. High Voltage Engineering, 2024, 50(5): 1855-1864.

[30] 郝　帅，张　旭，马　旭，等. 基于 PKAMNet 的输电线路小目标故障检测方法[J]. 高电压技术，2023，49(8)：3385-3394.
HAO Shuai, ZHANG Xu, MA Xu, et al. Small target fault detection method for transmission lines based on PKAMNet[J]. High Voltage Engineering, 2023, 49(8): 3385-3394.



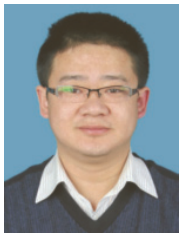
胡晨龙
2000—，男，硕士生
主要研究方向为电气设备在线监测及故障诊断
E-mail: hcl0001@yeah.net

HU Chenlong



裴少通(通信作者)
1990—，男，博士，讲师，硕导
主要研究方向为电气设备的智能故障检测与诊断技术
E-mail: peishaotong@ncepu.com

PEI Shaotong
Ph.D.
Corresponding author



刘云鹏
1976—，男，博士(后)，教授，博导
主要从事特高压输电技术、电气设备绝缘机理和电气设备在线监测等方向的研究工作
E-mail: liuyunpeng@ncepu.edu.cn

LIU Yunpeng
Post-doctorate
Professor

收稿日期　2023-05-25　修回日期　2024-07-25　　编辑　卫李静

附录 A

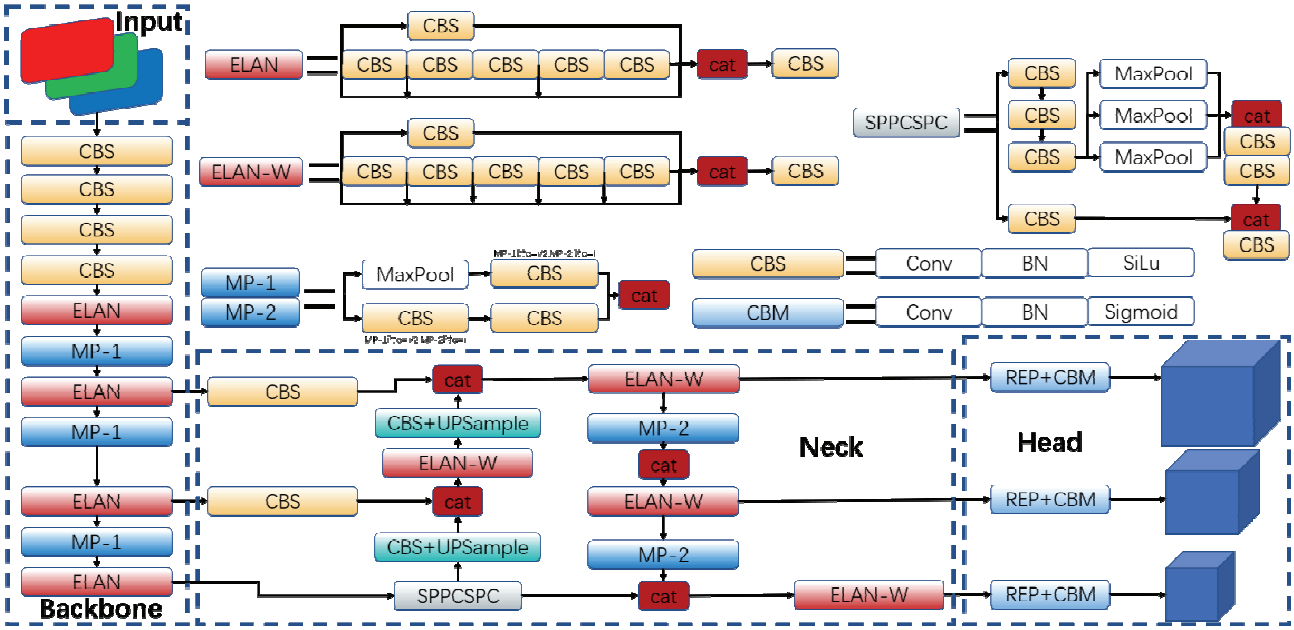


图 A1　原版 YOLOv7 网络结构图

Fig.A1　Structure diagram of original YOLOv7 network

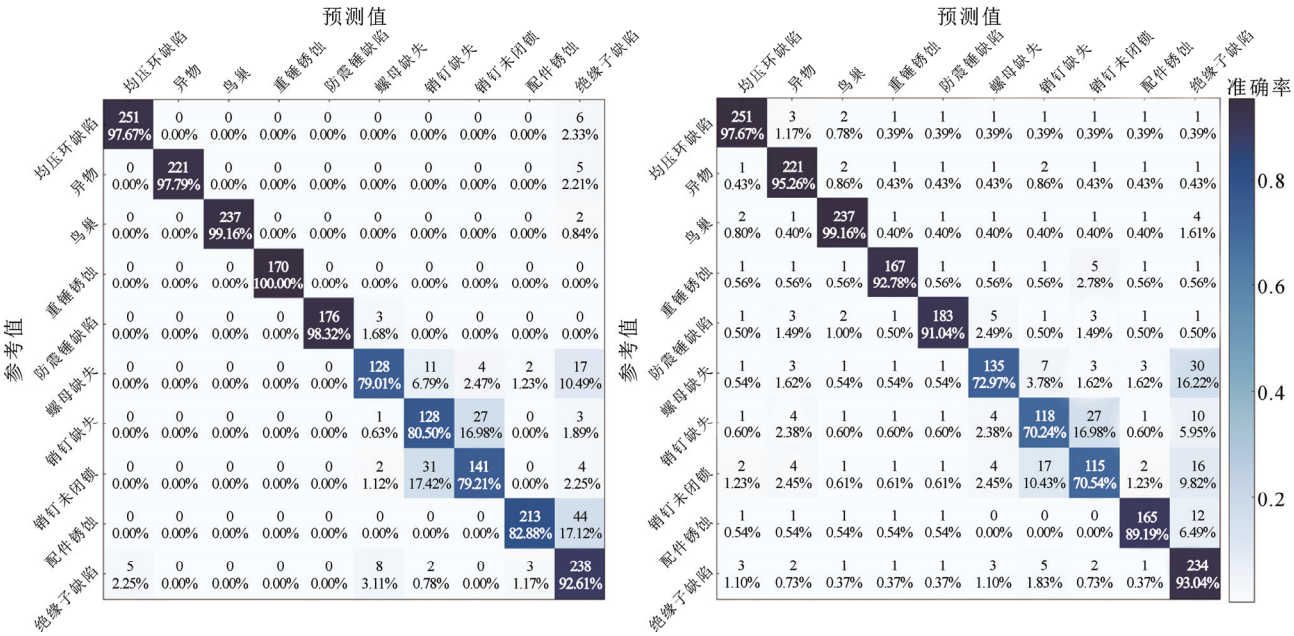


图 A2　混淆矩阵

Fig.A2　Confusion matri



图 A3　YOLOv7(左)及 LEE-YOLOv7(右)检测对比图

Fig.A3　Detection comparison diagram of YOLOv7 (left) and LEE-YOLOv7 (right)