

doi:10.6041/j.issn.1000-1298.2023.04.031

基于改进 YOLO v4 的落叶松毛虫侵害树木实时检测方法

林文树 张金生 何乃磊

(东北林业大学机电工程学院, 哈尔滨 150040)

摘要: 针对 two-stage 网络模型训练成本高, 无人机搭载的边缘计算设备检测速度低等问题, 提出一种基于改进 YOLO v4 模型的受灾树木实时检测方法, 以提高对落叶松毛虫虫害树木的识别精度与检测速度。以黑龙江省大兴安岭地区呼玛县白银纳乡受落叶松毛虫侵害的落叶松无人机图像为数据, 利用 LabelImg 软件标注 75~100 m 的无人机图像, 构建落叶松毛虫虫害树木图像数据集。将 CSPNet 应用于 YOLO v4 模型的 Neck 架构, 重新设计 Backbone 的特征提取网络——CSPDarknet53 模型结构, 并在 CSPNet 进行优化计算前的卷积中加入 SENet 以增加感受野信息, 使其改变网络的深度、宽度、分辨率及网络结构, 实现模型缩放, 提高检测精度。同时, 在 PANet 中使用 CSPConvs 卷积代替原有卷积 Conv × 5, 最后经过 YOLO Head 检测输出预测结果。将 YOLO v4 – CSP 网络模型部署至 GPU 进行训练, 训练过程的内存降低至改进前的 82.7%。再搭载至工作站进行测试, 结果表明: 改进的 YOLO v4 – CSP 网络模型在测试阶段对虫害树木检测的正确率为 97.50%, 相比于 YOLO v4 的平均正确率提高 3.4 个百分点, 模型精度接近目前主流 two-stage 框架 Faster R – CNN 的 98.75%; 将改进的 YOLO v4 – CSP 网络模型搭载至 Jetson nano 边缘计算设备, 检测速度达到 4.17 f/s, 高于 YOLO v4 模型的 1.72 f/s。基于 YOLO v4 – CSP 的检测模型可实现对受灾树木检测速度与精度的平衡, 降低模型的应用成本, 搭载至无人机可实现对森林虫害的实时监测。

关键词: 落叶松毛虫; 实时监测; 无人机; YOLO v4

中图分类号: S763.3 文献标识码: A 文章编号: 1000-1298(2023)04-0304-09

OSID: 

Real-time Detection Method of *Dendrolimus superans*-infested *Larix gmelinii* Trees Based on Improved YOLO v4

LIN Wenshu ZHANG Jinsheng HE Nailei

(College of Mechanical and Electrical Engineering, Northeast Forestry University, Harbin 150040, China)

Abstract: Aiming at the problems of high training cost of two-stage network model and low detection speed of edge computing equipment attached on UAV, a real-time detection method based on the improved YOLO v4 model was proposed in order to improve the recognition accuracy and detection speed for *Dendrolimus superans*-infested *Larix gmelinii* trees. Taking the UAV images of *Larix gmelinii* infested by *Dendrolimus superans* obtained from Baiyinna Township, Huma County in the Daxing'anling District of Heilongjiang Province as data, the UAV images at 75~100 m were marked with LabelImg software, and a data set of tree images infested by *Dendrolimus superans* was constructed. CSPNet was applied to the Neck architecture of the YOLO v4 model, the Backbone's feature extraction network—CSPDarknet53 model structure was redesigned, and SENet was added to the convolution before CSPNet optimization calculations to increase the receptive field information, making it change the depth, width, resolution and structure of the network to achieve model scaling and improve detection accuracy. Meanwhile, CSPConvs convolution was used in PANet to replace the original convolution Conv × 5, and finally the prediction result was output through YOLO Head detection. After deploying the YOLO v4 – CSP network model to the GPU for training, the memory of the training process was reduced to 82.7% of that before improvement. The improved model was installed on the workstation for testing. Results showed that the accuracy of tree detection was 97.50%, which was 3.4 percentage points higher than the average detection accuracy of YOLO v4, and close to 98.75% of the current mainstream two-stage framework Faster R – CNN. When attached to Jetson nano edge computing equipment, the detection speed was

收稿日期: 2022-06-17 修回日期: 2022-07-28

基金项目: 黑龙江省自然科学基金联合引导项目(LH2020C049)

作者简介: 林文树(1980—), 男, 教授, 博士生导师, 主要从事林业遥感研究, E-mail: linwenshu@nefu.edu.cn

4.17 f/s, higher than the 1.72 f/s of YOLO v4 model. Therefore, the proposed detection model based on YOLO v4 – CSP can achieve balance between detection speed and detection accuracy for the *Dendrolimus superans*-infested *Larix gmelinii* trees, reduce application cost of the model, and realize real-time monitoring of forest pests when attached to UAV.

Key words: *Dendrolimus superans*; real-time monitoring; UAV; YOLO v4

0 引言

落叶松毛虫 (*Dendrolimus superans* Butler) 属鳞翅目、枯叶蛾科, 广泛分布于我国内蒙古、东北三省及新疆北部地区, 是我国常见虫害之一^[1], 每年因落叶松虫害引发的木材生长量减少 $2.76 \times 10^6 \sim 3.68 \times 10^6$ m³^[2]。落叶松毛虫幼虫于春季气温 8 ~ 10℃ 时开始上树, 大面积爆发时造成林区树木成片死亡^[3], 制约了我国林业的可持续发展, 危害森林生态健康。

针对虫害树木检测, 目前主要有人工普查、遥感卫星监测及无线网络传感器传输等方法。人工普查需要深入林区研究检测, 效率低效果差, 存在一定危险性; 遥感卫星针对大片林区可实现动态监测, 但针对局部地区细微变化无法及时做出反应; 无线网络传感器只能作用于地面, 监测范围小。无人机可携带多种传感器及探测设备, 可以按照飞行系统的预定设计航线执行飞行指令, 小型轻便且成本较低^[4~5]。无人机采集的光谱影像数据对虫害早期判断有一定优势, 但实时性差, 不能及时对虫灾发生位置做出判断^[6]。相比而言无人机影像更能直观地反映虫灾发生位置, YUAN 等^[7]利用采集的林区图像划分超像素, 将超像素中的纹理特征作为分割依据, 利用随机森林进行分类取得了明显效果。张军国等^[8]基于分水岭算法对林区图像进行分割, 并对过分割区域进行融合, 实现了虫害区域提取。LEE 等^[9]使用无人机在松材线虫病疫区采集高分辨率图像, 并使用人工神经网络 ANN 和支持向量机技术监测松材线虫病致死、致枯萎的松树。以上传统的机器学习算法依赖人工提取特征, 借助颜色纹理特征对图像阈值分割, 存在一定的误判, 因此需要借助更多特征来对虫害进行定义。深度学习^[10]中的目标检测借助更深的网络层, 能有效拟合非线性数据^[11], 可充分利用图像信息定义虫害目标。

计算机视觉中应用广泛的目标检测方法主要分为 one-stage 和 two-stage 方法。two-stage 代表性方法是 R – CNN^[12~13] (Region – CNN) 系列, 如 R – CNN、Fast R – CNN、Faster R – CNN^[14~15]。在精度上, two-stage 优于 one-stage 方法, 但在实时检测速度上, one-stage 占优势。考虑到边缘计算平台算力,

本文选用处理速度更快、实时性更好的 YOLO (You only look once) 系列网络^[16]。在 YOLO 的更新迭代中, YOLO v4^[17~18] 在 YOLO v3 的基础上融合跨阶段局部网络 (Cross stage partial network, CSPNet)^[19] 进行优化, 在提高精度的同时减少了模型计算量。因此, 本文根据 CSPNet 网络特性, 在 YOLO v4 模型的路径聚合网络 (Path aggregation network, PAnet)^[20] 层融入 CSPNet 网络结构, 并预先使用 K-means 聚类得出的目标物像素修改锚框 (Anchor) 大小, 提出一种基于深度学习的落叶松虫害树木目标检测方法, 以期对落叶松毛虫虫害做出最优检测结果。

1 数据集构建

落叶松毛虫虫害图像数据采集于黑龙江省大兴安岭地区呼玛县白银纳乡 (新林区森林公园与呼玛县白银纳村林区)^[21], 拍摄图像的各项参数均引自文献^[21]。图 1 为采集的航拍图像。为保证图像清晰可用, 以及虫害目标占据图像范围适中, 设定采集高度为 75 ~ 100 m。落叶松毛虫顶端取食, 从航拍图像可以看出感染虫害的落叶松呈灰黑色。

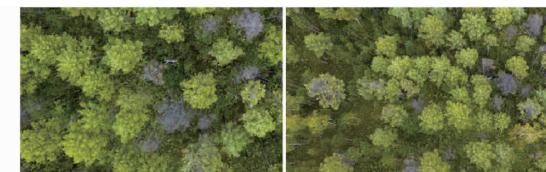


图 1 航拍图像示例

Fig. 1 Sample of aerial photographs

研究区内存在少部分枯死树木, 单一目标检测可能会对部分枯死树木产生误检。为提高模型泛化性, 选择增加枯死树木在数据集中的数量, 因此在标注落叶松毛虫虫害树木的同时, 添加部分哈尔滨市城市林业示范基地中落叶松的枯死树作为干扰项。如图 2 所示按照 Mosaic 数据增强算法拼接部分虫害树木目标与枯死树目标, 并使用 LabelImg 对落叶松毛虫虫害与枯死树目标进行标注。构建 Pascal VOC^[22] 格式数据集并进行转换, 标定的矩形框内包含落叶松毛虫虫害树木目标或者枯死树目标, 当标注目标位于边缘或被裁剪为多个目标时, 则标记该目标为困难样本。标注完成后, 经复核, 部分有异议的图像与人工

标注完成后, 经复核, 部分有异议的图像与人工



图 2 Mosaic 变换及 LabelImg 标注图像

Fig. 2 Mosaic transformation and LabelImg labeling image

地面调查相结合,确定是否为落叶松毛虫虫害树木目标,最后由混合拼接后图像与裁剪图像制作落叶松毛虫虫害数据集。

2 YOLO v4 模型及改进

2.1 YOLO v4 模型

YOLO v4 模型结构如图 3 所示,由 Backbone、空间金字塔池化(Spatial pyramid pooling, SPP)、路

径聚合网络(PANet)与 YOLO Head 检测器组成。输入图像首先在经过一次卷积后进入 Backbone 层,Backbone 的主干网络为 CSPDarknet53,模型训练过程中,输入图像由 5 次残差网络训练,经过下采样后,原输入图像大小由 $640 \times 640 \times 3$ 变为 $80 \times 80 \times 256$ (特征层 1)、 $40 \times 40 \times 512$ (特征层 2)、 $20 \times 20 \times 1024$ (特征层 3),得到虫害的语义特征,其中生成的语义特征经空间金字塔池化层全局池化后可实现不同尺度的特征融合。PANet 在特征金字塔网络(Feature pyramid networks, FPN)的基础上添加了一个自底而上的金字塔网络结构,来融合高层的特征语义信息与底层的定位信息,一部分接收来自 CSPDarknet53 的特征图像进行语义信息提取,另一部分接收 SPP 卷积后生成的特征图进行定位信息语义特征提取,在经过主干网络不断上下采样堆叠后更好地获得特征,最终分别由 3 个 YOLO Head 预测分类输出大、中和小 3 种尺寸预测图像。

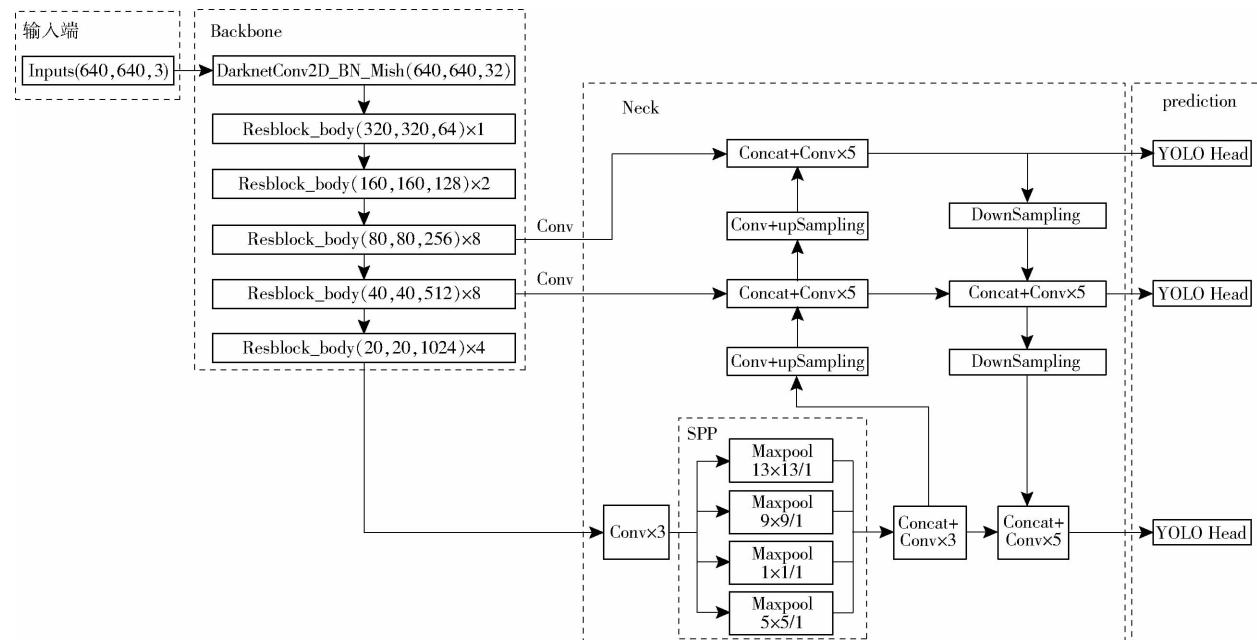


图 3 YOLO v4 模型结构

Fig. 3 YOLO v4 model structure

训练时采用 Mosaic 数据增强方法,从所有数据集中随机选择 4 幅图像随机缩放、裁剪、组合拼接来丰富检测物体的背景信息。重复一定次数后原先的 1 幅训练图像中融入了干扰信息(图 4),并且 1 个批次训练 1 幅图像变为同时训练 4 幅,原本图像中的目标经过 Mosaic 增强后缩小,增加训练效率同时解决 one-stage 模型对小目标漏检问题。Dropout 在训练时每一层随机失活神经元以防止过拟合,这种特性被广泛地用作全连接层的正则化技术。针对卷积网络,需要一种结构形式的 Dropout 正则化按块丢弃,因此选用 Dropblock 来优化卷积层。

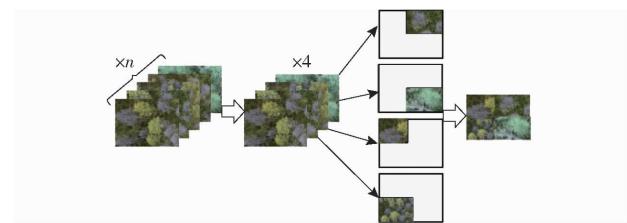


图 4 Mosaic 数据增强

Fig. 4 Mosaic data augmentation

2.2 改进方法

2.2.1 主干网络优化

训练过程中冗余的梯度信息可通过在 YOLO v4 网络中融合 CSPNet(图 5)解决。CSPNet 由多个

1×1 的卷积组成, 通过并联到网络结构的 Conv 层, 将原图像特征分为两部分, 一部分继续卷积提取特征信息, 另一部分则通过 1×1 的卷积直接进入下一层, 随后将两部分的特征图连接起来, 再进行转换操作。采用该策略, 将会大量减少计算量, 提高推理速度。另外不同特征层的拼接重用也会提高模型对目标的泛化性, 提高准确度。CSPDarknet53 的卷积层是由 Darknet53 卷积层融合 CSPNet 形成的 Resblock_body 结构(图 6), 使用 CSPNet 优化 Darknet53 可以减少计算量, 同时提高推理速度和准确度^[24]。因此本研究在 Backbone 部分采用 CSPNet1 网络(图 5)优化 Darknet53 结构。根据文献[24]得知, 当图 6 中残差结构 Residual 的数量 n 大于 1 时, Resblock_body 结构才会比 DarknetConv 有更少的计算量, 因此将 CSPDarknet53 结构中的第 1 层 Resblock_body 改回 DarknetConv 结构, 这样既保留了 Resblock_body 结构, 达到精简模型参数的目的, 又简化了模型复杂度。同样如图 7 所示, 在 PANet 的 Conv $\times 5$ 结构中使用 CSPNet2 网络进行优化, 减少梯度信息重用, 提高运算速度。

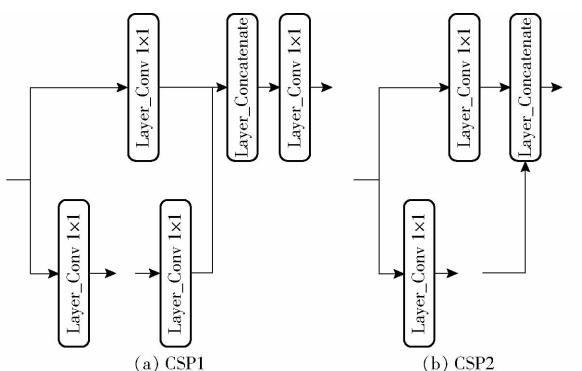


图 5 CSPNet 网络结构

Fig. 5 CSPNet network structure

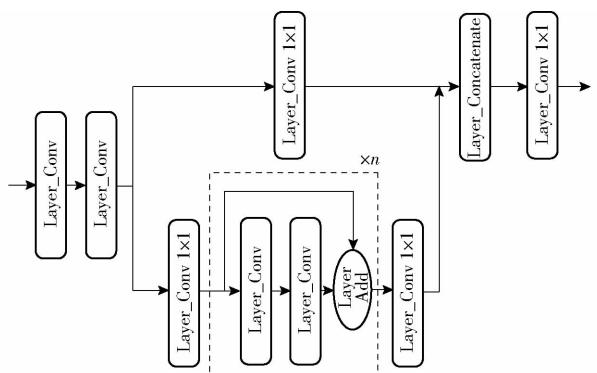


图 6 CSPDarknet53 卷积层结构

Fig. 6 CSPDarknet53 convolutional layer structure

增加 SENet(Squeeze-and-excitation networks)注意力机制, SE 模块如图 8 所示。图像输入网络后, 通过一系列的卷积变换后得到一个特征通道数为 C 的特征, 然后特征传入 SE 模块, 首先进行压缩操

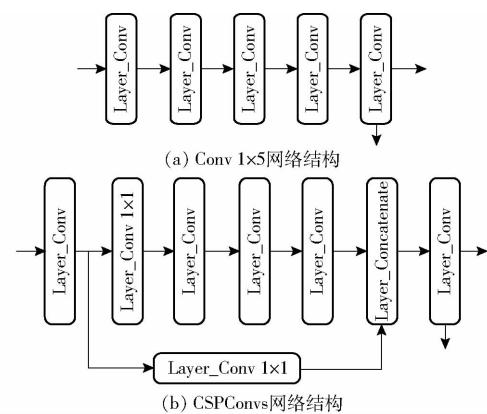
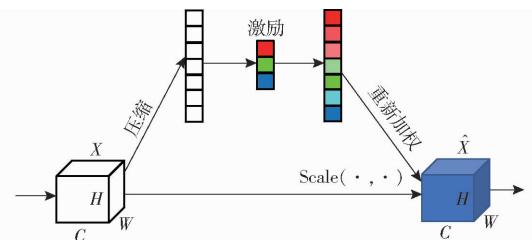
图 7 Conv $\times 5$ 插入 CSPNet 网络结构Fig. 7 Conv $\times 5$ inserted into CSPNet network structure

图 8 SENet 结构图

Fig. 8 SENet structure diagram

作:顺着空间维度进行特征压缩, 将每个二维的特征通道变换为一个实数, 并且使输出维度与输入特征通道数匹配, 这样让靠近输入的层也可以获得全局感受野;下一步进行激励操作, 通过学习参数 W 来为每个特征通道生成权重用来定义模型通道间的相关性;最后进行重新加权操作, 将激励输出的权重通过乘法通道加权至先前特征中, 完成对原始特征的重新标定, 以此来增加感受野大小。

将 SENet 加入 CSPDarknet53 结构如图 9 所示, 在 CSPNet 网络前加入 SENet 结构, 这使得模型在增加了网络深度的同时并不会带来较大的计算量。

优化模型自适应图像缩放算法。原图像尺寸为 1 330 像素 \times 1 000 像素, YOLO v4 训练前首先需要将图像尺寸缩放到 640 像素 \times 640 像素, 采用等尺度缩放后空白处填充 0 操作后生成 640 像素 \times 640 像素图像, 这种填充方式会使填充后空白面积占比增大(图 10), 造成信息冗余, 降低推理速度。本文通过训练前对 datasets.py 文件中 Letterbox 函数进行修改, 对图像长的一侧缩放至 640 像素, 小边则按照长边缩放度为标准, 以 32 的倍数同等缩放, 生成尺寸 640 像素 \times 480 像素图像, 缩放的同时既保留图像完整信息, 也尽可能地减少空白的填充, 降低冗余度, 提升训练速度。

2.2.2 改进后的 YOLO v4 - CSP 网络

改进后的 YOLO v4 - CSP 如图 11 所示, Backbone 部分采用增加 SENet 模块并改进结构后

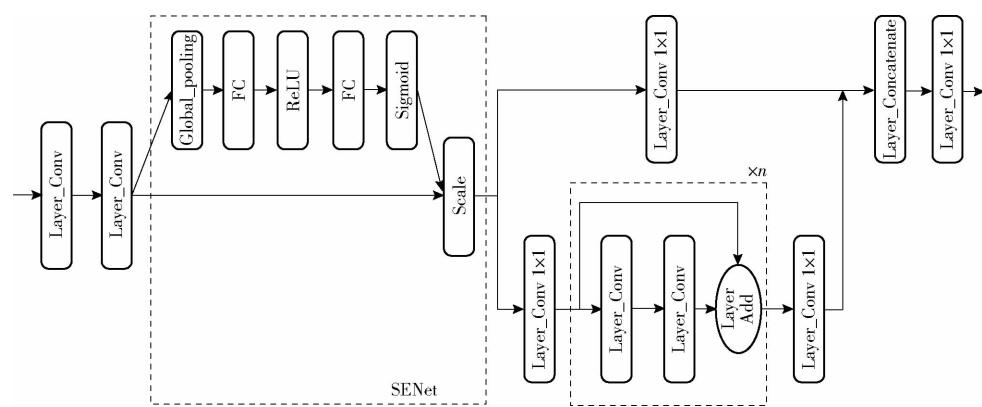


图9 前置网络中融合 SENet 模块

Fig. 9 Fusion SENet module in front-end network

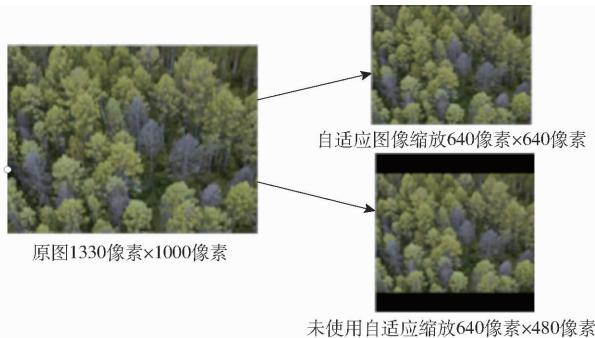


图10 自适应图像缩放

Fig. 10 Adaptive image scaling

形成的 CSPDarknet53 网络替换原有的特征提取网络、PANet 部分融入 CSPNet 网络形成 CSPConvs 结构(图7)。YOLO v4 - CSP 网络使用 CSPNet 优化网络减少运算的同时加入 SENet 模块增强特征提取, 最后使用多尺度检测来预测目标。

2.2.3 模型评价指标

目标检测模型性能评估的关键指标分别为平均

正确率(Average precision, AP)、损失值(Loss)与每秒模型处理帧数(Frames per second, FPS)。AP 越高, 代表模型的性能越好, 对落叶松毛虫虫害特征的检测更趋近于理想的结果。本文采用单幅航拍图像的检测时间(s)及落叶松毛虫虫害树木的平均正确率作为检测速度和检测精度的评价指标, 精确率(Precision)和召回率(Recall)是广泛应用于信息检索和统计学分类领域的两个度量值, 本实验中选择阈值为 0.5 进行验证。

2.2.4 实验环境设置

实验平台配置如表 1 所示。实验操作平台为 Ubuntu 18.04 计算机, 使用 PyTorch^[25]作为深度学习框架, 采用 GPU 进行训练, 配合 cuDNN 对训练过程加速。在参数的设置方面, 训练迭代次数设置为 175 次, 初始学习率设置为 0.000 5, 每次迭代训练图像的数量(Batch size)为 2, 学习率的衰减系数(gamma)和动量项分别为 0.1 和 0.9, 非极大值抑

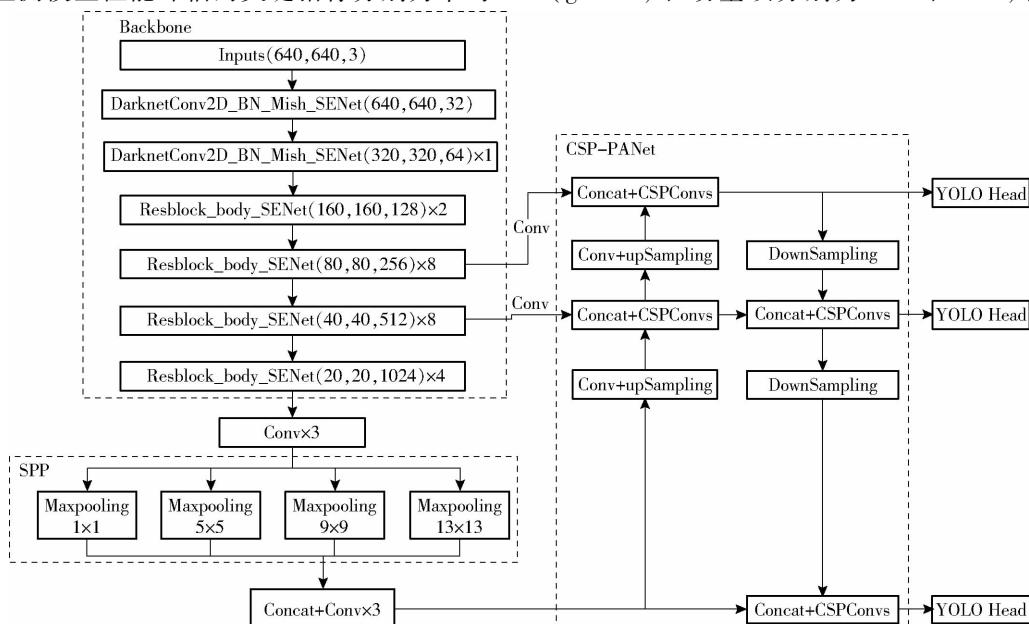


图11 改进后 YOLO v4 - CSP 网络结构

Fig. 11 Improved YOLO v4 - CSP network structure

制(Non-maximum suppression, NMS)的阈值设置为0.5,保留置信度大于0.5的部分。

表1 实验平台配置

Tab. 1 Experimental platform parameters

参数	数值/配置
CPU	Intel 酷睿 i7 10750H CPU @ 2.60 ~ 5.00 GHz
内存	32.00 GB DDR4 3200 MHz ECC RDIMM
操作系统	Ubuntu 18.04
GPU 加速库	CUDA9.0 cuDNN v7.1
深度学习框架	PyTorch - gpu 1.9.0

在部署完实验平台后导入落叶松毛虫虫害数据集进行训练,训练过程选用 ADAM 优化器对模型的学习率(Learning rate, LR)不断优化。训练完毕后,生成模型经常量化计算后,部署至工作站进行模型测试。将生成最优模型进行 PTH - ONNX - TRT^[26]转换,在 Jetson nano 边缘计算平台利用 TensorRT^[27]进行加速,对模型实时监测进行评价。

3 实验与结果分析

3.1 损失值

损失值是衡量模型训练是否优异的一个重要指标,损失值越低说明预测框与真实框之间差别越小,目标检测效果越好。图 12 为训练与验证过程中的损失值变化情况,随着训练的不断增加,YOLO v4 - CSP 与 YOLO v4 模型损失值不断减小,说明目标检测模型在不断收敛并未出现过拟合情况。两个模型大约训练 160 次后达到最优,并输出最优模型,此时

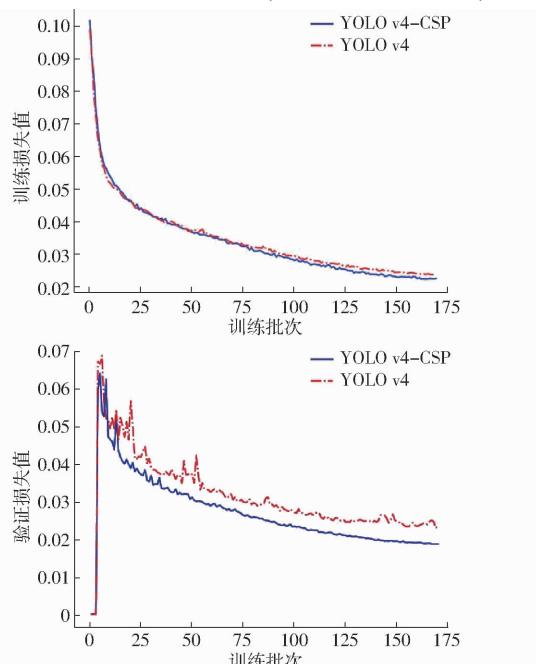


图 12 训练、验证过程损失值变化曲线

Fig. 12 Training and verification process loss value

change curves

YOLO v4 - CSP 模型的测试损失值比 YOLO v4 模型低 0.012。

3.2 改进前后模型对比

图 13 为改进后 YOLO v4 - CSP 模型与 YOLO v4 模型结果对比。本文选取交并比大于 0.5 和交并比大于 0.95 两个阈值进行比较,准确率为模型预测框与真实框之间交并比(IoU)大于 0.5 或 0.95 的检测框占所有判断为目标物样本数的百分比。图中可以看出改进后 YOLO v4 - CSP 模型的置信度明显高于 YOLO v4 模型,在交并比大于 0.5 的检测中改进后比改进前提高 2 个百分点,在交并比大于 0.95 的检测中改进后比改进前提高 7.4 个百分点,且改进后训练过程曲线更加平稳。

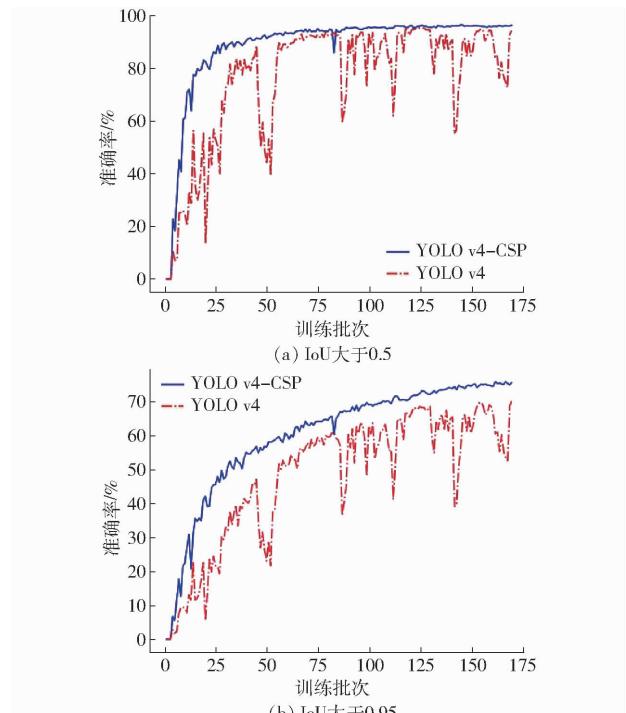


图 13 改进前后模型准确率对比

Fig. 13 Comparisons of model accuracy before and after improvement

3.3 P - R 曲线

图 14 为改进前后模型的精确率与召回率曲线(P - R),其与坐标轴所围面积越大说明检测效果越好。由改进后 YOLO v4 - CSP 模型训练结果可以看出,针对两种类别目标的检测,改进后模型平均正确率比改进前高 2 个百分点。

图 15 为 YOLO v4 - CSP 模型识别结果。通过调节图像曝光度来模拟室外光线变化,可以看出模型对虫害识别准确度较高,能准确识别范围内所有虫害目标,及时定位虫害发生区域。研究结果可以作为落叶松毛虫虫害识别检测的评价依据。

3.4 可视化分析

图 16 为注意力机制添加前后,输入图像经前置

Fig. 12 Training and verification process loss value

change curves

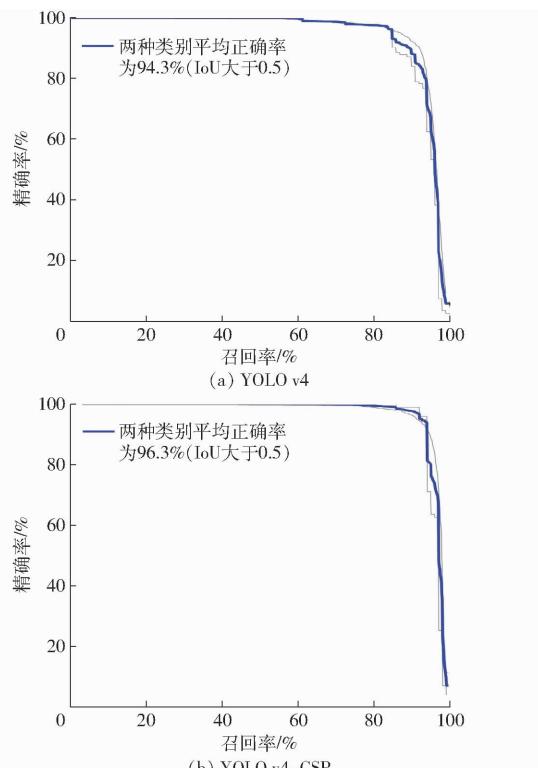


图 14 改进前后 P-R 曲线

Fig. 14 P-R curve before and after improvement

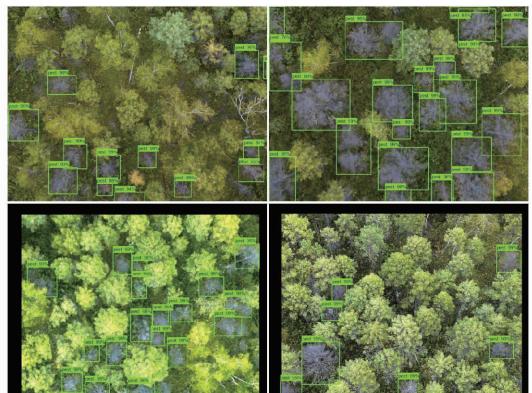


图 15 改进后模型虫害目标识别结果

Fig. 15 Improved pest target recognition results

特征网络后生成的热力图。红色部分代表网络对目标的关注程度，并通过这一部分来识别虫害特征，注意力机制反映在图像信息中为红色越深，特征越明显。在图中可以看出添加 SENet 结构后，网络获得的感受野更大，虫害特征被很好地表征，相较于原网络更加清晰地区分出图像中虫害树木的位置与多个目标物。

3.5 不同模型检测结果对比

用改进后的 YOLO v4 - CSP 模型对比当前主流深度学习目标检测框架 Faster R - CNN，选择置信度大于 0.5 的参数进行对比，训练过程如图 17 所示。Faster R - CNN 作为 two-stage 检测模型的代表，在训练稳定性与收敛速度上快于 YOLO v4 与 YOLO

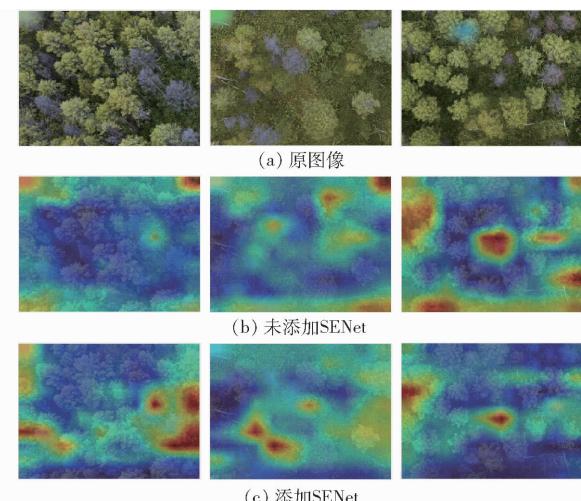


图 16 添加 SENet 前后可视化对比

Fig. 16 Visual comparison before and after adding SENet

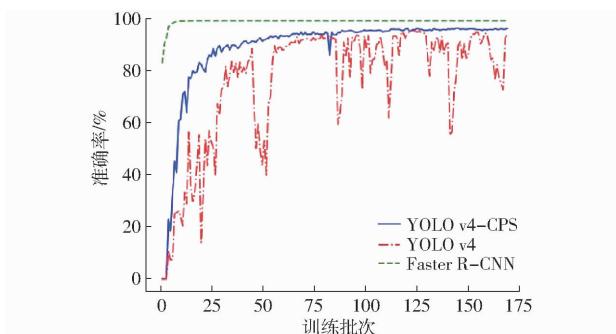


图 17 各模型准确率对比结果

Fig. 17 Accuracy comparison results among models

v4 - CSP，但实时检测效果差。经过改进后的 YOLO v4 - CSP 减少了模型运行过程中不稳定带来的精度曲线振荡问题，准确率接近 two-stage 检测方法 Faster R - CNN。

表 2 为各模型间的结果比对，参数对比上选择置信度大于 0.5 时的 AP、总体平均正确率、训练内存、生成模型大小及实时检测速度作为评价标准。由表 2 可以得到，改进后模型对虫害树木检测的平均正确率较改进前提升 3.4 个百分点，训练内存为改进前 YOLO v4 的 82.7%，生成模型内存占用量也较改进前降低 20% 左右，经验证帧率提升 2.45 f/s，改进后的 YOLO v4 - CSP 模型各参数优于未改进前模型，在精度测试方面接近 two-stage 检测方法 Faster R - CNN 模型。

4 讨论

针对 two-stage 速度慢，训练周期长，实时监测成本高等问题，本研究改进 one-stage 目标检测 YOLO v4 模型，提出一种针对无人机图像中尺度较小的落叶松毛虫虫害的无人机实时监测方法。数据集构建上首先通过增加噪声、对比度及改变亮度等

表2 主流算法间参数对比

Tab. 2 Comparison of parameters among main stream algorithms

模型	前置特征网络	平均正确率/%		总体平均 正确率/%	训练 内存/GB	生成模型内存 占用量/MB	实时检测速 度/(f·s ⁻¹)
		虫害树木	枯死树				
YOLO v4	CSPDarknet53	94.10	94.50	94.30	2.37	254	1.72
YOLO v4-CSP	SENet + CSPDarknet53(改进)	97.50	95.10	96.30	1.96	201	4.17
Faster R-CNN	ResNet50	98.75	99.77	99.28			

方法扩增训练样本,在保留虫灾特征的基础上,获取足量的训练样本。其次为增强模型泛化性,在数据集构建中融合部分哈尔滨市城市林业示范基地中落叶松的枯死树作为干扰项。模型优化方面使用CSPNet网络与SENet结构优化主干网络,训练过程对Letterbox函数进行优化,进一步减少计算量。实验结果表明:使用改进后CSPDarknet53模块增强虫害特征并融合枯死树做干扰项,增强了模型的泛化性,受害落叶松的平均正确率可达97.50%,优于目前常见目标检测模型。主干网络中使用SENet结构增加感受野信息,提高模型对虫害特征的提取能力,并使用CSPNet优化模型结构,相比原模型降低了运算量,降低了检测时间,提高了模型的稳定性。最后生成的最优模型内存占用量仅有201 MB,搭载至

Jetson nano边缘计算平台检测速度为4.17 f/s,可实现对受害落叶松的实时监测。

数据集构建上标定林场枯死树作为干扰信息用来提高模型泛化性。首先图像经过卷积后再由一层SENet结构训练权重信息扩大感受野,再经过CSPNet网络结构将输入特征一分为二,其中一部分直接传入下一阶段,另一部分经过卷积后与上一层特征合并,这种网络结构可以有效减少计算与特征重用等问题,保证了推理速度与准确性,内存使用情况约为未改进前的82.7%。利用自适应缩放技术对导入的训练图像缩放,保留了特征信息的同时减少图像填充后空白信息的占比,在相同参数配置下改进后的YOLO v4-CSP模型在训练速度上得到有效提升。经改进后的YOLO v4-CSP模型训练,得到最优模型内存占用量为201 MB,相较于未改进前参数量降低,减少模型的应用成本。

本研究针对落叶松毛虫侵害后的树木进行虫害目标检测,该方法可适用于其他树种因虫害导致的树木外型、叶片颜色变化等情况。为区别于其他自然灾害导致的树木损伤(腐朽、枯死等),需要设置干扰项来提高模型泛化性。本研究通过设置枯死树作为干扰目标,实现了对林区范围内受虫害影响树木目标及枯死树的精准检测,进一步提高了模型针

对于该片区域虫害树木检测的鲁棒性。由于本研究是针对大兴安岭严重后期落叶松虫害进行分类检测,面对早期感染落叶松毛虫虫害的树木,其树木外形颜色未发生明显变化时,很难在影像上与其他健康树木区别,因此会导致一些患病树木的漏检,造成一定的误差。在今后的研究中可结合使用光谱信息作为检测标准,从而提高对早期患病树木的检测精度。模型经过TensorRT优化后的实时监测满足无人机在飞行过程中获取的虫害数据,但帧率较低,下一步可针对特征提取网络进行剪枝优化,去除未发挥作用的网络层,进一步降低模型大小。落叶松毛虫虫害周期短,染病后传播速度快,在下一步可设置无人机机组搭载虫害检测模型,设定巡查路线定时定点巡视。

5 结论

(1) YOLO作为目前应用最广泛的实时目标检测模型,基于无人机搭载高清相机获取落叶松毛虫虫害林区影像,利用改进的YOLO v4-CSP深度学习目标检测模型进行检测,对落叶松毛虫虫害的检测平均正确率达到97.50%。基于YOLO v4-CSP的落叶松毛虫虫害检测方法可实现无人机森林虫害的识别监测。

(2) 将训练后模型搭载至Jetson nano边缘计算平台进行测试,实时检测速度为4.17 f/s,搭载无人机可实现对落叶松毛虫虫害树木的实时监测。

(3) YOLO v4-CSP模型简化了对落叶松毛虫虫害的检测流程,提高了无人机机组每次作业的针对性,及时定位害虫爆发中心,满足落叶松毛虫虫害早期预警的时效性需求。将YOLO v4-CSP模型生成最优模型部署至Jetson nano边缘计算平台,利用无人机搭载虫害模型可实现对大兴安岭地区落叶松毛虫虫害的无人机实时监测。本研究可为林区管理人员提供及时准确的虫灾发生信息,也为森林病虫害的受灾评估提供客观准确的依据,实现了基于现代遥感技术的森林病虫害监测,从而为森林资源健康动态监测与防治提供基础数据。

参考文献

- [1] 陈宏伟,胡远满,常禹,等.我国大兴安岭林区落叶松毛虫综合研究进展[J].西北林学院学报,2011,26(1):119–127.
CHEN Hongwei, HU Yuanman, CHANG Yu, et al. Advances in the researches of *Dendrolimus superans* of Daxing'an Mountain of China[J]. Journal of Northwest Forestry University, 2011, 26(1): 119–127. (in Chinese)
- [2] 邓淑芹.长白山地区落叶松毛虫防治技术的研究[J].防护林科技,2018(11):30–33.
DENG Shuqin. Control techniques of *Dendrolimus superans* in Changbai Mountain area [J]. Protection Forest Science and Technology, 2018(11): 30–33. (in Chinese)
- [3] 赵佳.落叶松毛虫对林木的危害及防治措施[J].农业与技术,2020,40(8):81–82.
- [4] 李浩,徐航煌,郑恒宇,等.基于无人机遥感图像的松材线虫病监测技术研究[J].中国农机化学报,2020,41(9):170–175.
LI Hao, XU Hanghuang, ZHENG Hengyu, et al. Research on pine wood nematode surveillance technology based on unmanned aerial vehicle remote sensing image[J]. Journal of Chinese Agricultural Mechanization, 2020, 41(9): 170–175. (in Chinese)
- [5] 孙钰,周焱,袁明帅,等.基于深度学习的森林虫害无人机实时监测方法[J].农业工程学报,2018,34(21):74–81.
SUN Yu, ZHOU Yan, YUAN Mingshuai, et al. UAV real-time monitoring for forest pest based on deep learning [J]. Transactions of the CSAE, 2018, 34(21): 74–81. (in Chinese)
- [6] DASH J P, WATT M S, PEARSE G D, et al. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 131: 1–14.
- [7] YUAN Y, HU X. Random forest and object-based classification for forest pest extraction from UAV aerial imagery[J]. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 41: 1093.
- [8] 张军国,冯文钊,胡春鹤,等.无人机航拍林业虫害图像分割复合梯度分水岭算法[J].农业工程学报,2017,33(14):93–99.
ZHANG Junguo, FENG Wenzhao, HU Chunhe, et al. Image segmentation method for forestry unmanned aerial vehicle pest monitoring based on composite gradient watershed algorithm [J]. Transactions of the CSAE, 2017, 33 (14) : 93 – 99. (in Chinese)
- [9] LEE S, PARK S, BAEK G, et al. Detection of damaged pine tree by the pine wilt disease using UAV Image[J]. Korean Journal of Remote Sensing, 2019, 35(3): 359–373.
- [10] 冯权泷,牛博文,朱德海,等.土地利用/覆盖深度学习遥感分类研究综述[J].农业机械学报,2022,53(3):1–17.
FENG Quanlong, NIU Bowen, ZHU Dehai, et al. Review for deep learning in land use and land cover remote sensing classification[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 1–17. (in Chinese)
- [11] FEICHTENHOFER C, PINZ A, ZISSERMAN A. Detect to track and track to detect [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 3038–3046.
- [12] LI W, LI J, SARMA K V, et al. Path R-CNN for prostate cancer diagnosis and gleason grading of histological images[J]. IEEE Transactions on Medical Imaging, 2018, 38(4): 945–954.
- [13] LEE H, EUM S, KWON H. Me R-CNN: multi-expert R-CNN for object detection [J]. IEEE Transactions on Image Processing, 2019, 29: 1030–1044.
- [14] 孙钰,张冬月,袁明帅,等.基于深度学习的诱捕器内红脂大小蠹检测模型[J].农业机械学报,2018,49(12):180–187.
SUN Yu, ZHANG Dongyue, YUAN Mingshuai, et al. Detection model of in-trap red turpentine beetle based on deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12):180 – 187. (in Chinese)
- [15] 朱红春,李旭,孟炀,等.基于 Faster R-CNN 网络的茶叶嫩芽检测[J].农业机械学报,2022,53(5):217–224.
ZHU Hongchun, LI Xu, MENG Shang, et al. Tea bud detection based on Faster R-CNN network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5):217 – 224. (in Chinese)
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779–788.
- [17] DU S, ZHANG P, ZHANG B, et al. Weak and occluded vehicle detection in complex infrared environment based on improved YOLO v4[J]. IEEE Access, 2021, 9:25671–25680.
- [18] 王卓,王健,王枭雄,等.基于改进 YOLO v4 的自然环境苹果轻量级检测方法[J].农业机械学报,2022,53(8):294–302.
WANG Zhuo, WANG Jian, WANG Xiaoxiong, et al. Lightweight real-time apple detection method based on improved YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8):294 – 302. (in Chinese)
- [19] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390–391.
- [20] 周小成,王锋克,黄洪宇,等.基于无人机遥感的伐区造林坑穴数量与参数提取[J].农业机械学报,2021,52(12):201–206.
ZHOU Xiaocheng, WANG Fengke, HUANG Hongyu, et al. Number and parameters extraction of tree well based on UAV remote sensing in cutting area[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52 (12) :201 – 206. (in Chinese)
- [21] 林文树,张金生,何乃磊.基于 YOLOv5 的落叶松毛虫虫害检测识别方法及系统: 202111444616.4 [P]. 2022–03–04.
- [22] EVERINGHAM M, VAN GOOL L, WILLIAMS C K I, et al. The pascal visual object classes (VOC) challenge [J]. International Journal of Computer Vision, 2010, 88(2): 303–338.
- [23] HUANG Z, WANG J, FU X, et al. DC-SPP-YOLO: dense connection and spatial pyramid pooling based YOLO for object detection[J]. Information Sciences, 2020, 522:241–258.