

基于改进 YOLOv7 的林业害虫检测分类方法

朱强军¹, 刘趁心², 王杨^{3*}

(1. 芜湖学院 计算科学学院, 安徽 芜湖 241000; 2. 芜湖学院 电子信息学院, 安徽 芜湖 241000; 3. 安徽师范大学 计算机与信息学院, 安徽 芜湖 241000)

摘要: 为提高林业害虫识别精度, 提出改进 YOLOv7 的林业害虫检测模型 (GhostConv and SE attention enhanced YOLOv7, GS-YOLOv7)。首先, 该模型将主干网络的传统卷积改用 GhostConv 轻量卷积, 减小模型运行的参数量, 提高模型效率; 其次, 通过添加挤压激励 (squeeze excitation, SE) 注意力模块, 强化对特征不显著的害虫图像边缘的提取能力, 进而提高网络的特征提取能力; 再次, 用内容感知的特征重组 (content aware reassembly of features, CARAFE) 轻量级算子取代传统采样方法, 提高特征重建质量, 解决尺度不匹配问题, 增强检测性能; 最后, 在 Neck 网络引入协调坐标卷积 (coordinate convolution, CoordConv) 模块, 利用其位置信息解决目标定位不准问题, 提高模型对空间位置的感知能力和泛化能力。在 6 种常见的病虫害数据集上进行试验, GS-YOLOv7 模型的精确率达到 93.15%, 交并比阈值为 0.5 时的平均精度均值达到 93.29%, 比原模型的精确率、平均精度均值分别提高 6.50% 和 2.09%; 参数量和模型大小分别降至 1.9×10^7 个和 38.17 MB, 比原模型分别降低 51.4% 和 46.53%。结果表明, GS-YOLOv7 模型较原模型性能有显著提升, 模型改进有效。

关键词: 林业害虫; 目标检测; YOLOv7; GhostConv; SE 注意力; CoordConv

中图分类号: TP391.4; S763.3

文献标识码: A

DOI: 10.7525/j.issn.1006-8023.2026.01.015

Forest Pest Detection and Classification Methods Based on Improved YOLOv7

ZHU Qiangjun¹, LIU Chenxin², WANG Yang^{3*}

(1. School of Computing Science, Wuhu University, Wuhu 241000, China; 2. School of Electronic & Information Technology, Wuhu University, Wuhu 241000, China; 3. School of Computer and Information, Anhui Normal University, Wuhu 241000, China)

Abstract: In order to improve the accuracy of forest pest identification, a forest pest detection model (GhostConv and SE attention enhanced YOLOv7, GS-YOLOv7) based on the improved YOLOv7 is proposed. Firstly, the model replaced the traditional convolution in the backbone network with GhostConv lightweight convolution to reduce the number of parameters in model operation and improve the model efficiency. Secondly, by adding the squeeze excitation (SE) attention module, the ability to extract the edges of pest images with insignificant features was enhanced, thereby further improving the feature extraction ability of the network. Thirdly, the content aware reassembly of features (CARAFE) lightweight operator was used to replace the traditional upsampling method to improve the quality of feature reconstruction, solve the scale mismatch problem, and enhance the detection performance. Finally, the coordinate convolution (CoordConv) module was introduced into the Neck network, and its position information was utilized to solve the problem of inaccurate target positioning and improve the model's sensitivity to spatial positions and its generalization ability. Experiments were conducted on six common pest and disease datasets, the precision of the GS-YOLOv7 model reached 93.15%, and the mean average precision at an intersection over union threshold of 0.5 reached 93.29%. Compared with the original model, the precision and mean average precision increased by 6.50% and 2.09%, respectively. The number of parameters and the model size decreased to 1.9×10^7 units and 38.17 MB, representing a reduction of 51.4%

收稿日期: 2025-02-18

基金项目: 安徽省高等学校省级质量工程项目 (2022sx052); 安徽省高校自然科学研究重点项目 (2023AH052459)。

第一作者简介: 朱强军, 硕士, 副教授。研究方向为机器视觉、智慧农业、智慧交通和智慧养老。E-mail: zhuqiangjun@ahnu.edu.cn

***通信作者:** 王杨, 博士, 教授。研究方向为人工智能系统、机器视觉和智慧农业。E-mail: wycap@126.com

引文格式: 朱强军, 刘趁心, 王杨. 基于改进 YOLOv7 的林业害虫检测分类方法 [J]. 森林工程, 2026, 42(1): 160-169.

ZHU Q J, LIU C X, WANG Y. Forest pest detection and classification methods based on improved YOLOv7 [J]. Forest Engineering, 2026, 42(1): 160-169.

and 46.53%, respectively, compared to the original model. Results indicate that the GS-YOLOv7 model demonstrates significant performance improvements over the original model, confirming the effectiveness of the model modifications.

Keywords: Forest pests; object detection; YOLOv7; GhostConv; squeeze excitation attention; CoordConv

0 引言

中国林业遭受生物胁迫的有害生物种类有 8 000 多种,经常造成危害的有 200 多种^[1]。林业害虫会降低木材质量,抑制林木的自然生长与更新,从而造成林业资源大量损失,对生态环境造成严重影响^[2]。及时、准确地识别林业害虫,制定合理的防治方案并采取相应的防治措施,对降低害虫造成的林业经济损失、保护生态环境具有重要意义。害虫检测主要包含人工检测、传统的机器学习算法检测和深度学习算法检测。人工检测是通过人工捕捉昆虫进行识别和计数,但该方法实时性差、效率低;传统的机器学习算法主要是通过支持向量机、随机森林等模型对人工提取的害虫图像特征进行分类,从而实现害虫检测识别,但该方法鲁棒性和泛化能力差。深度学习算法检测是将快速区域卷积神经网络(faster region-based convolutional neural networks, Faster R-CNN)、单次多框检测器(single shot multibox detector, SSD)和 YOLO(you only look once)等深度学习算法广泛地应用到林业害虫的检测识别。徐信罗等^[3]提出了基于 Faster R-CNN 的松材线虫病的检测识别,有效确定了受害木的位置,但检测精度不高。林文树等^[4]提出一种改进 YOLOv4 模型的受灾树木实时检测方法,提高树木落叶松毛虫虫害的识别精度与检测速度,但存在漏检的情况。戴佳兵等^[5]提出了一种 YOLOv5s-SE(you only look once v5s-squeeze-and-excitation)和通道剪枝的虫咬紫金蝉茶检测方法,该方法检测速度较快,但检测精度较低。周宏威等^[6]提出了一种改进的 YOLOv8 检测梢斑螟虫蛀树木,但平均检测精度仍需要提高。苏佳杰等^[7]提出了深度双线性转换注意力机制网络,实现了林业有害生物的识别,但准确率有待提高。综上所述,现有的林业害虫检测存在检测精度不高、识别速度慢等问题。

为提高林业害虫识别的精度和效率,本研究提出改进 YOLOv7 的林业害虫检测模型(GhostConv and SE attention enhanced YOLOv7, GS-YOLOv7)。该模型在主干网络中引入 GhostConv 轻量卷积代替传统卷积减小模型参数量,引入挤压激励(squeeze excitation, SE)注意力机制提高特征提取能力;在 Neck 网络中,引入 CoordConv 卷积模块提高模型的空间位置感知能力和泛化能力,采用内容感知的特征重组(content aware re-assembly of features, CARAFE)轻量级算子提高模型检

测能力。该模型通过结合轻量化网络、特征重组等方法在降低模型参数数量的同时,提高检测识别精度。

1 材料和方法

1.1 数据集构建与处理

数据集采用百度飞桨与北京林业大学合作开发的 AI 识虫数据集(<https://aistudio.baidu.com/datasetdetail/51399>)。该数据集包含测试集 245 张、验证集 245 张、训练集 1 693 张,共计 2 183 张图片。首先,通过程序将 xml 格式的数据集标签转换为符合 YOLOv7 需要的 txt 格式标签;其次,将数据集按照训练集(train)、验证集(val)、测试集(test)为 7:1.5:1.5 的比例进行分配;最后,使用 labelimg 对测试集标签进行 YOLO 格式标注。测试集(test)集无标签, YOLOv7 在测试时需要使用测试集的标签,需要对测试集进行标签标注。数据集包含 7 类,训练集中每类昆虫标签、实例统计结果,见表 1。通过检索数据发现,昆虫 *Linnaeus*(序号为 2)和昆虫 *linnaeus*(序号为 7)在标注文件是相同的,将二者合为一类,数据集变成 6 类,其中 *Linnaeus* 实例数变成了 8 727 张。

表 1 数据集标签

Tab. 1 Dataset labels

序号 Number	标签名 Label name	中文名 Chinese name	样本数量/张 Sample size
1	<i>Acuminatus</i>	尖尾松天牛	953
2	<i>Linnaeus</i>	家天牛	7 818
3	<i>Leconte</i>	红脂大小蠹	2 216
4	<i>Armandi</i>	华山松大小蠹	1 765
5	<i>Coleoptera</i>	松墨天牛	2 091
6	<i>Boerner</i>	松突圆蚧	1 595
7	<i>linnaeus</i>	家天牛	909

1.2 方法

1.2.1 YOLOv7 模型

YOLOv7^[8]模型主要由 4 个网络层次组成,分别是输入层(Input)、主干网络层(Backbone)、颈部(Neck)、检测头(Head)。输入层主要是将输入的数据进行尺寸归一化处理;主干网络层主要是使用深度卷积来提取不同尺度的特征信息;颈部主要是通过特征融合算法,将不同尺度的特征图像进行特征融合;检测头即输出层,将预测出的锚框坐标、种类及置信度进行非极大值抑制(non-maximum suppression, NMS)后输出。

YOLOv7 网络结构包括 ELAN (effective long-range aggregation network)、MP (max pooling) 和 SPPCSPC (spatial pyramid pooling, cross stage partial channel) 等多个多融合卷积模块。每一个多融合卷积模块通过改变卷积核大小及卷积步长来实现图像多尺度特征提取。CBS 模块由卷积层 (convocation, Conv)、批标准化层 (batch normalization, BN) 和激活层 (sigmoid linear unit, SiLU) 组成; ELAN 模块是由 7 个 CBS 构成的网络聚合结构, 工作机理是改变特征提取的路径, 从而使主干层得到的特征信息更加丰富, 并通过这种方式提高模型的鲁棒性。MP 模块是由 3 个 CBS 与一个最大池化层 (MP) 组成, 通过对图像进行最大池化算法和下采样算法实现图像特征的深度提取。SPPCSPC 模块的作用是扩大特征提取的范围, 可以对不同大小的图像进行特征提取, 使 YOLOv7 算法模型可以适应不同分辨率的图像, 通过这种方式提升算法的泛化能力。SPPCSPC 模块的工作方式是划分特征图像, 将其一分为二, 其中一部分使用传统卷积进行特征提取, 另一部分通过池

化操作提高特征提取的广度。

1.2.2 GhostConv 轻量化卷积模块

传统的特征提取操作是多个卷积核堆叠在一起的操作, 是对输入特征图的所有通道执行卷积映射, 造成资源的浪费。传统卷积能生成丰富的特征, 但计算速度更慢, 且参数量更多。针对 YOLOv7 网络结构采用传统卷积的特征提取导致模型参数多的问题, 有学者提出了网络优化 ShuffleNet、MobileNet 等轻量级卷积网络^[9-11]。这些网络简单、有效且易实现, 但卷积仍然占用大量的内存。因此, 引入 GhostConv 模块代替传统卷积模块, 降低模型的参数, 轻量化模型, 提高速度。传统卷积与 GhostConv 模块如图 1 所示。GhostConv 先通过普通的卷积操作生成一部分特征图, 对特征图进行一系列的线性变换后获得更多的特征图, 将线性变换前后的特征图进行级联操作, 生成输出特征图。GhostConv 可以减少非关键图像特征的学习消耗, 获得更丰富特征信息, 从而降低参数量和计算量, 提高 YOLOv7 目标检测算法在对害虫识别和分类的速度。




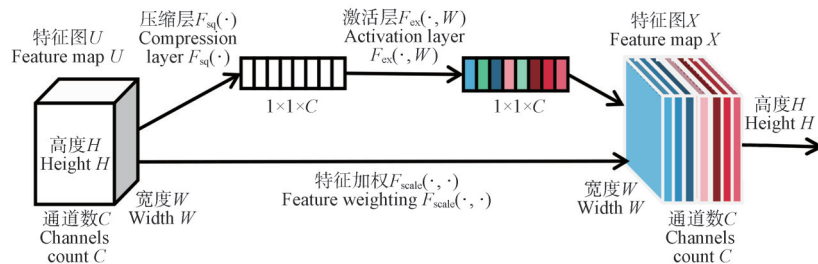
图1 传统卷积与幽灵卷积模块

Fig. 1 Traditional convolution and GhostConv module

1.2.3 SE 注意力

SE^[12]注意力机制是一种通道注意力机制, 可以学习使用全局信息来选择性地强调特征信息, 并抑制无

关的特征信息。SE 注意力机制已被广泛应用于目标检测、图像分割等任务中。SE 注意力模块如图 2 所示。



U 为特征图像; W 为图像的宽; H 为图像的高; C 为输入图像的通道数; X 为经过 SE 注意力处理后输出的特征图像。

U represent the feature image; W denote the width of the image; H denote the height of the image; C denote the number of channels of the input image; and X denote the feature image output after SE attention processing.

图2 SE 注意力模块

Fig. 2 Squeeze excitation attention module

SE 注意力机制的基本思想是不同通道的权重应该自适应分配,由网络自己学习出来。将向量输入到 2 个全连接层中,以学习每个通道的权重。第 1 个全连接层被称为“压缩层”,将平均值向量压缩为更小的尺寸,以减少计算开销。第 2 个全连接层被称为“激活层”,使用 Sigmoid 函数或 ReLU 函数等激活函数来学习每个通道的权重。压缩层表达式 z_c 为

$$z_c = F_{sq}(u) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

式中: W 和 H 分别为输入特征的宽和高; $u_c(i, j)$ 为通道 i 和 j 上的单一元素点。

激活层表达式 s 为

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

式中: σ 为 ReLU 激活函数; g 为全连接层的线性变化函数; δ 为 Sigmoid 激活函数; W_1 为降维层的参数; W_2 为升维层的参数。

输出特征图 \tilde{x}_c 公式为

$$\tilde{x}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (3)$$

式中: u_c 为输入 SE 模块的第 c 个通道原特征图; s_c 为激励操作输出的第 c 个通道权重。

1.2.4 CARAFE 上采样算子

轻量级上采样算子 CARAFE^[13] 包含上采样核预测模块和特征重组模块。其中上采样核预测模块含有特征图通道压缩、内容编码、上采样核预测和上采样核归一化 4 个部分。

1) 特征图通道压缩。将形状为 $H \times W \times C$ 的特征图像 X , 用一个最小单位 1×1 的卷积核特征图进行通道压缩, 将大小为 $H \times W \times C$ 的特征图像通道数 C 个压缩到 C_m 个, 通过通道压缩, 减少后续的计算量。

2) 内容编码和上采样核预测。对通道压缩后的特征图像, 利用大小为 $k_{up} \times k_{up}$ 的上采样核来预测, 将压缩后的通道数 C_m 输入上采样核, 生成输出的通道数为 $\sigma^2 k_{up}^2$, 最后对生成的通道数执行三维扩展操作, 得到与输出图像的大小为 $\sigma H \times \sigma W \times k_{up}^2$ 匹配的上采样核。

3) 上采样核归一化。通过 softmax 对第 2 步中得到的上采样核进行归一化, 使其卷积权重和为 1。

4) 特征重组。对于上采样归一化得到的特征图像将其映射回输入图像 X , 将 X 中大小为 $X_1 \times k_{up}$ 的区域基于该区域进行特征重组。CARAFE 上采样算子结构如图 3 所示。

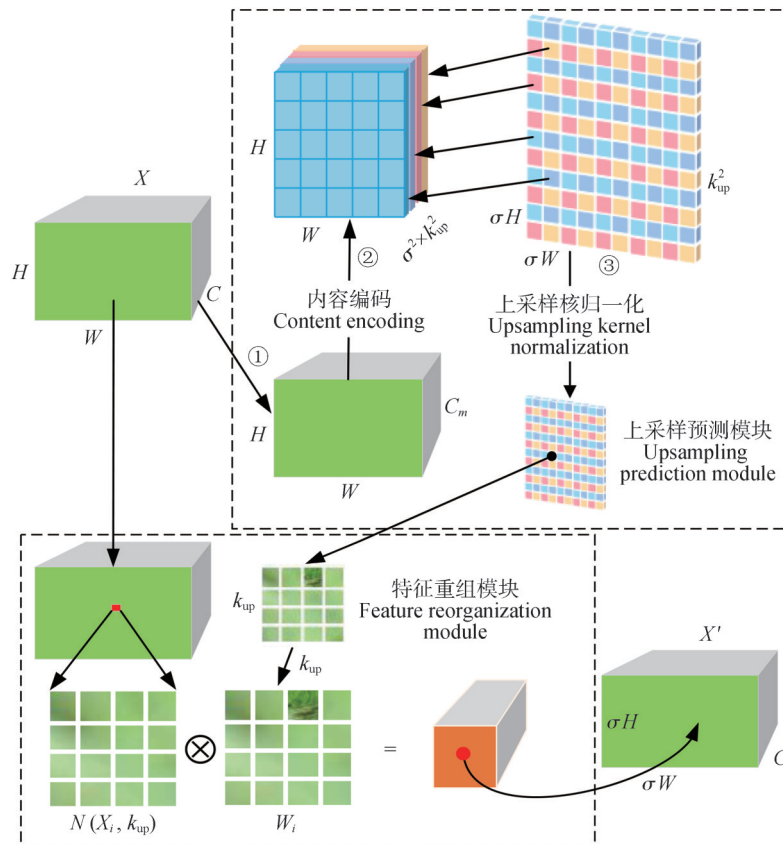


图 3 CARAFE 上采样算子结构

Fig. 3 Structure diagram of the CARAFE upsampling operator

1.2.5 协调坐标卷积

传统卷积具备平移不变性即进行特征提取时不会改变图像的特征信息,在分类等任务中可以更好地学习本质特征,但在需要识别目标位置信息的监督学习任务中,传统卷积则效果不佳。为使得卷积能够对空间信息有更好的感知能力,Liu等^[14]提出了协调坐标卷积(CoordConv),在输入特征图像后增加2个 Coordi-

nate 通道,分别表示原始输入位置坐标(i, j),再进行传统卷积,使得卷积过程可以感知输入特征图像的空间信息,增强其特征感知能力,提高模型对图像的特征信息的感知能力,能够使得网络根据不同任务需求学习平移不变性或者一定程度的平移依赖性。常规卷积与协调坐标卷积如图4所示。

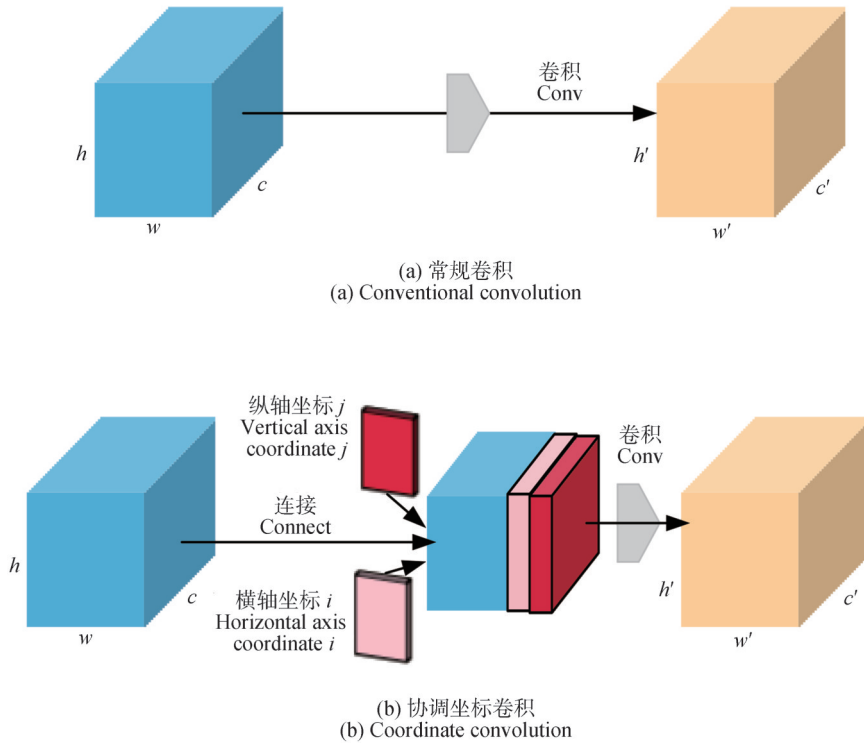


图4 常规卷积与协调坐标卷积

Fig. 4 Conventional convolution and coordinated convolution

综上所述,为提高林业病虫害识别精度,提出了GS-YOLOv7模型。该模型在主干网络中引入GhostConv卷积和SE注意机制,提高林业害虫识别精度;在Neck网络中,用协调坐标卷积代替传统卷积,提升网络对于空间关系的理解和利用能力,从而提高网络的检测精度;用CARAFE上采样代替传统上采样,增大感受野并提升模型的泛化能力。在CBS模块中,GhostConv代替Conv,轻量化模型。GS-YOLOv7模型网络结构如图5所示。

1.3 试验平台和评价指标

1.3.1 试验环境与参数设置

试验计算机的操作系统为64位Windows10专业版,CPU型号为Intel(R)Core(TM)i9-13900K,GPU为NVIDIA GeForce RTX4070Ti,显存大小为12 G。集成编译软件为PyCharm社区版2023.1.3,CUDA版本为

12.0,深度学习框架Pytorch2.0,Python3.8。试验训练过程中采用随机梯度下降(stochastic gradient descent,SGD)优化器来进行优化,训练周期(epoch)为150,线程(workers)为8,批量大小(batch_size)为16,输入照片尺寸(images_size)为640,初始化学率(lr0)为0.01。

1.3.2 试验评估标准

采用精确率(precision, P),召回率(recall, R)、平均精度(average precision, AP,式中为 S_{AP})和平均精度均值(mean average precision, mAP,式中为 S_{mAP})作为试验评价指标,从而衡量不同模型检测水果的精度。以上指标的公式为

$$P = \frac{T_p}{T_p + F_p} \quad (4)$$

$$R = \frac{T_p}{T_p + F_N} \quad (5)$$

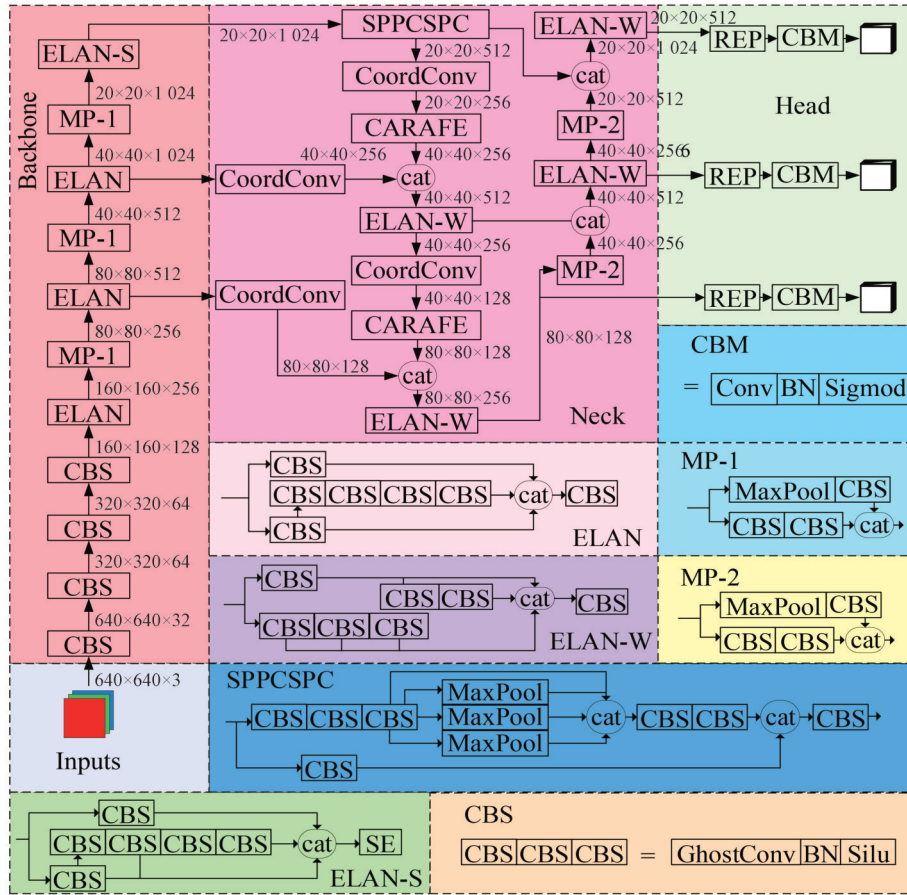


图 5 GS-YOLOv7 网络结构

Fig. 5 GS-YOLOv7 network structure

$$S_{AP} = \int_0^1 P(R) dR. \quad (6)$$

$$S_{mAP} = \frac{1}{n} \sum_{i=1}^n S_{AP_i} \quad (7)$$

式中: T_p 为正样例预测为正样例的数量; F_p 为负样例预测正样例的数量; F_n 为正样例预测为负样例的数量; n 为数据集的类别数, i 为当前种类编号; S_{AP_i} 为第 i 类别的平均精度, 其值越高, 说明模型的检测效果越好; S_{mAP} 为平均精度均值。

2 结果与分析

2.1 不同注意力机制对比试验

为进一步验证 SE 注意力机制模块的性能, 在相同的试验条件下, 将 SE、高效通道注意力 (efficient channel attention, ECA)^[15]、卷积块注意力模块 (convolutional block attention module, CBAM)^[16] 分别嵌入到 YOLOv7 网络结构中, 通过试验得到不同注意力的 P 、 R 、 $S_{mAP0.5}$ 、内存和速率值, 结果见表 2。

表 2 不同注意力机制对比

Tab. 2 Comparison of different attention mechanisms

模型 Model	精确率/% Precision	召回率/% Recall	交并阈值为 0.5 时 平均精度均值/% $S_{mAP0.5}$	速率/(帧·s ⁻¹) V_{FPS}	内存/MB Memory
YOLOv7(原模型) YOLOv7(original model)	85.65	86.20	91.20	149.6	71.38
YOLOv7-ECA	84.91	84.82	90.52	140.8	71.38
YOLOv7-CBAM	82.90	88.68	87.09	135.1	71.63
YOLOv7-SE	87.58	86.35	92.19	147.1	71.63

由表2可知, YOLOv7-SE模型的 P 和 $S_{mAP0.5}$ 是所有比较模型中最高的, 分别达到了87.58%和92.19%。YOLOv7-SE模型的 P 、 R 和 $S_{mAP0.5}$ 比原模型分别提高了1.93%、0.15%和0.99%, 消耗内存略大, V_{FPS} 略低; 比YOLOv7-ECA模型的 P 、 R 、 $S_{mAP0.5}$ 和 V_{FPS} 分别提高2.67%、1.53%、1.67%和6.3帧/s, 消耗内存略大; 比YOLOv7-CBAM模型的 P 、 $S_{mAP0.5}$ 和 V_{FPS} 分别提高4.68%、5.10%和12帧/s, R 略低, 内存消耗相同。

表3 不同卷积网络模型试验结果

Tab. 3 Experimental results of different convolutional network models

模型 Model	精确率/% Precision	召回率/% Recall	交并阈值为0.5时 平均精度均值/% $S_{mAP0.5}$	速率/(帧·s ⁻¹) V_{FPS}	内存/MB Memory
YOLOv7(原模型) YOLOv7 (original model)	85.65	86.20	91.20	149.6	71.38
YOLOv7-PConv	86.12	91.53	90.41	137.0	76.70
YOLOv7-DSCConv	84.01	89.67	88.72	144.9	72.15
YOLOv7-CoordConv	90.07	89.21	92.13	151.5	73.22

由表3可知, YOLOv7-CoordConv模型的 P 、 $S_{mAP0.5}$ 和 V_{FPS} 是所有比较模型中最高的, 达到了90.07%、92.13%和151.5帧/s。YOLOv7-CoordConv模型的 P 、 R 、 $S_{mAP0.5}$ 和 V_{FPS} 比原模型提高4.42%、3.01%、0.93%、1.9帧/s, 消耗内存略高; 比YOLOv7-PConv模型的 R 略低, 其他参数均占优; 比YOLOv7-DSCConv模型的内存略高, 其他参数均占优。

2.3 不同模型对比试验

为验证GS-YOLOv7目标检测模型在害虫识别分类的检测精度, GS-YOLOv7模型对数据各种害虫识别精度见表4。由表4可知, GS-YOLOv7模型对6种害虫检测识别效果较优。与同系列的YOLOv5、YOLOv7^[8]、YOLOv9c^[19]和MS-YOLOv7^[20]模型进行比较, 不同模型试验结果见表5。

2.2 不同卷积层对比

为验证CoordConv^[14]模块对YOLOv7算法的作用, 在相同的试验条件下, 将协调坐标卷积(CoordConv)模块、部分卷积(partial convolution, PConv)^[17]模块和动态蛇形卷积核(dynamic snake convolution, DSConv)^[18]模块分别嵌入到YOLOv7算法中, 并对3种卷积网络进行对比试验, 不同卷积网络模型试验结果见表3。

表4 各类病虫害检测情况

Tab. 4 Detection of various pests and diseases %

名称 Name	精确率 Precision	召回率 Recall	交并阈值为0.5时 平均精度均值/% $S_{mAP0.5}$
Acuminatus	92.04	94.77	95.48
Linnaeus	94.20	92.35	94.25
Leconte	97.63	94.49	94.38
Armandi	89.23	81.28	89.16
Coleoptera	93.88	89.58	90.05
Boerner	92.92	94.91	96.42
平均值 Average value	93.15	91.23	93.29

表5 不同模型试验结果

Tab. 5 Experimental results of different models

模型 Model	精确率/% Precision	召回率/% Recall	交并阈值为0.5时 平均精度均值/% $S_{mAP0.5}$	参数量/个 Parameters	大小/MB Size	速率/(帧·s ⁻¹) V_{FPS}
YOLOv5	83.42	87.16	88.97	7.0×10 ⁶	13.80	124.0
YOLOv7	85.65	86.20	91.20	3.7×10 ⁷	71.40	149.6
YOLOv9c	90.38	91.00	90.98	5.1×10 ⁷	106.20	41.2
MS-YOLOv7	93.05	92.15	93.49	2.33×10 ⁷	58.70	151.2
GS-YOLOv7	93.15	91.23	93.29	1.9×10 ⁷	38.17	148.4

由表 5 可知,GS-YOLOv7 模型与其他模型比较,识别精确率最高,达到了 93.15%; R 和 $S_{mAP0.5}$ 略低于 MS-YOLOv7 模型,均优于其他模型;参数量和大小除 YOLOv5 模型外,均优于其他模型;模型处理速度略低于 MS-YOLOv7 和 YOLOv7。综上比较,GS-YOLOv7 模型比 YOLOv5 模型、YOLOv7 模型和 YOLOv9c 模型有较大优势;与 MS-YOLOv7 模型比较,本试验模型在参数量及内存占用方面有较明显优势。

2.4 泛化试验

为验证本研究模型的普适性,采用 IP102 公开数据集进行试验,IP102 数据集是一个用于昆虫、害虫识别的大规模基准数据集,包含水稻、玉米、小麦和甜菜

等害虫,其中包含各类害虫共 102 种,被用于训练和测试害虫识别和检测模型。采用 IP102 数据集作为本实验的泛化试验数据,选取其中 5 类最具代表性的昆虫进行试验对比。试验证明,GS-YOLOv7 模型比 YOLOv7 模型的 $S_{mAP0.5}$ 提高了 3.8%。GS-YOLOv7 模型具有较好的泛化性,识别精度高,在林业生产中能够及时识别害虫从而及时防治,对害虫防治具有实际应用意义。

2.5 消融试验

为验证 GS-YOLOv7 模型中不同的改进模块对模型的影响,同时也为了验证各个模块的有效性,进行消融试验。各个模块对 YOLOv7 的影响见表 6。

表 6 各个模块对 YOLOv7 的影响
Tab. 6 Influence of each module on YOLOv7

模块 Model	协调坐标卷积 CoordConv	挤压激励 SE	特征内感知重组 CARAFE	幽灵卷积 GhostConv	精确率/% Precision	召回率/% Recall	交并比阈值为 0.5 时 平均精度均值/% $S_{mAP0.5}$	内存/MB Memory	速率/(帧·s ⁻¹) V_{FPS}
原模型 Original model	×	×	×	×	86.65	87.20	91.20	71.38	149.6
模型 1 Model 1	√	×	×	×	90.07	89.21	92.13	73.22	151.5
模型 2 Model 2	×	√	×	×	87.58	86.35	92.19	71.63	147.1
模型 3 Model 3	×	×	√	×	88.27	92.86	91.24	65.30	122.5
模型 4 Model 4	×	×	×	√	88.42	89.21	92.21	39.90	135.2
模型 5 Model 5	√	√	×	×	89.46	90.25	91.11	71.70	147.2
模型 6 Model 6	√	×	√	×	90.57	89.69	91.24	69.20	126.6
模型 7 Model 7	√	×	×	√	87.34	88.25	89.30	40.00	137.1
模型 8 Model 8	×	√	√	×	90.35	89.55	91.31	66.30	130.4
模型 9 Model 9	×	√	×	√	88.42	89.34	90.20	40.10	134.2
模型 10 Model 10	×	×	√	√	87.12	89.20	88.32	39.50	128.7
模型 11 Model 11	√	√	√	×	91.20	90.68	91.52	66.20	142.5
模型 12 Model 12	√	√	×	√	90.76	89.87	91.42	42.10	131.2
模型 13 Model 13	√	×	√	√	89.20	90.12	90.22	39.40	137.2
模型 14 Model 14	×	√	√	√	91.24	90.11	92.56	40.20	136.3
模型 15(本研究) Model 15(This study)	√	√	√	√	93.15	91.23	93.29	38.17	140.6

注:“√”代表“有”;“×”代表“无”。

Note:“√” indicates “Yes”;“×” indicates “No”.

由表6可知,与原模型比较,模型1的 P 、 R 、 $S_{\text{mAP0.5}}$ 和 V_{FPS} 分别提高3.42%、2.01%、0.93%和1.90帧/s,消耗内存增加了1.84 MB;模型1的 V_{FPS} 达到了151.5帧/s,是所有模型中最高的;模块2的 P 和 $S_{\text{mAP0.5}}$ 略有上升,消耗内存略有增加, V_{FPS} 略有下降;模型3、模型4、模型6、模型8、模型11、模型12、模型14和模型15的 P 、 R 和 $S_{\text{mAP0.5}}$ 均有不同程度的提高,消耗内存和 V_{FPS} 均有不同程度的降低;模型3的 R 提高5.66%,达到92.86%,是所有模型中最高的,但 V_{FPS} 只有122.5帧/s,是最小的;模型15的 P 和 $S_{\text{mAP0.5}}$ 分别提高6.50%和2.09%,达到了93.15%和93.29%,是所有模型中最高的;同时模型15消耗的内存只有38.17 MB,是所有模型中最小的;模型5、模型7、模型9、模型10和模型13的 P 和 R 均有不同程度的提高, $S_{\text{mAP0.5}}$ 和 V_{FPS} 均有不同程度的降低,模型5的消耗内存略有增加,其他模型均有降低。综上分析,本文改进方法对模型的参数均具有积极效果。

3 结论与讨论

为降低林业害虫造成的损失,提出GS-YOLOv7林业害虫检测模型。该模型将GhostConv代替常规Conv,减少了模型参数,降低了计算量,达到了轻量化模型,实现更高效的检测;通过引入SE注意力,增强不显著的特征提取能力,提高了模型特征检测能力;采用CARAFE上采样提高了特征重建质量;通过引入CoordConv提高了模型空间位置的感知能力以及模型泛化能力。试验结果表明,GS-YOLOv7模型比原YOLOv7模型的 P 、 R 和 $S_{\text{mAP0.5}}$ 分别提高6.50%、4.03%和2.09%,分别达到93.15%、91.23%和93.29%,消耗内存降低33.21 MB,只有38.17 MB, V_{FPS} 略有下降。该林业害虫检测模型与同类先进模型比较,该模型具有精度高、计算量低和泛化能力强等优点,可促进林业害虫检测及分类任务向信息化、智能化方向发展。

GS-YOLOv7模型在林业害虫检测任务中展现出性能优势,通过创新的网络架构设计在精度与计算效率之间达成了突破性平衡。但该模型在维持高精度表现的同时, V_{FPS} 出现轻微下降,主要归因于GhostConv等轻量化模块引入的推理性能开销。未来可从2个方面进行优化。第一,探索轻量化与推理速度的优化平衡,通过重构网络分支结构降低计算冗余;第二,可引入模型量化等前沿技术,在保证模型精度的前提下进一步提升推理效率,为实现实时林业害虫检测提供解决方案。

参 考 文 献

[1] 郑加强,徐幼林,张慧春,等. 国内外林业有害生物防治

靶标识别技术的研究与展望[J]. 林业科学, 2023, 59(3): 152-166.

ZHENG J Q, XU Y L, ZHANG H C, et al. Advances and prospects of target recognition techniques for forest pest control at home and abroad [J]. Scientia Silvae Sinicae, 2023, 59(3): 152-166.

[2] 孟贵,刘叶菲,张旭峰,等. 1998—2018年我国林业有害生物灾情的时序分析[J]. 林业科学, 2022, 58(7): 134-143.

MENG G, LIU Y F, ZHANG X F, et al. Sequential variation analysis of forest pest disasters in China from 1998 to 2018 [J]. Scientia Silvae Sinicae, 2022, 58(7): 134-143.

[3] 徐信罗,陶欢,李存军,等. 基于Faster R-CNN的松材线虫病受害木识别与定位[J]. 农业机械学报, 2020, 51(7): 228-236.

XU X L, TAO H, LI C J, et al. Detection and location of pine wilt disease induced dead pine trees based on faster R-CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 228-236.

[4] 林文树,张金生,何乃磊. 基于改进YOLO v4的落叶松毛虫侵害树木实时检测方法[J]. 农业机械学报, 2023, 54(4): 304-312, 393.

LIN W S, ZHANG J S, HE N L. Real-time detection method of dendrolimus superans-infested *Larix gmelinii* trees based on improved YOLO v4 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 304-312, 393.

[5] 戴佳兵,宋春芳,凌彩金,等. 基于YOLOv5s-SE和通道剪枝的虫咬紫金蝉茶检测方法研究[J]. 河南农业科学, 2024, 53(5): 157-163.

DAI J B, SONG C F, LING C J, et al. Research on insect-bitten Zijin tea detection method based on YOLOv5s-SE and channel pruning [J]. Journal of Henan Agricultural Sciences, 2024, 53(5): 157-163.

[6] 周宏威,纪皓文,吴羿轩,等. 基于YOLOv8算法改进模型检测梢斑螟虫蛀树木[J]. 森林工程, 2025, 41(1): 126-137.

ZHOU H W, JI H W, WU Y X, et al. Improve the detection model of tree decay by dioryctria based on the YOLOv8 [J]. Forest Engineering, 2025, 41(1): 126-137.

[7] 苏佳杰,张哲宇,徐嘉俊,等. 基于深度双线性转换注意力机制网络的林业有害生物识别方法[J]. 林业科学, 2023, 59(2): 121-128.

SU J J, ZHANG Z Y, XU J J, et al. Forest pest identification method based on a deep bilinear transformation attention mechanism network [J]. Scientia Silvae Sinicae, 2023, 59(2): 121-128.

[8] 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]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, BC, Canada, August 22, 2023. IEEE, 2023: 1063–6919.
- [9] ZHAO L L, ZHU M L. MS-YOLOv7: YOLOv7 based on multi-scale for object detection on UAV aerial photography [J]. *Drones*, 2023, 7(3): 188.
- [10] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, June 18–23, 2018. IEEE, 2018: 6848–6856.
- [11] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [EB/OL]. arXiv. 1704.04861v1 [cs. CV] (2017-04-17) [2024-10-08].
- [12] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011–2023.
- [13] WANG J Q, CHEN K, XU R, et al. CARAFE: Content-aware reassembly of features [C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), October 27 – November 02, 2019. IEEE, 2019: 3007–3016.
- [14] LIU R, LEHMAN J, MOLINO P, et al. An intriguing failing of convolutional neural networks and the coordconv solution [EB/OL]. arXiv. 1807.03247v2 [cs. CV] (2018-12-03) [2024-11-05].
- [15] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, June 13–19, 2020. IEEE, 2020: 11531–11539.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]// Proceedings of 15th European Conference on Computer Vision (ECCV), 2018: 3–19.
- [17] KAUR A, RAJ A, JAYANTHI N, et al. Inpainting of irregular holes in a manuscript using UNet and partial convolution [C]//2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA), Coimbatore, India, July 15–17, 2020. IEEE, 2020: 778–784.
- [18] QI Y, HE Y, QI X, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation [C]// 2023 IEEE/CVF International Conference on Computer Vision (ICCV), Paris, France, October 01–06, 2023. IEEE, 2023: 6047–6056.
- [19] WANG C Y, YEH I H, LIAO H Y M. YOLOv9: Learning what you want to learn using programmable gradient information [EB/OL]. arXiv. 2402.13616v2 [cs. CV] (2024-02-29) [2024-11-05].
- [20] 刘双喜, 刘思涛, 屈慧星, 等. 基于 MS-YOLO v7 的多尺度稻飞虱识别分类方法 [J]. *农业机械学报*, 2023, 54(1): 212–221.
- LIU S X, LIU S T, QU H X, et al. Multi-scale rice planthopper image recognition and classification based on lightweight MS-YOLO v7 [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(1): 212–221.