doi:10.6041/j.issn.1000-1298.2024.04.016

基于轻量型网络的无人机遥感图像中茶叶枯病检测方法

胡根生　谢一帆　鲍文霞　梁　栋

（安徽大学农业生态大数据分析与应用技术国家地方联合工程研究中心，合肥 230601）

摘要：针对无人机采集的茶叶枯病图像中病斑差异大，病斑和背景之间相似性高等问题，设计了一个轻量型网络 LiTLBNet，用于准确、实时地检测野外茶园无人机图像中的茶叶枯病。LiTLBNet 使用轻量型的 M－Backbone 作为骨干网络，用来提取茶叶枯病病斑的可区分特征，减少因图像中病斑的尺度、颜色和形状的巨大差异而导致的漏检。在 LiTLBNet 的 LNeck 结构中引入了 SE 和 ECA 模块，帮助网络在通道维度上学习目标的综合特征，减少因病斑和背景之间的相似性造成的误检，同时删除原基线网络最大的特征图，以减少计算量和模型大小。此外，本研究还通过旋转、加噪声、构建合成图像等方式来扩充训练样本数量，提高小样本条件下 LiTLBNet 网络泛化能力。实验结果表明，利用 LiTLBNet 检测无人机遥感图像中茶叶枯病的精度为 75.1%，平均精度均值为 78.5%，与 YOLO v5s 接近。然而，LiTLBNet 内存占用量仅 2.0 MB，是 YOLO v5s 网络的 13.9%。LiTLBNet 网络可用于对茶叶枯病进行实时、准确的无人机遥感监测。

关键词：茶叶病害；目标检测；无人机遥感；轻量型网络；LiTLBNet

中图分类号：S127　　**文献标识码**：A　　**文章编号**：1000-1298(2024)04-0165-11　　**OSID**：

Lightweight Network for Tea Leaf Blight Detection in UAV Remote Sensing Images

HU Gensheng　XIE Yifan　BAO Wenxia　LIANG Dong

(*National Engineering Research Center for Agro-Ecological Big Data Analysis and Application*, *Anhui University*, *Hefei* 230601, *China*)

Abstract: Aiming at the problems of large differences in disease spots and high similarity between disease spots and background in tea leaf blight (TLB) disease images collected by UAV, a lightweight network LiTLBNet for the accurate and real-time detection of TLB disease in UAV images of tea gardens in the field was designed. A lightweight M－Backbone was used to extract the distinguishing features of the TLB spots, which reduced missed detections caused by the large differences in the scales, colors, and shapes of the disease spots in the images. The SE and ECA modules were introduced into the LNeck of LiTLBNet to help the network learn more comprehensive features in the channel dimension and reduce false detections caused by the similarities between disease spots and backgrounds. The largest feature maps were deleted to reduce the calculations and the network size, and furthermore, the training samples were also augmented by rotating them by different angles, adding noise to the images, and constructing synthetic images to improve the generalization of LiTLBNet by using a small number of samples. Experimental results showed that the precision of LiTLBNet was 75.1%, and the mAP was 78.5%, which was similar to that of YOLO v5s. However, the size of LiTLBNet was only 2.0 MB, which was 13.9% of the size of YOLO v5s. The proposed method can be effectively used for the real-time and accurate UAV remote sensing monitoring of TLB disease in tea gardens with a relatively large area.

Key words: tea disease; object detection; UAV remote sensing; lightweight network; LiTLBNet

收稿日期：2023－09－05　修回日期：2023－10－24

基金项目：国家自然科学基金项目(32372632、62273001)、安徽省高等学校自然科学研究重大项目(KJ2020ZD03)和安徽省自然科学基金项目(2208085MC60)

作者简介：胡根生(1971—)，男，教授，博士，主要从事机器学习、图像与视频处理技术研究，E-mail：hugs2906@sina.com

通信作者：梁栋(1963—)，男，教授，博士，主要从事计算信号处理、智能感知与处理技术研究，E-mail：dliang@ahu.edu.cn

0 引言

中国是世界上最大的茶叶生产和消费国之一。2022 年,中国茶园面积已达到 3.2×10^6 hm^2。茶叶在生长过程中很容易受到病害的影响,其中茶叶枯病(Tea leaf blight,TLB)是最常见的茶叶病害之一,广泛分布于我国大部分茶园地区。茶叶枯病叶片上的病斑为褐色,形状为半圆形或圆形,并向各个方向扩散。发病后期茶叶枯病病斑呈现灰白色,叶片组织死亡,形成不规则斑块[1]。感染茶叶枯病的茶树叶片会提前脱落,茶树过早衰老,严重影响了茶叶产量和质量。因此,准确、实时地检测茶叶枯病,防止茶叶枯病的快速传播,对提高茶叶产量和品质,减少茶农经济损失具有重要作用。

目前,在大多数茶叶种植地区,茶叶枯病病害的检测主要依靠茶农和植保专家的人工调查。人工调查需要耗费大量的时间和财力,不利于对茶叶枯病的实时监测。此外,人工调查适用于点状区域的茶叶枯病病害,如果茶园面积较大,调查结果可能会出现遗漏和误判的情况。

无人机遥感覆盖面广、速度快、成本低,可以与机器学习模型相结合,实现高精度的作物病虫害检测。ZHANG 等[2]利用安装在无人机上的多光谱相机获得香蕉镰刀菌枯萎病(Banana fusarium wilt,BFW)图像,研究并评估了 BFW 冠层病害的光谱特征和不同的 BFW 检测模型。XIAO 等[3]采集了苹果树冠的无人机遥感图像,采用不同的经典机器学习模型检测了苹果火烧病的严重程度差异和空间分布。MARIN 等[4]从无人机图像中提取植被指数,采用机器学习模型检测咖啡叶锈病的严重程度。LAN 等[5]使用安装在大疆无人机上的商用多光谱相机拍摄柑橘园的多光谱图像,在对图像进行去噪和植被指数计算后,使用经典的机器学习模型检测柑橘疾病。ABDULRIDHA 等[6]使用无人机设备和地面设备获得了番茄多光谱图像,并使用两种经典的机器学习方法,包括多层感知器(Multilayer perceptron,MLP)和逐步判别分析(Stepwise discriminant analysis,STDA)方法检测番茄病害。ABDULRIDHA 等[7]利用无人机在实验室和田间收集南瓜白粉病的高光谱成像数据,测试了 29 种光谱植被指数和机器学习模型的性能。SU 等[8]利用安装在机载平台上的低成本多光谱相机获取冬小麦黄锈病的多光谱图像,选择对黄锈病敏感的光谱波段和光谱植被指数,输入机器学习模型,实现了对黄锈病的监测。上述经典的机器学习模型需要人工提取对植物病害检测影响较大的特征,具有一定的主观性和探索性。由于无人机图像中茶叶枯病病斑和叶片的颜色和纹理与周围土地和杂草的颜色和纹理相似,因此很难准确选择茶叶枯病的可区分特征,人工提取特征会导致许多漏检和误检。

深度学习网络可以自主地学习图像中目标的浅层和深层特征,具有很高的准确性和效率[9-16]。

轻量型网络具有参数量少、运算量低等优势。近年来,研究人员设计了一系列轻量型卷积神经网络,如 SqueezeNet[17]、Xception[18]、MobileNetV3[19]、ShufflenetV2[20]、Ghostnet[21]、EfficientNet[22]等。HE 等[23]用多色荧光和多光谱图像构建训练样本,训练轻量型网络 MobileNetV3 来检测柑橘黄龙病。SUTAJI 等[24]将 MobileNetV2 和 Xception 串联提取的特征训练轻量型网络 LEMOXINET 用于植物病害检测。ZHAO 等[25]设计了一个轻量型的端到端网络 YOLO-GP,用于检测葡萄串及其采摘点。LU 等[26]结合 ghost 卷积和 transformer 编码器,提出了一种用于田间葡萄叶病的诊断网络。CHEN 等[27]设计了轻量型网络 MobIncNet,通过将改进的 Inception 与预先训练的 MobileNet 配对来识别和检测水稻病害。LI 等[28]改进了 YOLO v4 网络,设计了一个 DAC-YOLO v4 网络用于检测草莓叶片上的白粉病。GAO 等[29]在对病害图像进行预处理后,训练了 EfficientNet 模型来监测木薯叶病害。杨佳昊等[30]基于 YOLO v5 网络,通过替换主干网络、模型剪枝及知识蒸馏技术,构建了一个轻量化模型检测叶片病害。这些轻量型卷积神经网络尺寸小、参数少、计算复杂度低、检测速度快,能很方便地部署在便携式移动设备上。由于无人机图像分辨率低,背景复杂,图像中作物病害目标的尺度和形状多样,使用上述轻量型网络检测无人机图像中作物病害的精度不高。

由于光线不均匀和背景复杂,无人机遥感图像中的茶叶枯病病斑在颜色和形状上差异很大,茶叶枯病病斑的颜色与背景相似。茶叶枯病病斑的类内差异性和病斑与背景的类间相似性是茶叶枯病检测的两个挑战。

本研究设计一个轻量型网络 LiTLBNet,拟部署在便携式移动设备上,用于监测野外无人机图像中的茶叶枯病病害。

1 材料与方法

1.1 图像采集与数据集构建

本研究中所用的无人机遥感图像采集自坝镇茶园,该茶园位于安徽省合肥市南部,西邻庐江县,北接巢湖市,地理坐标为北纬 31°14′47.4″,东经

117°36′17.1″。图像采集于 2021 年 10 月 1—4 日。研究区域如图 1 所示。携带采集设备的无人机型号为 DJI 147 Mavic Air2，相机型号为 DJI FC3170，该相机可采集 4 800 万像素的可见光图像。无人机具有卫星定位功能，可获取每幅图像的经纬度和拍摄高度。本研究中无人机飞行高度为距离茶叶冠层 4 m，拍摄时相机镜头垂直于地面。图像采集设备和采集方法如图 2 所示。

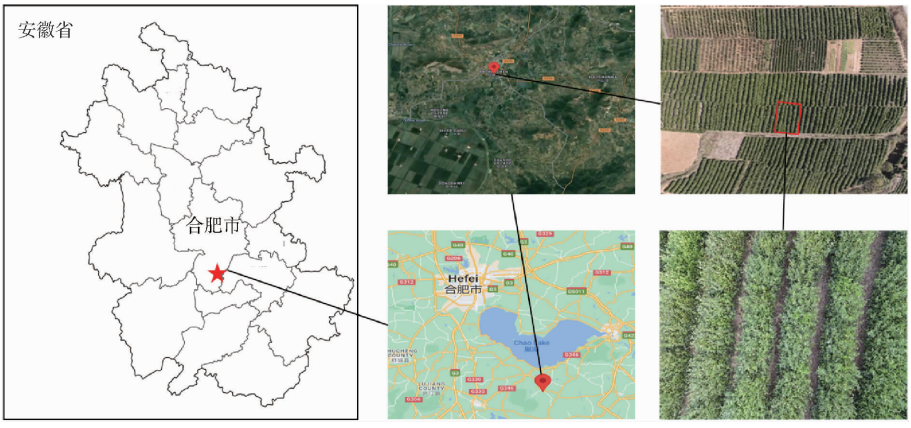

图 1　研究区域

Fig. 1　Study area

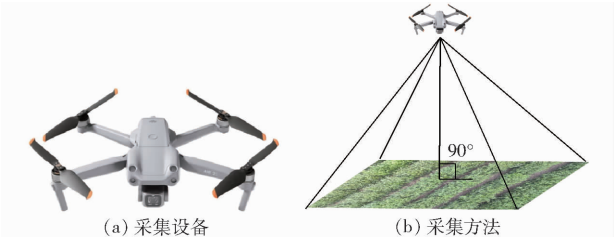

图 2　图像采集设备和采集方法

Fig. 2　Image acquisition equipment and acquisition method

本研究共获得了 33 幅无人机拍摄的野外茶园图像，每幅图像尺寸为 8 000 像素 ×6 000 像素，其中 24 幅野外茶园图像被用于 LiTLBNet 的训练和验证，9 幅被用于测试。训练和验证中的每幅图像都被剪切成 256 个图像块，每个图像块与相邻图像块之间有 50 像素的重叠。剪切方法如图 3 所示。在剪切的图像块中，共有 1 177 个图像块有茶叶枯病病斑，其余 103 个图像块只包含背景和健康茶叶。在农业生态学专家的指导下，使用 LabelImg 图像标注软件对图像块进行标注，生成 XML 文件，该文件包含每个图像块名称和大小以及图像块中茶叶枯病叶片位置信息。标注的图像块用来构建训练集和验证集，比例为 9∶1，因此训练集有 1 049 个图像块，验证集有 128 个图像块。在测试阶段，每个原始测试图像按照上述方法被剪切成 256 个图像块，检测结束后测试图像块被拼接成原始图像大小，最终实现对原始无人机图像中茶叶枯病病害检测。

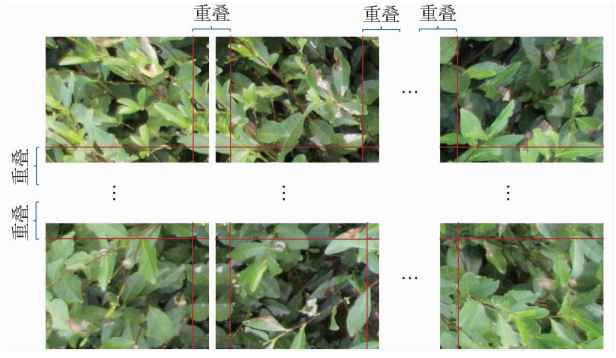

图 3　无人机遥感图像剪切方法示意图

Fig. 3　Schematic of UAV remote sensing image cutting method

为了提高 LiTLBNet 在小样本条件下的泛化性能，防止因训练样本不足而导致的过拟合，本研究扩充训练集中的图像块数量。扩充方法主要包括旋转图像块、添加噪声和构建合成图像块。图像块旋转 180°或 210°，添加的噪声包括高斯噪声和椒盐噪声。为了构建合成图像块，首先创建异常样本库，即用 Labelme 图像标签软件从原始图像中手动剪切出有病斑的茶叶图像块，然后，从异常样本库中随机选择茶叶枯病叶片，粘贴到只有背景或健康茶叶的图像块上，产生一个合成的图像块。图 4 给出了扩充的茶叶枯病图像块样例。扩充后，训练集中图像块数量为 2 028 个。表 1 给出了扩充后训练样本、验证样本和测试样本数量以及茶叶枯病叶片数量。

1.2　轻量型网络 LiTLBNet

由于精确度高和速度快，YOLO 系列网络目前已经成为目标检测的主流网络。本研究将尺寸小、训练和推理速度快的 YOLO v5s 选为基线网络，设计一种轻量型网络 LiTLBNet，以实现无人机遥感图像中茶叶枯病的实时检测。LiTLBNet 网络包括输入、骨干、颈部和预测头 4 部分，输入部分定义了不同形状的锚框，并将图像缩放到统一尺寸。

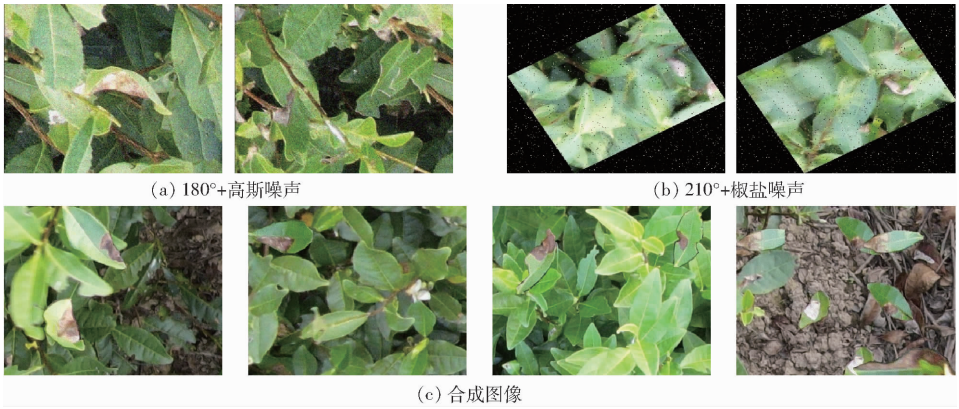

(a) 180°+高斯噪声 (b) 210°+椒盐噪声

(c) 合成图像

图 4 扩充的茶叶枯病图像块样例

Fig. 4 Examples of augmented TLB image blocks

表 1 扩充后图像块数和茶叶枯病叶片数

Tab. 1 Number of image blocks and TLB leaves after augmented

集合	图像数量/幅	茶叶枯病叶片数量/片
训练集	2 028	9 110
验证集	128	674
测试集	256	2 104
总和	2 412	11 888

LiTLBNet 的骨干网络采用轻量型的 M - Backbone 来提取茶叶枯病的特征图,以获得茶叶枯病病斑的可区分性特征。LiTLBNet 的颈部采用轻量型的 LNeck 结构,保留并简化了 FPN 和 PAN 以融合目标的顶层和底层特征,原 YOLO v5s 颈部结构中最大的特征图被删除以减小模型内存占用量,本研究还在 LNeck 结构中引入了 SE 和 ECA 注意力模块,帮助 LiTLBNet 在通道维度上学习目标的综合特征。预测头生成了目标的类概率和位置坐标。图 5 为轻量型网络 LiTLBNet 的结构。

1.2.1 M - Backbone

LiTLBNet 中的 M - Backbone 骨干网络从无人机遥感图像中提取茶叶枯病特征。M - Backbone 由 1 个 Conv2d 模块和 11 个串联的 M - Block 模块组成。Conv2d 模块由卷积、批量归一化和 h - swish 激活函数组成。与 YOLO v5s 的骨干网络不同,M - Backbone 是一个轻量型网络。M - Backbone 中的 M -Block 采用了深度可分离卷积以减少参数量,M - Block 中的 SE 模块可以帮助网络自主学习有用的通道特征并提取全局通道特征信息。与 ShufflenetV2 等其他轻量型骨干网络相比,M - Backbone 可以从无人机遥感图像中提取茶叶枯病病斑特征,其可区分性高,解决茶叶枯病病斑的尺度、颜色和形状的多样性问题,以减少漏检。M - Backbone 的结构如图 6 所示。

图 6 中 M - Block 模块的结构是一种轻量型的倒残差结构,它是由逐点卷积、深度卷积、SE 和线性逐点卷积(不使用非线性激活函数)串联而成[19]。$s=1$ 时 M - Block 模块结构如图 7a 所示。首先,卷积层中通道数量通过核大小为 1 × 1 的逐点卷积扩大,卷积后通道数量将由非线性激活函数调整。使用核大小为 3 × 3 的深度卷积来提取特征图的深度特征。插入一个 SE 模块来自主地获得每个特征通道的重要性程度。最后,进行线性逐点卷积。值得

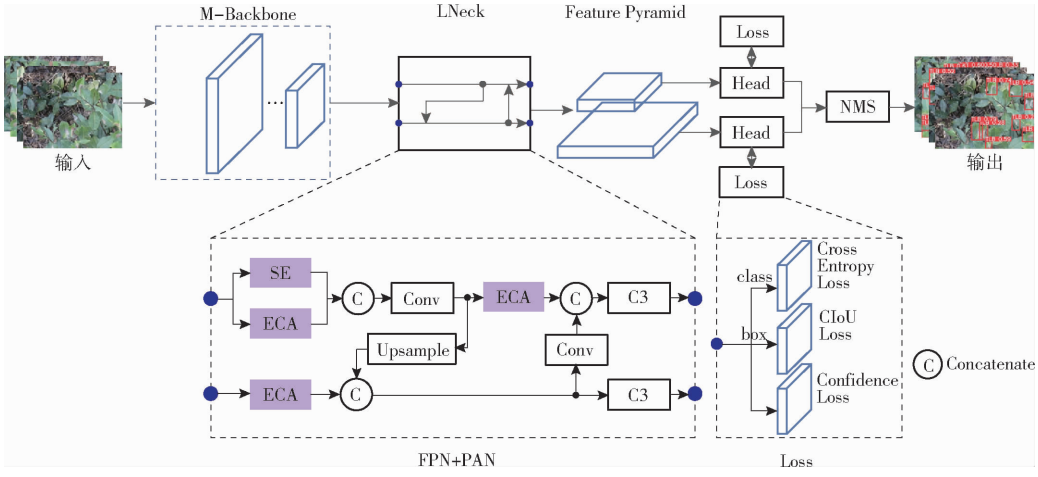

图 5 轻量型 LiTLBNet 网络结构

Fig. 5 Structure of lightweight network LiTLBNet

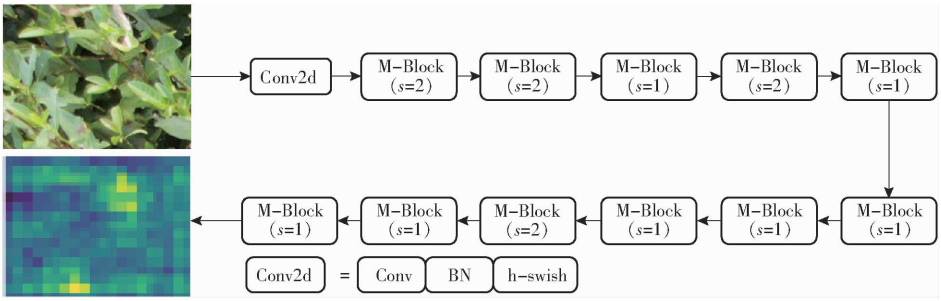

图 6　M－Backbone 结构

Fig. 6　Structure of M－Backbone

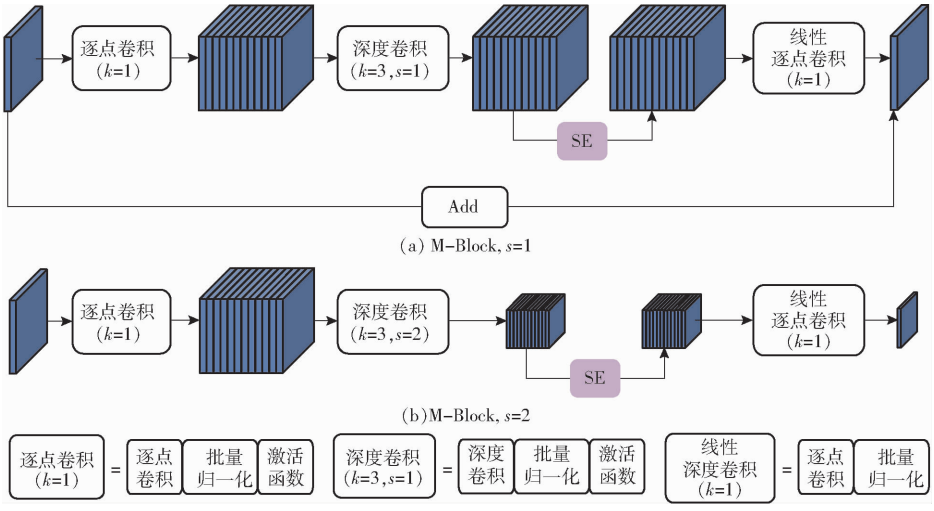

图 7　LiTLBNet 中 M－Block 模块结构

Fig. 7　Structure of M－Block module in LiTLBNet

注意的是，在这个卷积之后没有使用非线性激活函数，以避免特征图恢复时的信息损失。该结构中还有一个捷径分支，对输入和输出特征图的相同通道进行相加操作。$s=2$ 时 M－Block 模块结构如图 7b 所示，在这个结构中，输入和输出特征图的通道数不一样，也没有捷径连接。输出特征图是通过对输入特征图进行下采样得到，这可以扩展 LiTLBNet 的感受野。

M－Block 模块轻量化的主要原因是采用了深度可分离卷积，如图 8 所示。深度可分离卷积参数和计算量比普通卷积少，但计算过程仍然保证了空间信息的提取和跨通道信息的融合。

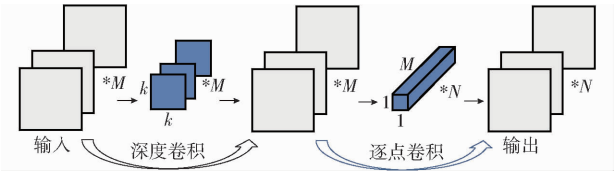

图 8　深度可分离卷积结构

Fig. 8　Structure of depthwise separable convolution

1.2.2　LNeck 结构

与 YOLO v5s 不同，LiTLBNet 的颈部网络采用轻量型的 LNeck。尽管无人机图像中茶叶枯病病斑尺度、颜色和形状有明显不同，但病叶尺寸基本相同。因此，LNeck 保留了 YOLO v5s 颈部网络中的 FPN 和 PAN 结构来融合语义特征，特征融合是在不同层上进行的。为了保证 LiTLBNet 能够很好地学习茶叶枯病病斑特征，同时加快训练和推理过程，本研究通过删除最大的特征图（80 像素 ×80 像素）来简化原始 FPN 和 PAN 结构。无人机在野外采集的茶园图像中不仅有茶叶枯病叶片，还有大量的复杂背景，如土地、杂草等，这些背景与茶叶枯病叶片高度相似，使用轻量型网络削弱了提取病害特征的能力。为此，本研究在 LiTLBNet 中的两个地方引入了注意力模块。在 M－Backbone 和 LNeck 的连接处增加了并联的 SE 和 ECA 注意力模块，以自适应地提取有关茶叶枯病的全局和局部通道特征，并融合提取的特征信息，获得通道维度上的综合特征。在 LNeck 中加入 ECA 注意力模块，以突出深度卷积生成的特征图中的目标特征，强化深度图像中的病叶目标信息，并弱化背景信息，以增强对病叶的关注，减少因病叶与背景相似而造成的误检。

SE 注意力模块对输入特征图进行通道特征增强（图 9）。图 9 中的 GAP 代表全局平均池化，MLP 是全连接（Fully connected，FC）层、ReLU 激活函数和 sigmoid 激活函数的组合。SE 注意力模块首先进

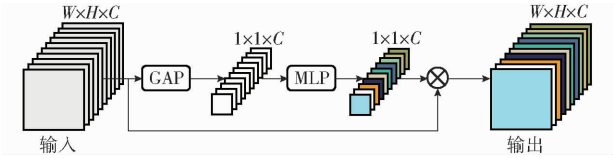

图 9 SE 注意力模块结构

Fig. 9 Structure of SE attention module

行全局平均池化,在空间维度上压缩空间特征;然后,从压缩后的特征中学习通道特征,主要通过 2 个 FC 层来实现学习不同通道的重要目标。最后,通道关注的特征图(1 × 1 × C)和输入特征图($W \times H \times C$)逐个通道相乘,产生一个具有通道关注的特征图。

ECA 模块是轻量型的通道注意力模块(图 10),它为重要的特征生成高权重,为不重要的特征生成低权重,这使得 LiTLBNet 能够更多地关注病叶特征,而减少对健康茶叶和背景的关注。ECA 和 SE 之间最大的区别是 ECA 使用自适应确定的卷积核进行 1 × 1 卷积,以学习不同通道的重要性,使其能够从不同的输入特征图中提取不同的局部范围特征。1 × 1 卷积只能学习通道之间的局部信息,而 SE 使用 FC 层来学习和处理输入通道特征图的全局。因此,SE 和 ECA 注意力模块的组合可以同时学习目标的全局和局部通道特征。

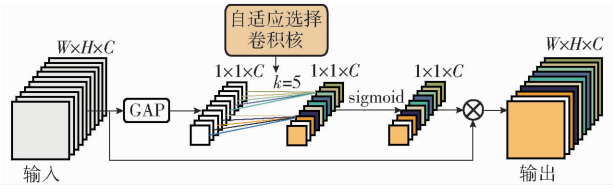

图 10 ECA 注意力模块结构

Fig. 10 Structure of ECA attention module

1.3 检测步骤

使用所设计的轻量型网络 LiTLBNet 检测无人机图像中茶叶枯病病害步骤如下:

(1)拍摄野外茶园无人机图像(8 000 像素 × 6 000 像素),构成原始训练集和测试集。

(2)将原始训练集中的每幅图像裁剪成 256 个图像块,每个图像块之间有 50 像素的重叠。

(3)选择含有茶叶枯病病斑的图像块,构成训练集和验证集。使用 LabelImg 图像标记软件对这些图像块进行标注。

(4)训练集中的图像块通过旋转、加噪声和构建合成图像块的方法进行扩充。

(5)设计轻量型茶叶枯病检测网络 LiTLBNet。

(6)用扩充的训练集和验证集对 LiTLBNet 进行训练和验证。

(7)根据步骤(2)的方法,将原始测试集的图像剪切成 256 个图像块,然后将这些图像块输入到训练好的 LiTLBNet 中,得到检测结果。

(8)将有检测结果的图像块拼接成与原始无人机图像尺寸相同的图像,实现对无人机图像中茶叶枯病病害的检测。

2 实验结果和分析

2.1 不同深度卷积神经网络的检测结果

图 11 为 3 个含有茶叶枯病的测试图像块,图中红色矩形表示地面真实的茶叶枯病叶片。图 12 为使用不同深度卷积神经网络对图 11 所示的 3 个测试图像块的检测结果,这些深度卷积神经网络都使用与本研究相同的数据扩充方式来进行训练。图 12 中的红色、黄色和蓝色矩形分别表示正确检测、漏检和误检。由于光线不均匀,叶片上的光斑很容易被网络误认为是病斑,从而被错误地检测为目标。此外,病斑形状和颜色不同,无人机遥感图像分辨率低,病斑颜色和纹理与土地颜色和纹理非常相似,导致漏检。从图 12 可以看出,大多数深度卷积神经网络都存在一定数量的误检和漏检。Faster R - CNN[31]、RetinaNet[32]、SSD[33]、YOLO v3[34]、YOLO v5s 等检测结果有较多的漏检和误检。本研究利用轻量型骨干网络和 LNeck 中的注意力模块可以更好地将病叶与背景区分开来,解决茶叶枯病病斑的类内差异性和茶叶枯病病斑与背景的类间相似性问题,这使得所提出网络可以有效地检测茶叶枯病病叶,减少漏检和误检。与其他深度卷积神经网络方法相比,LiTLBNet 网络漏检和误检率更低。



图 11 3 个含有茶叶枯病的测试图像块

Fig. 11 Three test image blocks containing TLB disease

表 2 为不同深度卷积神经网络在所有测试图像块上的检测结果。可以看出,参数量和浮点运算量(FLOPs)较大的网络的平均精度均值(mAP)与参数量和 FLOPs 较小的网络的平均精度均值相似,说明网络内存占用量与平均精度均值之间没有直接关系,轻量型卷积神经网络也可以取得好的性能。轻量型网络 LiTLBNet 的精确率(Precision)、召回率(Recall)和 F1 值较高,其平均精度均值仅比 YOLO v5s 低 0.7 个百分点,比 YOLO X - s 低 2.3 个百分点。然而,LiTLBNet 模型内存占用量是 YOLO v5s 的 14.3%,是 YOLO X - s[35] 的 5.5%。LiTLBNet 参

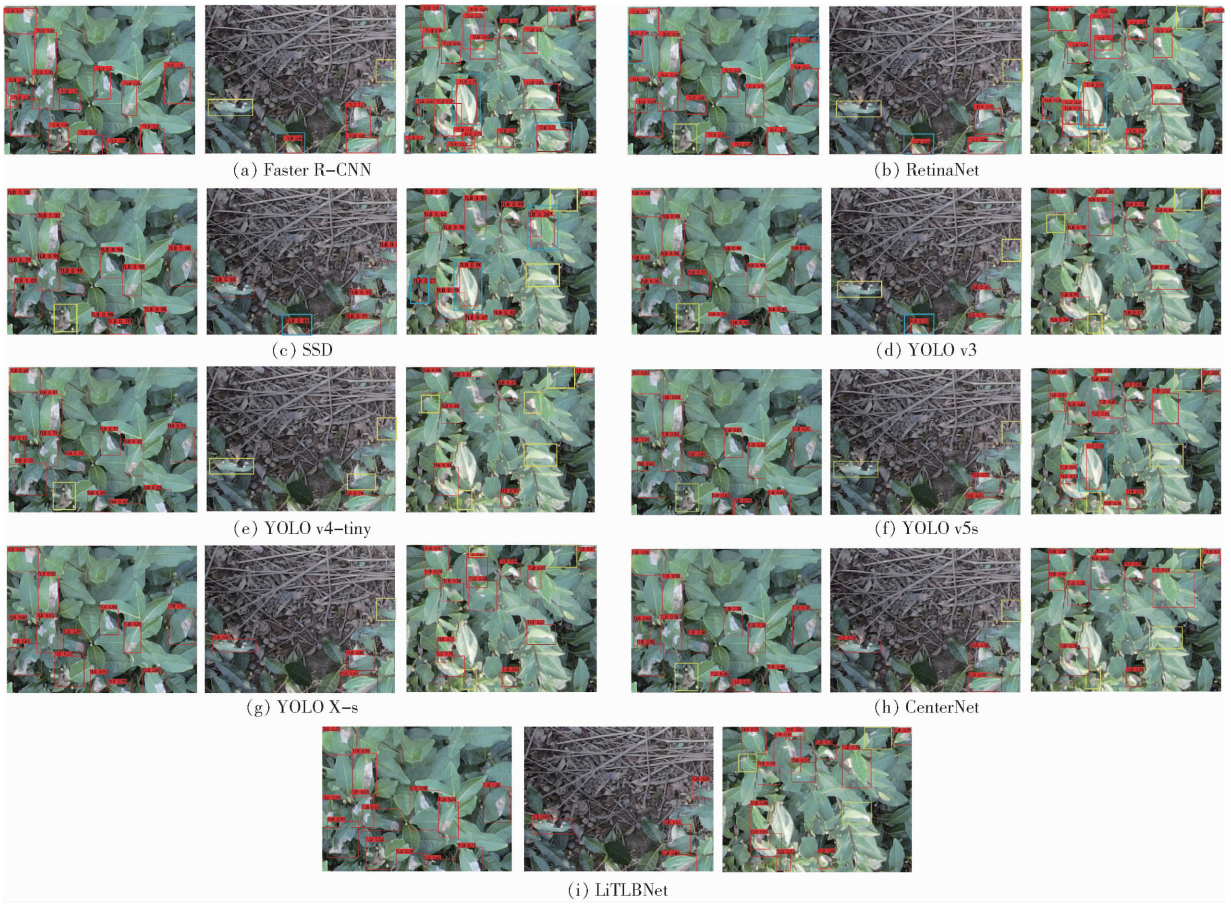

图 12　不同深度卷积神经网络的检测结果

Fig. 12　Detection results of different deep convolutional neural network

表 2　不同深度卷积神经网络的量化评估结果

Tab. 2　Quantitative evaluation results of different deep convolutional neural network

检测网络	精确率/%	召回率/%	平均精度均值/%	F1 值/%	参数量	浮点运算量	模型内存占用量/MB
Faster R－CNN	56.5	82.3	77.5	67.0	2.8×10^{7}	9.5×10^{11}	113.4
RetinaNet	80.7	70.5	78.3	75.0	3.6×10^{7}	1.6×10^{11}	145.7
SSD	77.6	72.6	76.9	75.0	2.4×10^{7}	2.7×10^{11}	95.0
YOLO v3	86.7	49.1	74.6	63.0	6.2×10^{7}	1.6×10^{11}	246.5
YOLO v4-tiny	81.7	41.1	68.7	55.0	5.9×10^{6}	1.6×10^{10}	23.6
YOLO v5s	75.3	72.9	79.2	74.0	7.0×10^{6}	1.6×10^{10}	14.4
YOLO X－s	81.3	72.1	80.8	76.0	9.0×10^{6}	2.7×10^{10}	36.0
CenterNet	91.2	49.3	76.7	64.0	3.3×10^{7}	1.1×10^{11}	131.0
LiTLBNet	75.1	71.1	78.5	73.0	9.0×10^{5}	1.3×10^{9}	2.0

数量只有 9×10^{5}，FLOPs 只有 1.3×10^{9}。因此，本研究中设计的轻量型检测网络 LiTLBNet 具有良好的性能。

2.2　不同轻量型骨干检测结果

图 13 比较了不同轻量型骨干的检测结果，其中黄色矩形代表漏检，蓝色矩形代表误检。表 3 列出了不同轻量型网络在所有测试图像块上的定量评价结果。从表 3 可以看出，轻量型网络 LiTLBNet 与 ShufflenetV2 的参数量相近，模型内存占用量与 ShufflenetV2 相同，浮点运算量比 ShufflenetV2 低 5×10^{8}；但是，精确率和平均精度均值分别提高 5.6、2.9 个百分点。与 Ghostnet 相比，平均精度均值相近，但模型内存占用量小得多，其参数量不到 Ghostnet 的 1/4，浮点运算量不到 Ghostnet 的 1/6。



图 13　不同轻量型骨干的检测结果

Fig. 13　Detection results of different lightweight backbones

2.3　消融实验

本研究使用数据扩充来防止过拟合。轻量型骨干网络 M－Backbone 用于特征提取，获取目标的可

表 3 不同轻量型骨干的定量评价结果

Tab. 3 Quantitative evaluation results of different lightweight backbones

轻量型骨干	精确率/%	召回率/%	平均精度均值/%	F1 值/%	参数量	浮点运算量	模型内存占用量/MB
ShufflenetV2	69.5	71.8	75.6	71.0	8.4×10^5	1.8×10^9	2.0
Ghostnet	75.5	71.2	77.9	73.0	3.7×10^6	8.1×10^9	7.8
LiTLBNet	75.1	71.1	78.5	73.0	9.0×10^5	1.3×10^9	2.0

区分特征,减少因茶叶枯病病斑的尺度、颜色和形状的巨大差异而造成的漏检。简化 FPN 和 PAN,并在 LNeck 中引入 SE 和 ECA 注意力模块,有助于 LiTLBNet 学习病斑的全局和局部通道特征,减少因病斑和背景之间的相似性造成的误检。表 4 为所有测试图像块上的消融实验结果。

表 4 消融实验结果

Tab. 4 Results of ablation experiments

扩充	M - Backbone	FPN + PAN	SE + ECA	精确率/%	召回率/%	平均精度均值/%	F1 值/%	参数量	浮点运算量	模型内存占用量/MB
-	-	-	-	77.5	71.2	78.3	74.0	7.0×10^6	1.6×10^{10}	14.4
√	-	-	-	75.3	72.9	79.2	74.0	7.0×10^6	1.6×10^{10}	14.4
-	√	-	-	68.9	66.2	71.6	68.0	1.4×10^6	2.2×10^9	3.1
√	√	-	-	72.0	70.2	75.9	71.0	1.4×10^6	2.2×10^9	3.1
√	√	√	-	73.8	72.2	75.9	73.0	9.0×10^5	1.3×10^9	2.0
√	√	√	√	75.1	71.1	78.5	73.0	9.0×10^5	1.3×10^9	2.0

注:“√”表示模块被添加到极限网络中,“-”表示不进行这一操作。

从表 4 可以看出,在没有数据扩充的情况下,只用 M - Backbone 替换基线网络的骨干网络,网络内存占用量会大幅减少到 YOLO v5s 的 21.5%,但检测结果的其他定量评价值却有所下降。当使用扩充的训练图像集训练网络时,精确率、召回率、平均精度均值和 F1 值分别提高 3.1、4、4.3、3 个百分点。当最大的特征图被删除后,网络参数量、浮点运算量和网络内存占用量都减少,同时保持了检测精度,使网络更加轻量化。在 LNeck 中加入 SE 和 ECA 注意力模块后,参数量略有增加,但平均精度均值进一步提高到 78.5%,与基线网络 YOLO v5s 平均精度均值相差 0.7 个百分点。本研究提出的由样本扩充、M - Backbone、FPN + PAN 和 SE + ECA 模块组成的轻量型网络 LiTLBNet 平均精度均值与 YOLO v5s 基本相同,但 LiTLBNet 参数量只有 9×10^5,浮点运算量只有 1.3×10^9,模型内存占用量只有 2.0 MB,这意味着所提出网络可以对无人机图像中的茶叶枯病病害进行实时检测,而且精度较高。

2.4 热力图可视化

本研究将 SE 和 ECA 注意力模块引入到 LiTLBNet 中。图 14 为可视化热力图,第 1 列是 LiTLBNet 对测试图像块的检测结果,其余 3 列是检测头输出的可视化热力图。图 14a 和图 14b 分别为在网络中加入注意力模块之前和之后的热力图可视化结果。从图 14 中可以看到,加入注意力模块后,网络可以提取更全面的通道特征,对病斑区域的关注度更高,对背景区域的关注度更低,这说明了在 LiTLBNet 中引入 SE 和 ECA 注意力模块的有效性。

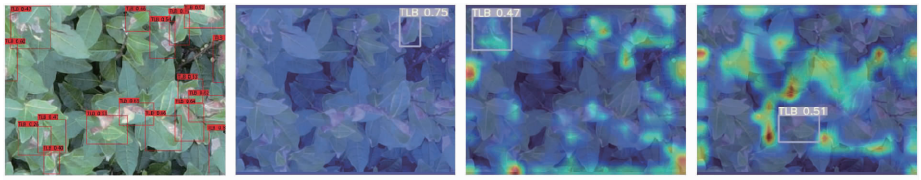

(a) 添加注意力模块前

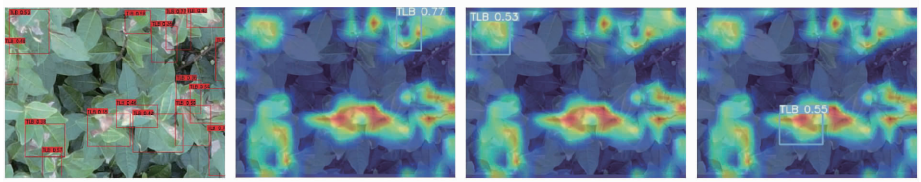

(b) 添加注意力模块后

图 14 热力图可视化结果

Fig. 14 Heat map visualization results

3　讨论

在偏远崎岖的山区茶园中快速、准确地检测茶叶枯病，以便采取措施防止茶叶枯病的传播，对减少茶叶损失、提高茶叶产量和质量非常重要。HU 等[36]使用改进的 Faster R－CNN 网络检测自然场景图像中的茶叶枯病病害，该网络仅适用于地面高分辨率图像中的茶叶枯病。ZHAO 等[37]利用检测网络 WGNet 来检测麦粒，使用稀疏网络修剪和混合注意力模块来解决退化问题，它提供了更快的预测和更高的准确性。然而，该网络是在实验室环境下用于检测麦粒的。自然环境下图像背景复杂，枯草、树叶、土壤和岩石都会影响检测结果。另外，无人机获取图像时光线不均匀，图像中的光斑往往被误认为病斑。此外，无人机图像低分辨率和病斑不明显性使得现有轻量型检测网络检测精度不够。本研究设计了一个轻量型茶叶枯病检测网络 LiTLBNet 来检测无人机遥感图像中的茶叶枯病病害，网络可以进行实时检测，同时保证较高的检测精度。

每幅原始测试图像被剪切成 256 幅，并输入训练好的 LiTLBNet 中进行茶叶枯病检测。检测完成后，必须将图像拼接起来，以呈现每幅原始测试图像的检测结果，如图 15 所示。考虑到病斑的大小，该研究使用了 50 像素的重叠来剪切图像块。这意味着拼接在一起的图像块的边缘大多保留了完整的检测框，但这种方法也产生了一些不完整和移位的检测框。在未来的工作中，可以尝试使用 Python 中 PIL 库的接口处理方法将两幅图像合并成一幅图像，例如，可以使用混合接口方法或掩码来合并图像，这样每个检测框就可以完全显示出来。

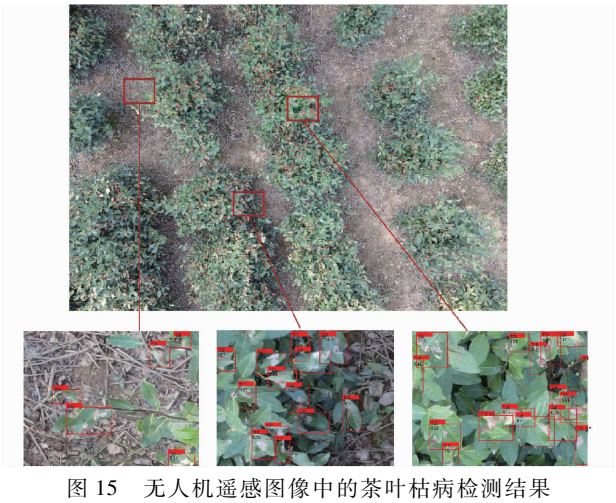

图 15　无人机遥感图像中的茶叶枯病检测结果

Fig. 15　TLB detection results for UAV remote sensing image

在 LiTLBNet 网络的检测结果中仍有一些漏检，如图 16a 所示，黄色矩形表示漏检的茶叶枯病叶片。这些病叶有一个共同点：病斑部分脱落，叶片不完整，这意味着网络没有学习到病斑的有效特征信息，因此没有检测到这些叶片。在未来工作中，对这些类型的叶片尝试恢复它们的原始形状。在图 16b 中，由黄色矩形标记的茶叶枯病叶子没有被检测到，因为它们被遮挡住。茶叶相互遮挡是一个常见的问题，导致大部分的病斑被遮挡住，因此，特征信息大大减少。此外，无人机遥感图像分辨率不如手持相机拍摄图像分辨率高，在低分辨率图像中，特征信息也不明显。下一步工作将找寻更好的网络，在保持轻量型的同时提高检测精度。

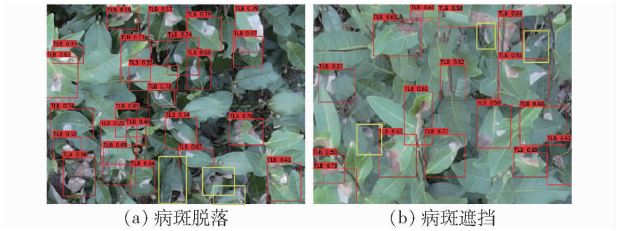

(a) 病斑脱落　　(b) 病斑遮挡

图 16　漏检示例图

Fig. 16　Examples of missed detections

4　结束语

利用安装在无人机上的可见光相机，采集野外茶园的遥感图像，动态监测茶叶枯病，以便及时有效地控制病害的传播。然而，在野外茶园无人机遥感图像中，茶叶枯病病斑的尺度、颜色和形状的多样性会导致漏检。此外，与普通数码相机拍摄的地面图像不同，无人机遥感图像的分辨率较低，背景复杂，光照不均匀，茶叶枯病病斑的颜色和纹理与背景的颜色和纹理相似，会导致误检。因此，在本研究中，轻量型骨干网络可以提取可区分性特征，解决茶叶枯病病斑的类内差异性问题，减少漏检。在颈部网络中加入 SE 和 ECA 注意力模块，可以使其提取更全面的通道特征，解决茶叶枯病病斑与复杂背景或光斑之间的相似性问题，减少误检。LiTLBNet 网络平均精度均值为 78.5%，仅比 YOLO v5s 低 0.7 个百分点，但浮点运算量和模型内存占用量分别为 1.3×10^9 和 2.0 MB，是 YOLO v5s 的 8.2% 和 13.9%。因此，对于拍摄的野外茶园无人机遥感图像，所提出的 LiTLBNet 网络可以进行实时和准确的茶叶枯病检测。

参　考　文　献

[1]　HU G, WEI K, ZHANG Y, et al. Estimation of tea leaf blight severity in natural scene images[J]. Precision Agriculture, 2021, 22: 1239－1262.

[2] ZHANG S, LI X, BA Y, et al. Banana fusarium wilt disease detection by supervised and unsupervised methods from UAV-based multispectral imagery[J]. Remote Sensing, 2022, 14(5): 1231.
[3] XIAO D, PAN Y, FENG J, et al. Remote sensing detection algorithm for apple fire blight based on UAV multispectral image [J]. Computers and Electronics in Agriculture,2022, 199: 107137.
[4] MARIN D B, SANTANA L S, BARBOSA B D S, et al. Detecting coffee leaf rust with UAV-based vegetation indices and decision tree machine learning models[J]. Computers and Electronics in Agriculture, 2021, 190: 106476.
[5] LAN Y, HUANG Z, DENG X, et al. Comparison of machine learning methods for citrus greening detection on UAV multispectral images[J]. Computers and Electronics in Agriculture, 2020, 171: 105234.
[6] ABUDLRIDHA J, AMPATZIDIS Y, KAKARLA S C, et al. Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques[J]. Precision Agriculture, 2020, 21: 955 - 978.
[7] ABDULRIDHA J, AMPATZIDIS Y, ROBERTS P, et al. Detecting powdery mildew disease in squash at different stages using UAV-based hyperspectral imaging and artificial intelligence[J]. Biosystems Engineering, 2020, 197: 135 - 148.
[8] SU J, LIU C, COOMBES M, et al. Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery[J]. Computers and Electronics in Agriculture, 2018, 155: 157 - 166.
[9] ZHAO J, YAN J, XUE T, et al. A deep learning method for oriented and small wheat spike detection (OSWSDet) in UAV images[J]. Computers and Electronics in Agriculture, 2022, 198: 107087.
[10] DENG J, ZHOU H, LV X, et al. Applying convolutional neural networks for detecting wheat stripe rust transmission centers under complex field conditions using RGB-based high spatial resolution images from UAVs[J]. Computers and Electronics in Agriculture, 2022, 200: 107211.
[11] ZHANG T, YANG Z, XU Z, et al. Wheat yellow rust severity detection by efficient DF - UNet and UAV multispectral imagery [J]. IEEE Sensors Journal, 2022, 22(9): 9057 - 9068.
[12] GORLICH F, MARKS E, MAHLEIN A K, et al. UAV-based classification of cercospora leaf spot using RGB images[J]. Drones, 2021, 5(2): 34.
[13] 胡根生,吴继甜,鲍文霞,等. 基于改进 YOLO v5 网络的复杂背景图像中茶尺蠖检测[J]. 农业工程学报, 2021, 37(21): 191 - 198.
HU Gensheng, WU Jitian, BAO Wenxia, et al. Detection of *Ectropis oblique* in complex background images using improved YOLO v5[J]. Transactions of the CSAE, 2021, 37(21): 191 - 198. (in Chinese)
[14] DANG L M, HASSAN S I, SHUYEON I, et al. UAV based wilt detection system via convolutional neural networks[J]. Sustainable Computing: Informatics and Systems, 2020, 28: 100250.
[15] 李就好,林乐坚,田凯. 改进 Faster R - CNN 的田间苦瓜叶部病害检测[J]. 农业工程学报, 2020, 36(12): 179 - 185.
LI Jiuhao, LIN Lejian, TIAN Kai, et al. Detection of leaf diseases of balsam pear in the field based on improved Faster R - CNN[J]. Transactions of the CSAE, 2020, 36(12): 179 - 185. (in Chinese)
[16] KERKECH M, HAFIANE A, CANALS R. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach[J]. Computers and Electronics in Agriculture, 2020, 174: 105446.
[17] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size[J]. arXiv preprint arXiv:1602.07360, 2016.
[18] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251 - 1258.
[19] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNetV3[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314 - 1324.
[20] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient CNN architecture design[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 116 - 131.
[21] HAN K, WANG Y, TIAN Q, et al. Ghostnet: more features from cheap operations[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580 - 1589.
[22] TAN M, LE Q. Efficientnet: rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. PMLR, 2019: 6105 - 6114.
[23] HE C, LI X, LIU Y, et al. Combining multicolor fluorescence imaging with multispectral reflectance imaging for rapid citrus Huanglongbing detection based on lightweight convolutional neural network using a handheld device[J]. Computers and Electronics in Agriculture, 2022, 194: 106808.
[24] SUTAJI D, YILDIZ O. LEMOXINET: lite ensemble MobileNetV2 and Xception models to predict plant disease[J]. Ecological Informatics, 2022, 70: 101698.
[25] ZHAO R, ZHU Y, LI Y. An end-to-end lightweight model for grape and picking point simultaneous detection[J]. Biosystems Engineering, 2022, 223: 174 - 188.
[26] LU X, YANG R, ZHOU J, et al. A hybrid model of ghost-convolution enlightened transformer for effective diagnosis of grape leaf disease and pest[J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34(5): 1755 - 1767.
[27] CHEN J, CHEN W, ZEB A, et al. Lightweight inception networks for the recognition and detection of rice plant diseases[J]. IEEE Sensors Journal, 2022, 22(14): 14628 - 14638.
[28] LI Y, WANG J, WU H, et al. Detection of powdery mildew on strawberry leaves based on DAC - YOLO v4 model[J].

Computers and Electronics in Agriculture, 2022, 202: 107418.
[29] GAO F, SA J, WANG Z, et al. Cassava disease detection method based on EfficientNet[C]// 2021 7th International Conference on Systems and Informatics (ICSAI). IEEE, 2021: 1-6.
[30] 杨佳昊,左昊轩,黄祺成,等.基于 YOLO v5s 的作物叶片病害检测模型轻量化方法[J].农业机械学报,2023,54(增刊1):222-229.
YANG Jiahao, ZUO Haoxuan, HUANG Qicheng, et al. Lightweight method for crop leaf disease detection model based on YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 222-229. (in Chinese)
[31] REN S, HE K, GIFSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
[32] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
[33] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// Computer Vision-ECCV, 2016: 21-37.
[34] REDMON J, FARHADI A. Yolov3: an incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.
[35] GE Z, LIU S, WANG F, et al. Yolox: exceeding YOLO series in 2021[J]. arXiv preprint arXiv: 2107.08430, 2021.
[36] HU G, WANG H, ZHANG Y, et al. Detection and severity analysis of tea leaf blight based on deep learning[J]. Computers & Electrical Engineering, 2021, 90: 107023.
[37] ZHAO W, LIU S, LI X, et al. Fast and accurate wheat grain quality detection based on improved YOLO v5[J]. Computers and Electronics in Agriculture, 2022, 202: 107426.

(上接第 154 页)

[28] DONG T, LIU J, SHANG J, et al. Assessment of red-edge vegetation indices for crop leaf area index estimation[J]. Remote Sensing of Environment, 2019, 222: 133-143.
[29] HASITUYA, CHEN Z, WANG L, et al. Monitoring plastic-mulched farmland by Landsat-8 oli imagery using spectral and textural features[J]. Remote Sensing, 2016, 8(4): 353.
[30] LA C D, TOM M, STAMM C, et al. Pixel-based mapping of open field and protected agriculture using constrained Sentinel-2 data[J]. ISPRS Open Journal of Photogrammetry and Remote Sensing, 2023, 8: 100033.
[31] 谷晓博, 程智楷, 周智辉, 等. 基于特征降维和机器学习的覆膜冬小麦 LAI 遥感反演[J]. 农业机械学报, 2023, 54(6): 148-157, 167.
GU Xiaobo, CHENG Zhikai, ZHOU Zhihui, et al. Remote sensing inversion of leaf area index of mulched winter wheat based on feature downscaling and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 148-157, 167. (in Chinese)
[32] 陶惠林, 冯海宽, 杨贵军, 等. 基于无人机数码影像和高光谱数据的冬小麦产量估算对比[J]. 农业工程学报, 2019, 35(23): 111-118.
TAO Huilin, FENG Haikuan, YANG Guijun, et al. Comparison of winte wheat yields estimated with UAV digital image and hyperspectral data[J]. Transactions of the CSAE, 2019, 35(23): 111-118. (in Chinese)
[33] 杨晓菲, 张树军, 唐敏. 播期和温度对冬小麦抽穗期的影响分析[J]. 河南科学, 2021, 39(6): 929-933.
YANG Xiaofei, ZHANG Shujun, TANG Min. Correlation analysis of sowing date and temperature on heading date of winter wheat[J]. Hennan Science, 2021, 39(6): 929-933. (in Chinese)
[34] TUVDENDORJ B, WU B, ZENG H, et al. Determination of appropriate remote sensing indices for spring wheat yield estimation in Mongolia[J]. Remote Sensing, 2019, 11(21): 2568.
[35] 刘新杰, 魏云霞, 焦全军, 等. 基于时序定量遥感的冬小麦长势监测与估产研究[J]. 遥感技术与应用, 2019, 34(4): 756-765.
LIU Xinjie, WEI Yunxia, JIAO Quanjun, et al. Growth monitoring and yield prediction of winter wheat based on time-series quantitative remote sensing data[J]. Remote Sensing Technology and Application, 2019, 34(4): 756-765. (in Chinese)
[36] ORLANDO S, MINACAPILLI M, SARNO M, et al. A low-cost multispectral imaging system for the characterisation of soil and small vegetation properties using visible and near-infrared reflectance[J]. Computers and Electronics in Agriculture, 2022, 202: 107359.
[37] 董羊城, 蔡炳祥, 王福民, 等. 基于最佳植被指数组合的水稻鲜生物量估测[J]. 科技通报, 2019, 35(6): 59-65.
DONG Yangcheng, CAI Bingxiang, WANG Fumin, et al. Estimation of fresh biomass of rice based on optimum vegetation index[J]. Bulletin of Science and Technology, 2019, 35(6): 59-65. (in Chinese)
[38] FU Z, JIANG J, GAO Y, et al. Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle[J]. Remote Sensing, 2020, 12(3): 508.