

doi:10.6041/j.issn.1000-1298.2024.01.020

基于 YOLO v5 的农田杂草识别轻量化方法研究

冀汶莉¹ 刘洲¹ 邢海花²

(1. 西安科技大学通信与信息工程学院, 西安 710600; 2. 海南师范大学信息科学技术学院, 海口 571158)

摘要: 针对已有杂草识别模型对复杂农田环境下多种目标杂草的识别率低、模型内存占用量大、参数多、识别速度慢等问题, 提出了基于 YOLO v5 的轻量化杂草识别方法。利用带色彩恢复的多尺度视网膜 (Multi-scale retinex with color restoration, MSRCR) 增强算法对部分图像数据进行预处理, 提高边缘细节模糊的图像清晰度, 降低图像中的阴影干扰。使用轻量级网络 PP – LCNet 重置了识别模型中的特征提取网络, 减少模型参数量。采用 Ghost 卷积模块轻量化特征融合网络, 进一步降低计算量。为了弥补轻量化造成的模型性能损耗, 在特征融合网络末端添加基于标准化的注意力模块 (Normalization-based attention module, NAM), 增强模型对杂草和玉米幼苗的特征提取能力。此外, 通过优化主干网络注意力机制的激活函数来提高模型的非线性拟合能力。在自建数据集上进行实验, 实验结果显示, 与当前主流目标检测算法 YOLO v5s 以及成熟的轻量化目标检测算法 MobileNet v3 – YOLO v5s、ShuffleNet v2 – YOLO v5s 比较, 轻量化后杂草识别模型内存占用量为 6.23 MB, 分别缩小 54.5%、12% 和 18%; 平均精度均值 (Mean average precision, mAP) 为 97.8%, 分别提高 1.3、5.1、4.4 个百分点。单幅图像检测时间为 118.1 ms, 达到了轻量化要求。在保持较高模型识别精度的同时大幅降低了模型复杂度, 可为采用资源有限的移动端设备进行农田杂草识别提供技术支持。

关键词: 杂草识别; 目标检测; YOLO v5s; 轻量化特征提取网络; Ghost 卷积模块; 注意力机制

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1298(2024)01-0212-11

OSID:



Lightweight Method for Identifying Farmland Weeds Based on YOLO v5

JI Wenli¹ LIU Zhou¹ XING Haihua²

(1. College of Communications and Information Engineering, Xi'an University of Science and Technology, Xi'an 710600, China)

2. School of Information Science and Technology, Hainan Normal University, Haikou 571158, China)

Abstract: The disadvantage of the existing weed recognition models for a variety of small target weeds is that they are low recognition rate, large volume, many parameters and slow detection speed in complex farmland environment. In order to solve this problem, a lightweight weed recognition method was proposed based on YOLO v5 model. Firstly, the multi-scale retinex with color restoration (MSRCR) algorithm was used to preprocess part of the image data to improve the image definition with blurred edge details and reduce the shadow interference in the image. On this basis, the feature extraction network in the recognition model was reset by using the lightweight network PP – LCNet to reduce the amount of model parameters. Secondly, the Ghost convolution model lightweight feature fusion network was used to further reduce the amount of calculation. In order to make up for the loss of model performance caused by lightweight, a normalization-based attention module (NAM) was added at the end of the feature fusion network to enhance the feature extraction ability of the model for weeds and corn seedlings. Finally, the activation function of the attention mechanism of the backbone network was optimized to improve the nonlinear fitting ability of the model. Experiments were carried out on the self-built dataset. The experimental results showed that compared with the current mainstream target detection algorithm YOLO v5s and the mature lightweight target detection algorithms MobileNet v3 – YOLO v5s and ShuffleNet v2 – YOLO v5s, the volume of the lightweight weed recognition model was 6.23 MB, which was reduced by 54.5%, 12% and 18%, respectively. The mean average precision (mAP) was 97.8%, which was

收稿日期: 2023-06-20 修回日期: 2023-09-20

基金项目: 国家自然科学基金项目(62066013)、海南省自然科学基金项目(622RC674)和西安市科技局农业科技创新工程项目(20193054YF042NS042)

作者简介: 冀汶莉(1973—),女,副教授,博士,主要从事深度学习在农业和工业领域应用研究,E-mail: jiwenli@xust.edu.cn

increased by 1.3 percentage points, 5.1 percentage points, and 4.4 percentage points, respectively. The detection time of single image was 118.1 ms, which achieved the requirement of lightweight. It could significantly reduce the complexity of the model while maintaining high model recognition accuracy. The proposed method could identify corn seedling and weed accurately and rapidly, which provided technical support for the use of mobile devices with limited resources for farmland weed recognition.

Key words: weed recognition; target detection; YOLO v5s; lightweight feature extraction network; Ghost convolution module; attention mechanisms

0 引言

玉米是我国除了小麦和水稻以外主要的农作物,杂草会和玉米幼苗争夺养分和水分,影响玉米幼苗生长^[1-3]。据统计,我国每年杂草发生面积达 $9.333 \times 10^7 \text{ hm}^2$ 以上,造成粮食损失300多万吨^[4]。目前我国田间杂草控制方法通常以大范围喷洒除草剂的方式来完成,喷洒的农药残留物不仅对农作物的生长造成污染,也会破坏土壤生态环境^[5-6]。解决农作物和杂草的准确识别问题,实现智能化除草,对提高农作物产量和减少农药对环境造成的影响有重要作用。

田间杂草可以利用除草机器人来完成识别和清除,但除草机器人核心处理设备计算和存储资源有限。对作物幼苗和杂草的识别在保证识别精度的情况下,减少模型参数量和计算复杂度,提高杂草检测速度仍需要进一步研究。杂草识别问题引起部分学者的研究兴趣。文献[7-10]使用卷积神经网络建立基于深度学习的杂草识别模型,改进的杂草识别模型mAP均超过74%。上述研究大多采用多层次卷积网络进行目标特征提取和目标识别,但也存在模型体积大、参数多、检测速度慢,难以部署到小型移动端设备上的问题。研究者开始关注目标检测中识别模型轻量化方法。孙俊等^[11]建立了以深度可分离卷积以及残差块为基础的多通道深度可分离卷积模型,对甜菜与杂草进行快速准确识别。识别平均准确率为87.58%,速度可达42.064 f/s。WANG等^[12]对YOLO v4进行轻量化,设计了YOLO v4-tiny模型,在GPU上进行测试,速度比YOLO v4模型提高了80%以上。孟庆宽等^[13]针对玉米田杂草检测精度低、实时性和鲁棒性差的问题,利用轻量卷积网络结合特征层融合机制构建SSD杂草识别模型,mAP为88.27%,模型检测速度为32.26 f/s。王卓等^[14]针对苹果采摘机器人果实识别算法参数量大、计算复杂度高的问题,使用MobileNet v3作为主干网络,轻量化YOLO v4杂草识别模型,mAP为92.23%,在嵌入式平台检测速度为15.11 f/s。徐艳蕾等^[15]针对田间自然环境下杂草识别精度低和检测速度慢的问题,在Xception卷积网络的基础上构

建了一种基于轻量卷积网络的杂草识别模型,mAP为98.63%,改进模型内存占用量为83.5 MB。亢洁等^[16]提出了基于SENet注意力机制与动态稀疏约束的识别模型的压缩方法,并在经典多分类数据集CIFAR-10上对VGG16模型进行验证,参数量减少43.97%,平均精度只降低0.91个百分点。目前杂草识别模型轻量化工作还有提升空间,识别精度与识别速度的平衡问题有待进一步研究。

本文针对农田环境下杂草识别模型参数多、体积大、检测速度慢的问题,以玉米幼苗和多种小目标杂草为研究对象,设计基于YOLO v5s的高效轻量化杂草识别模型。使用轻量级网络PP-LCNet作为杂草和玉米幼苗等目标的特征提取网络,并引入Ghost卷积轻量化特征融合网络,以减少识别模型参数量和计算量,实现轻量化目标。为降低轻量化对识别模型精度的影响,在特征融合网络的末端加入基于标准化的注意力模块提高对杂草和玉米幼苗特征的获取。用SiLU激活函数替换主干网络注意力机制激活函数,提高模型非线性拟合能力。为田间复杂环境下的杂草快速检测提供理论和技术支持。

1 图像获取及预处理

1.1 图像获取

为获取田间玉米幼苗和杂草图像数据,设计了玉米田地幼苗和杂草的图像数据采集模块。将调试正常的数据采集模块搭载到现有履带式车型机器人上进行田间数据采集。采用STM32单片机作为采集模块的中心处理设备,驱动摄像头模块拍摄玉米幼苗和杂草图像,并通过EC20-4G传输模块自动上传图像至自建服务器进行存储。同时采集模块还可以通过温湿度传感器和光照传感器采集田间作物生长环境的数据,同步发送至服务器。数据采集及传输的网络拓扑结构如图1所示。

图像采集于陕西省西安市临潼区行者乡玉米试验田,分别在玉米幼苗2~5叶期及其伴生杂草间进行数据采集,选择晴天、阴天、多云等不同的天气情况进行拍摄。图像最大分辨率为1920像素×1080像素,共采集有效图像2560幅。图像中包含多种情况,如:玉米幼苗和杂草相互遮挡,光照下有

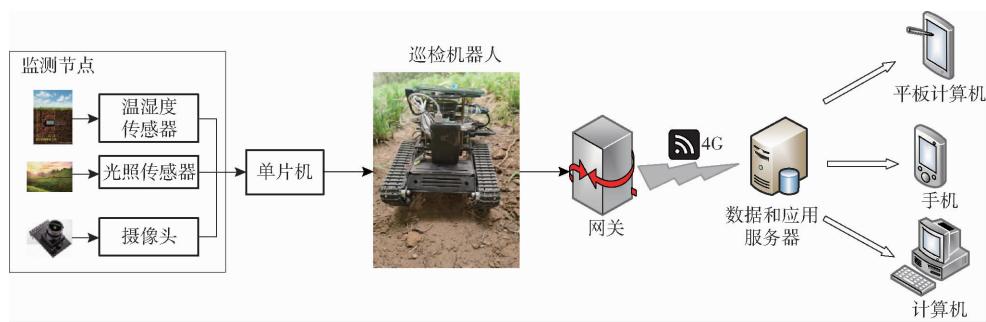


图 1 数据采集子系统拓扑结构

Fig. 1 Topology structure of data collection system

阴影遮挡,田间复杂环境中存在其它杂物。部分样本图像如图 2 所示。图中黄色框表示玉米幼苗,红色框表示杂草,蓝色框表示杂物。

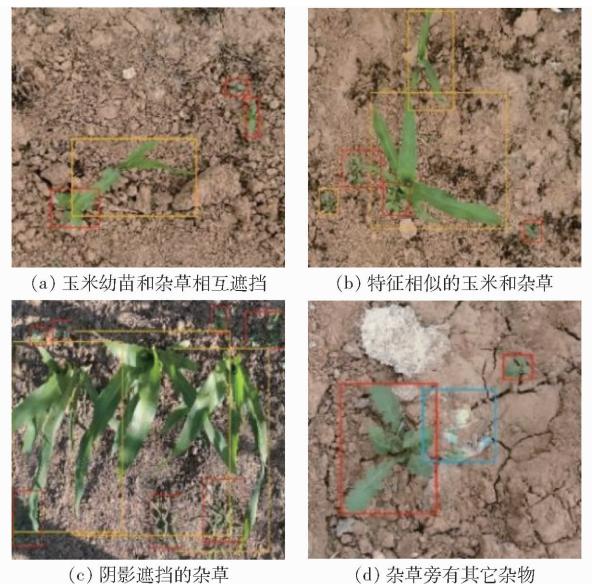


图 2 采集到的样本图像

Fig. 2 Collected sample images

1.2 图像特征增强

在拍摄的 2 560 幅图像中,阴影遮挡的图像有 425 幅,亮度大的图像有 262 幅,边缘细节模糊的图像有 348 幅。为了提高识别精度,采用带色彩恢复的多尺度视网膜 (Multi-scale retinex with color restoration, MSRCR) 增强算法^[17]对这些图像进行了特征增强处理,部分特征增强图像如图 3 所示。为了防止训练过程中模型过拟合,也为了显著增加数据样本集的数量和多样性,对采集到的图像数据以旋转、裁剪、调整图像亮度、增加噪声等方式进行图像增强操作。最终得到 4 000 幅图像,对这些图像数据进行随机划分,80% 为训练集,20% 为测试集。其中经过特征增强的数据也按照比例 8:2 分为训练集和测试集。

1.3 数据集标注

对创建好的数据集采用 LabelImg 标注软件以 YOLO 格式进行人工标注,并将标注好的信息保存



图 3 图像特征增强结果

Fig. 3 Results of image feature enhancement

在 TXT 标签文件中。标注类别为玉米和杂草两类,分别标注为 corn 和 grass。

2 基于 YOLO v5s 的轻量化杂草识别方法

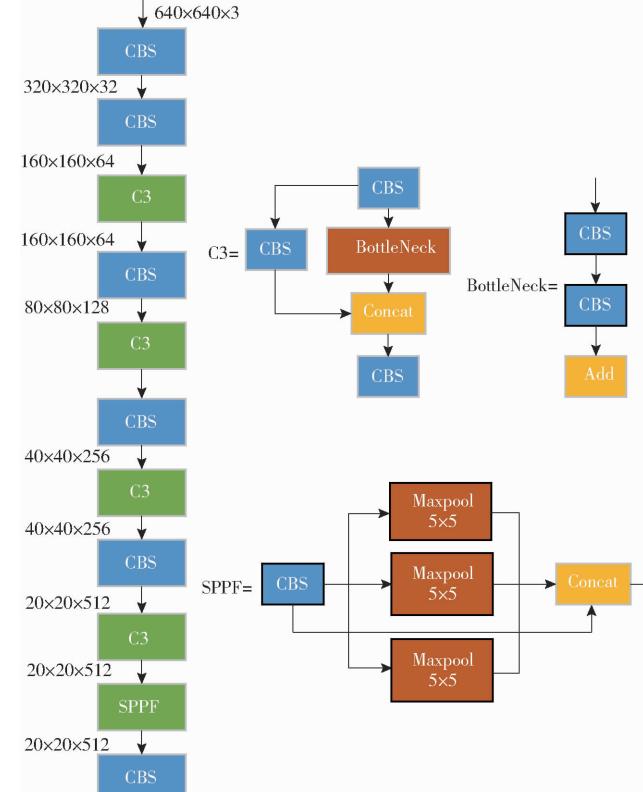
2.1 YOLO v5s 模型

YOLO v5s 网络由输入端 (Input)、主干网络 (Backbone)、特征融合网络 (Neck)、目标检测头 (Head)4 部分组成^[18]。输入端使用自适应锚框计算和 Mosaic 数据增强等策略对图像数据进行处理。主干网络^[19]主要由 CBS 模块、C3 模块、SPPF 模块组成。CBS 结构包含普通卷积、批量归一化 (Batch normalization, BN)、SiLU 激活函数。C3 模块由 CBS 模块、瓶颈模块 BottleNeck 和通道融合模块 Concat 组成。Neck 层^[20]由路径聚合网络 (Path aggregation network, PANet) 组成,采用自底向上的下采样和自顶向下的上采样对主干网络特征图进行特征融合,使网络充分学习目标的特征信息。在 Head 层对 Neck 层输出的 3 个不同大小的特征图进行位置和类别的回归,使用 CIoU 损失函数进行位置回归,使用二元交叉熵损失函数进行类别回归。

2.2 特征提取网络轻量化

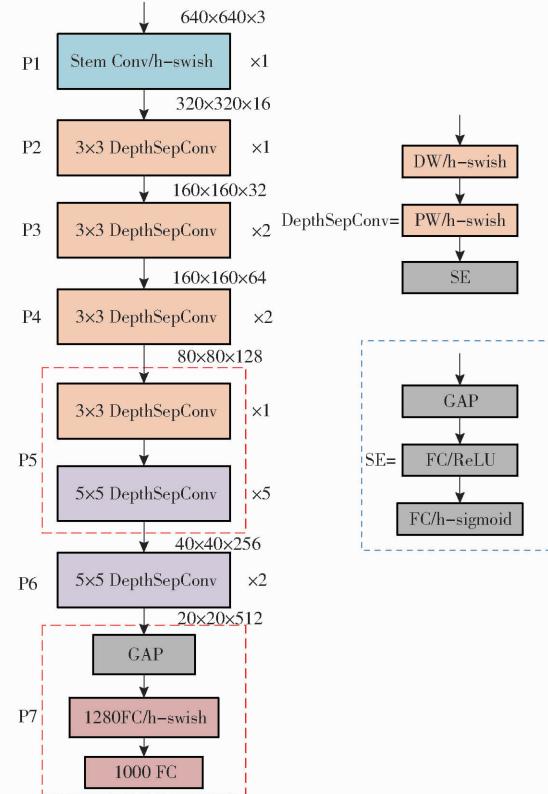
YOLO v5s 特征提取网络采用 CSPdarknet53 网络结构,如图 4a 所示。网络参数量达到 7 025 023。本文采用轻量级网络 PP-LCNet^[21]对 YOLO v5s 杂草识

别模型的特征提取网络进行重构。PP-LCNet 使用 MobileNet v1 提供的深度可分离卷积模块 DepthSepConv 替代了普通卷积计算, 极大降低了网络模型的参数量和运算量, 使杂草识别模型参数量降至 3 074 271。如图 4b 所示, 在 PP-LCNet 的结构中, P1 模块表示普通卷积, P2~P6 模块表示深度可



(a) CSPdarknet53网络结构

分离卷积模块。深度可分离卷积模块 DepthSepConv 由 2 个卷积层组成。蓝色虚线框中的挤压和激励 (Squeeze and excitation, SE) 模块被嵌入在 P6 最后两层深度可分离卷积模块之后。PP-LCNet 网络的 P7 模块包含全局平均池化层和 2 个全连接层, 主要用于图像分类。



(b) PP-LCNet网络结构

图 4 CSPdarknet53 与 PP-LCNet 网络结构对比

Fig. 4 Comparison structures of CSPdarknet53 and PP-LCNet network

在 PP-LCNet 网络结构中,首先执行 P1 的普通卷积,然后执行 P2~P4 的卷积核大小为 3×3 和 P5、P6 的卷积核大小为 5×5 的深度卷积操作,最后在 GAP 后进行 1×1 点卷积操作。且深度可分离卷积模块没有旁支,这极大地提高了网络计算效率,有利于加快模型检测速度。深度可分离卷积与标准卷积的参数量比值为

$$\frac{K^2 M + MN}{MK^2 N} = \frac{1}{N} + \frac{1}{K^2} \quad (1)$$

式中 K —卷积核尺寸

M —输入通道数

N —输出通道数

因此,深度可分离卷积的参数量是标准卷积的 $\frac{1}{N} + \frac{1}{K^2}$ 倍,在 PP-LCNet 网络中使用深度可分离卷积进行特征提取极大减少了网络参数量。

2.3 Neck 层轻量化

为了保证对输入图像中的杂草和玉米幼苗有更

全面的学习,由大量卷积结构组成的深度卷积神经网络在完成深层特征提取时,进行了大量浮点运算,增加了模型计算量^[22~23]。

为清晰地说明这个问题,用向量 $\mathbf{X} \in \mathbf{R}^{c \times h \times w}$ 表示深度卷积神经网络中的输入, c 表示输入通道数, h 和 w 分别表示输入数据宽度和高度。产生 n 个输出特征图卷积层运算为

$$\mathbf{O} = \mathbf{X} * \text{conf} + b \quad (2)$$

其中

$$\text{conf} \in \mathbf{R}^{c \times K \times K \times n}$$

$$\mathbf{O} \in \mathbf{R}^{h' \times w' \times n}$$

式中 \mathbf{O} — n 个通道的输出特征图, 特征图的尺寸为 $h' \times w'$

conf —卷积层中卷积滤波器

b —偏置项

$*$ —卷积操作运算符

由式(2)可知,对于同一个输入图像在卷积层经过不同通道的大量卷积核的卷积计算后,会产生

包含冗余信息的输出特征图^[22-23]。这些冗余信息的产生增加了模型计算量。为了进一步轻量化杂草识别模型,保持识别精度不降低并减少计算成本和参数量,本文在前述改进模型的基础上引入 Ghost 模块^[23]。

Ghost 模块使用一些特殊的线性变换来生成部分输出特征,相对于传统的卷积操作计算复杂度低,同时保留了传统卷积后目标对象的特征信息^[24-25]。为了得到相同数量的输出特征图,Ghost 模块首先采用传统的卷积核,对输入的特征图利用 3×3 标准卷积操作生成包含主要特性的固有特征图。然后对这些固有特征图分别进行简单特殊的 3×3 或 5×5 的卷积线性计算。在每一个通道进行线性操作的计算量远小于传统的卷积操作。 y_{ij} 计算式为

$$y_{ij} = \Phi_{i,j}(y'_i) \quad (i=1,2,\dots,m; j=1,2,\dots,s) \quad (3)$$

式中 y'_i ——部分特征图

y_{ij} ——第 i 个特征图的第 j 个线性映射特征图

$\Phi_{i,j}$ ——对固有特征进行线性映射的函数

本文使用华为诺亚方舟实验室开发的包含 Ghost 卷积的 GhostBottleneck 模块替换杂草识别模块中 Neck 层 C3 模块的 BottleNeck 模块,减少参数量提高训练速度。图 5 展示了由 2 个堆叠的 Ghost 模块组成 GhostBottleneck 的具体结构。第 1 个 Ghost 模块的主要功能是增加通道数量来增加特征维度,第 2 个 Ghost 模块减少通道数量,以便与短路连接(shortcut)匹配,短路连接可以使 2 个模块的输入和输出进行通道相加操作。第 2 个 Ghost 模块在处理完特征信息后不需要进行 ReLU 操作,只需要使用批归一化操作。

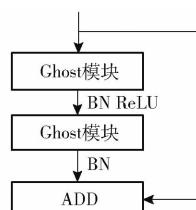


图 5 Neck 层 C3 模块 GhostBottleneck 结构图

Fig. 5 Illustration of GhostBottleneck structure
on Neck layer C3 module

2.4 轻量化杂草识别模型优化

2.4.1 注意力机制对特征融合网络的优化

对 YOLO v5s 的特征提取网络进行轻量化重构后,在大幅减少了参数量和计算量的同时,也容易忽略识别目标的一些特征,导致识别精度降低。而且玉米幼苗周围杂草种类较多且目标较小,玉米幼苗和周围一些杂草有一定的相似性,也影响模型的学习。为了提升模型识别精度,将标准化注意力模块(Normalization-based attention module, NAM)^[26]引入

到杂草识别模型的 Neck 层末端 C3 模块之后,以便更好地提取杂草、玉米幼苗的局部细节特征。

NAM 是一种高效且轻量级的注意力机制,采用批归一化的缩放因子来表示权重的重要性,利用权重的贡献因子来改善注意力机制的性能,不使用全连接层和卷积层,简化计算和减少参数量。NAM 模块分为通道注意力模块(Channel attention module, CAM)和空间注意力模块(Spatial attention module, SAM)两部分,分别在特征图的通道维度与空间维度实现注意力机制。NAM 注意力机制结构如图 6 所示。

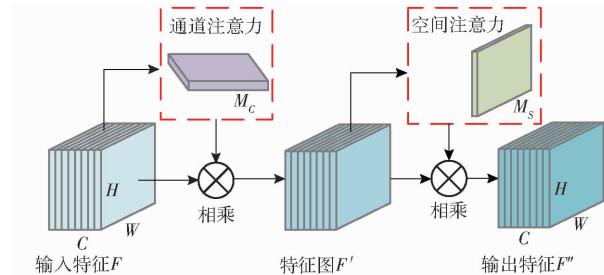


图 6 NAM 注意力机制结构

Fig. 6 NAM attention mechanism structure

C3 模块输出的特征图进入通道注意力子模块。NAM 中的通道注意力子模块如图 7 所示, γ_i 表示每个通道比例因子, ω_i 表示权重。

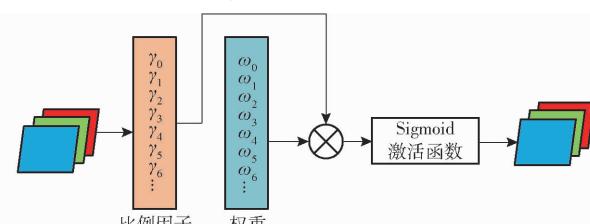


图 7 NAM 通道注意力子模块

Fig. 7 NAM channel attention submodule

在通道注意力子模块中利用批归一化中的缩放因子 α 来测量通道方差^[27],方差越大说明此通道含有的信息越丰富,可以提供的特征信息越多,占有的权重因子也就越大。批归一化比例因子 B_{out} 计算公式为

$$B_{out} = BN(B_{in}) = \alpha \frac{B_{in} - \mu_b}{\sqrt{\sigma_b^2 + \epsilon}} + \beta \quad (4)$$

其中 $B_{out} = [\gamma_0 \ \gamma_1 \ \dots \ \gamma_i \ \dots \ \gamma_n]$

式中 B_{in} ——输入的特征矩阵

α ——批归一化比例因子函数

β ——模型在训练过程中学习到的位移变换参数

μ_b ——最小批量 b 均值

σ_b ——最小批量 b 标准差

ϵ ——较小的常数,防止分母为 0

权重 W_γ 计算公式为

$$W_\gamma = \frac{\gamma_i}{\sum_{i=0}^n \gamma_i} \quad (5)$$

式中 n —通道数

通道注意力子模块的输出 M_c 计算公式为

$$M_c = \sigma(W_\gamma(BN(\mathbf{B}_{in}))) \quad (6)$$

式中 σ —激活函数

将经过通道注意力机制得到的批归一化比例因子调整的权重信息的特征图再与输入的特征图相乘, 提高识别目标的特征权重。输出的特征图再经过空间注意力子模块的计算, 空间注意力子模块的结构和通道注意力机制相同, 只是将批归一化比例因子变换为批归一化的空间比例因子和对应的权重值。特征矩阵经过批归一化的空间比例因子和对应权重的计算, 进一步抑制不重要的背景特征。C3 模块输出的特征融合后的特征矩阵, 经过 NAM 注意力机制对识别目标特征进行自适应的权重调整, 有效提升了 Head 层对目标的识别精度。

2.4.2 主干网络注意力机制激活函数优化

深度神经网络中非线性激活函数具有较强的拟合能力, 使深度神经网络的学习能力更强。PP-LCNet 的最后 2 层 5×5 卷积中嵌入 SE 注意力机制, 如图 4b 所示。在 SE 的全连接层中采用 Hard-Sigmoid 激活函数, 其梯度呈现硬饱和, 不利于神经网络在训练过程中进行梯度优化。Hard-Sigmoid 函数表达式为

$$f(x) = \begin{cases} 0 & (x < -2.5) \\ 0.2x + 0.5 & (-2.5 \leq x \leq 2.5) \\ 1 & (x > 2.5) \end{cases} \quad (7)$$

式中 x —输入变量

SiLU 函数没有上下限, 平滑且非单调, 具有较好的非线性能力和自稳定性, 可以提高深层神经网络的表征能力。在定义域内可导且连续, 更利于梯度优化。SiLU 函数表达式为

$$f(x) = x\sigma(x) = \frac{x}{1 + e^{-x}} \quad (8)$$

SiLU 函数和 Hard-Sigmoid 函数图如图 8a 所示, 它们的一阶导数如图 8b 所示。从图 8a 中可以看出, Hard-Sigmoid 函数在输入小于 -2.5 时, 输出为 0, 导致某些神经元无法被激活, 一些参数无法更新。SiLU 函数在大于 0 时都为正值, 小于 0 时为负值, 函数接近 0 时具有更平滑的曲线, 具有较好的连续性和可导性。从图 8b 中可以看出, 在输入值小于 -2.5 或大于 2.5 时, Hard-Sigmoid 函数梯度为 0, 导致模型在训练过程中会出现梯度消失的现象。SiLU 函数在输入为负时, 有一个较小的梯度, 保证了导数存

在且导数有正负之分, 防止了梯度消失情况的出现。因此将 SE 注意力机制中的 Hard-Sigmoid 函数替换为 SiLU 激活函数, 提高了识别模型非线性的学习能力。

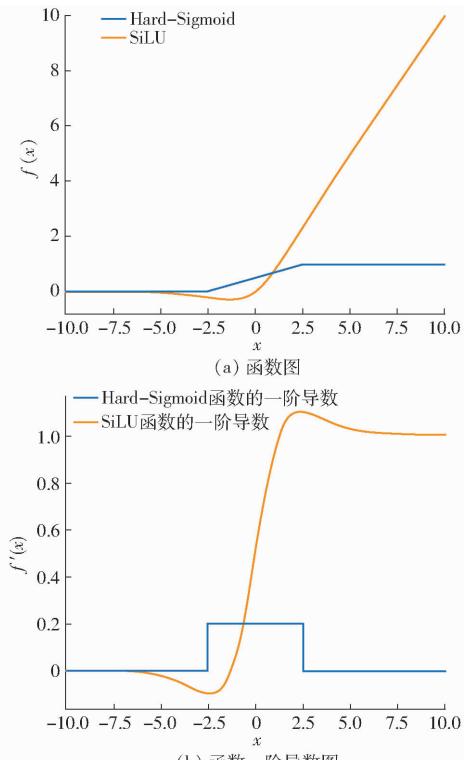


图 8 Hard-Sigmoid 和 SiLU 函数及一阶导数图

Fig. 8 Hard-Sigmoid and SiLU functions and first-order derivative graphs

3 模型训练

3.1 实验环境及参数设置

实验环境为 Windows 10 操作系统, CPU 为 Intel core i7-8700, 主频为 3.60 GHz, 杂草识别模型的搭建使用 Python 3.8 开发环境, 深度学习框架选用 Pytorch。GPU 使用 NVIDIA GeForce RTX 2080Ti 进行运算加速, GPU 运行内存为 11 GB, 使用 CUDA 版本为 10.2。所有实验中, 模型训练使用 GPU 环境, 测试使用 CPU 环境。在模型训练过程中使用随机梯度下降 (Stochastic gradient descent, SGD) 方法对训练过程进行优化。其超参数设置如表 1 所示。

表 1 改进杂草识别模型训练超参数

Tab. 1 Hyperparameter of training improved weed identification model

参数	数值
批量大小	16
动量因子	0.98
权重衰减	0.001
初始学习率	0.01
迭代次数	300

为验证改进杂草识别模型性能优于 YOLO v5s 识别模型,在自建数据集的训练集上分析边界框损失函数和分类损失函数在模型训练过程中的收敛趋势。两种杂草识别模型均经过 300 次迭代,边界框损失函数变化曲线如图 9 所示,分类损失函数变化曲线如图 10 所示。从图 9 中可以看出,两个模型在迭代到 50 次都具有较好的收敛性,边界框损失函数值分别达到 0.022 和 0.024。从图 10 可以看出,在迭代到 50 次时,分类损失函数值分别达到 0.0025 和 0.005。从图 9 和图 10 可知,在相同迭代次数下改进后的识别方法损失函数值低于原始模型,表明具有更快的收敛速度和更优的识别精度。

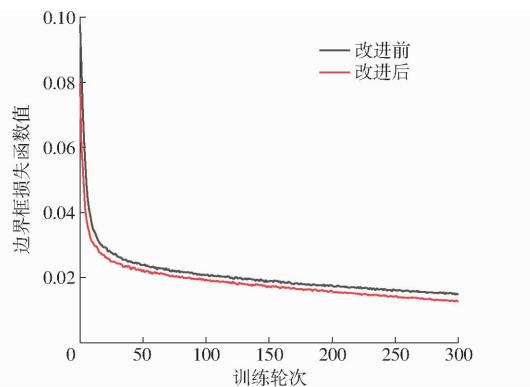


图 9 模型训练过程中边界框损失函数变化曲线

Fig. 9 Box loss function curves during model training

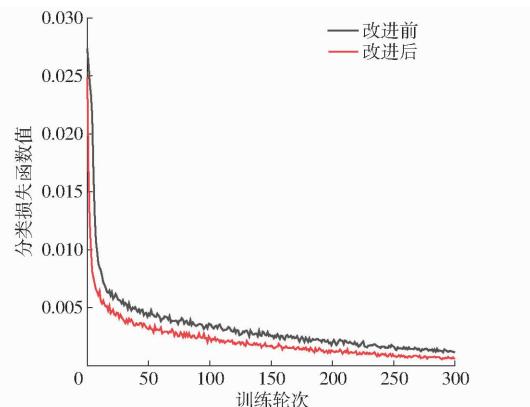


图 10 模型训练过程中分类损失函数变化曲线

Fig. 10 Classification loss function curves during model training

3.2 评价指标

采用精确率(Precision, P)、召回率(Recall, R)、平均精度(Average precision, AP)、平均精度均值(Mean average precision, mAP)、模型内存占用量和单幅图像检测时间评价模型效果。

mAP@0.5 表示当真实框与预测框重叠度(Intersection over union, IOU)为 0.5 时,模型平均精度均值。

3.3 实验结果分析

3.3.1 MSRCR 算法有效性实验

为了验证经过 MSRCR 算法预处理图像后对杂草识别基础网络 YOLO v5s 的有效性,在测试集中选取了双株杂草、与玉米幼苗高度相似的杂草以及杂草和玉米幼苗伴生且杂草较小的图像进行识别。图 11 展示了 2 组图像数据由 YOLO v5s 识别的结果,其中图 11a 是原始图像经 YOLO v5s 识别的结果,图 11b 是 MSRCR 算法预处理后的图像经 YOLO v5s 识别的结果。从识别结果可以看出,图 11a 中 YOLO v5s 杂草识别模型对原始图像的识别存在漏检情况,预测框的置信度不高,最高为 0.79,最低为 0.64。图 11b 消除了漏检情况,识别模型对玉米幼苗和杂草目标预测框置信度较高,最高为 0.97,最低为 0.64。实验结果表明,使用 MSRCR 算法预处理图像可以提高杂草识别模型的识别性能。

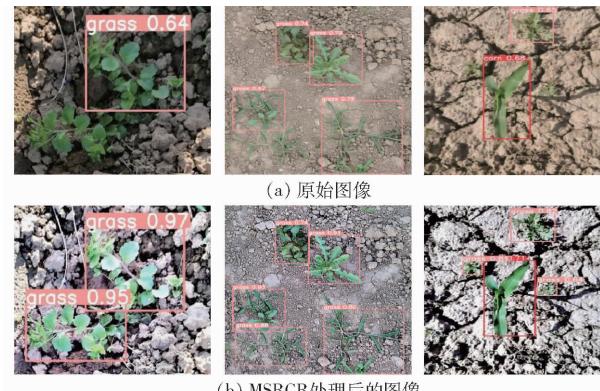


图 11 图像预处理后 YOLO v5s 杂草识别模型检测

效果对比

Fig. 11 Comparison of detection effects of weed identification model based on YOLO v5s after image preprocessing

3.3.2 轻量化杂草识别模型实验结果

为了验证基于 YOLO v5s 的轻量化杂草识别模型的有效性,通过消融实验分析了轻量化方法对杂草识别模型识别性能的影响。表 2 展示了不同轻量化改进方法对杂草识别性能的影响。采用 PP-LCNet 和 CSPdarknet53 作为主干特征提取网络,虽然 PP-LCNet 作为特征提取网络时模型的 mAP@0.5 下降 1 个百分点,但模型内存占用量减小 41.2%,且模型检测速度大大提高,每帧图像检测时间为 121 ms。这主要归结于 PP-LCNet 网络中使用 5×5 的卷积核,增大了网络感受野,同时在最后 2 个卷积层后分别嵌入 SE 注意力机制,增加了对杂草和玉米幼苗目标的关注,使模型性能没有大幅度下降。

表2 轻量化杂草识别模型的消融实验

Tab. 2 Ablation experiment of lightweight weed recognition model

基线网络	NAM	PP-LCNet	Ghost	SiLU 激活函数	AP/%		mAP@0.5/%	内存占用量/MB	单幅图像检测时间/ms
					玉米	杂草			
YOLO v5s					98.5	94.4	96.5	13.70	156.4
	√				98.7	95.8	97.2	13.70	163.7
	√	√			98.2	94.2	96.2	8.05	121.0
	√	√	√		99.1	94.1	96.6	6.23	120.2
	√	√		√	98.5	95.6	97.0	8.05	100.6
	√	√	√	√	99.1	96.6	97.8	6.23	118.1

注:√表示基线网络采用此模块。

当采用 Ghost 模块替换 YOLO v5s 中 Neck 层的 C3 模块的 Bottleneck 模块时,模型参数量进一步下降,降至 6.23 MB,如表 2 所示。根据 2.3 节 Ghost 模块的轻量化原理,为了更直观地展示 Ghost 模块对中间特征图冗余信息的减少作用,分别对经过 C3 模块输出的特征图和对采用 Ghost 卷积后的特征图进行可视化展示,如图 12 所示。图 12a 为 Neck 层中 C3 模块的特征图输出,图 12b 为采用 Ghost 卷积后的特征图的输出。采用图像感知哈希算法^[28]分别对图 12a 和图 12b 中的每一幅特征图生成 64 位哈希值,比较两幅特征图哈希值不同的位数,哈希值不同的位数越少,则说明这两幅图像越相似,包含更多的冗余信息。通过计算可知图 12a 中 3 个红色框中的特征图相似度高,包含更多的冗余信息。图 12b 中使用 Ghost 卷积得到的特征图对应位置的红色框中的特征图相似度较低,包含更少的冗余信息。图 12b 红色框中所展示的特征图的有效信息更加丰富,同时减少了模型计算量。

但同时也注意到,当对 YOLO v5s 网络进行轻量化改进后,识别精度有所下降。分析原因是特征图的冗余信息减少后,对一些较小或被遮挡的杂草特征提取不全面,容易产生误判。因此,引入了 NAM 注意力机制并对特征提取网络中的 SE 注意力机制中的激活函数使用 SiLU 激活函数优化后,提高了模型对目标的特征提取能力和非线性的拟合能力。为了验证优化激活函数后识别模型的性能,图 13 展示了在测试集上未优化与优化激活函数后的识别模型的检测效果,从图中可以看出,优化激活函数后模型对杂草和玉米目标的识别框置信度均有提高,杂草识别框的置信度平均提高 0.068,对于玉米识别框置信度提高 0.11,且没有漏检的情况。表 2 中展示了采用改进方法后的轻量化杂草识别模型性能。从结果可看出,当在 YOLO v5s 中融入 NAM、PP-LCNet 和 SiLU 激活函数后,mAP@0.5 达到 97.0%,杂草的识别精度是 95.6%,模型内存占用量减小到 8.05 MB。当采用 SiLU 激活函数后,对杂草的识别精度和模型 mAP@0.5 分别提高 1.4 个百分点和 0.8 个百分点。单幅图像检测时间由 121.0 ms 降低为 100.6 ms,因为原有的 Hard-Sigmoid 激活函数进行线性计算之前需要进行 3 次条件判断,比 SiLU 激活函数费时。当神经元数目少时,二者的累积运行时间差异不大,但随着神经元数目增加,累积运行时间的差异就显现出来了。最终,优化后的轻量化杂草识别模型的 mAP@0.5 达到 97.8%,相较于 YOLO v5s 提高 1.3 个百分点,模型内存占用量由 13.7 MB 减小到 6.23 MB,缩小 54.5%,模型对单幅图像的检测时间缩小到 118.1 ms。由以上分析可知,本文所提出的基于 YOLO v5s 轻量化杂草识别模型性能更优,满足资源有限的杂草检测设备对识别精度和检测速度的要求。

3.3.3 NAM 注意力机制对模型性能的影响

为了进一步说明 NAM 注意力机制对轻量化杂草识别模型识别性能的影响,使用梯度加权类激活

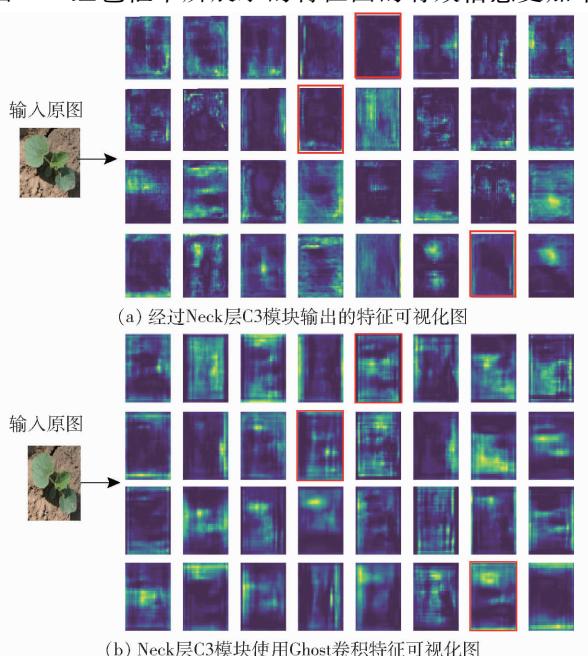


图 12 Neck 层 C3 模块输出特征图可视化对比

Fig. 12 Visualization comparison of output feature maps of Neck layer C3 module

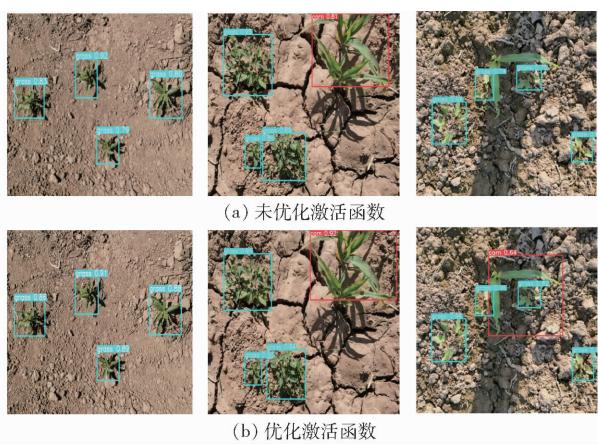


图 13 优化激活函数检测效果对比

Fig. 13 Comparison of detection effect of optimized activation function

映射(Gradient-weighted class activation mapping, Grad CAM)方法来观察在YOLO v5s模型Neck层的末端引入卷积块注意模块(Convolutional block attention module, CBAM)、有效通道注意力(Efficient channel attention, ECA)模块和NAM注意力机制后,模型对目标特征关注度的变化。可以根据某一区域亮度的深浅变化直观地了解模型对这一区域的关注程度,实验结果如图14所示。从图中可以看出,未添加注意力机制时,识别模型没有关注到图像左下角的玉米幼苗目标。添加注意力机制后都可以关注到玉米幼苗目标,NAM注意力机制可以使模型更显著地关注识别目标的特征,有效抑制了模型对背景区域等显著性弱的特征的关注,降低了对识别目标的关键信息的丢失。

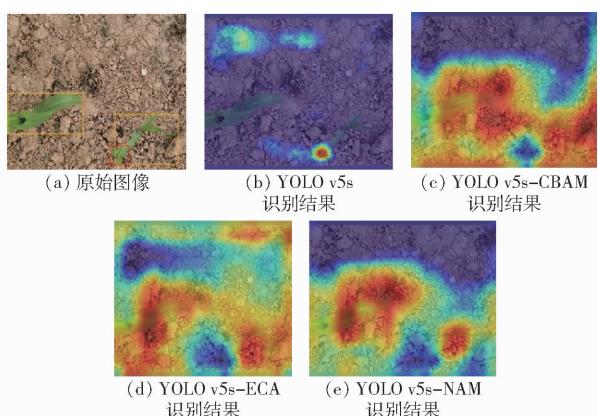


图 14 不同注意力机制下目标热力图可视化分析

Fig. 14 Visualization analysis of target thermogram with different attention mechanisms

3.3.4 轻量化模型对比实验

为了验证轻量化杂草识别模型在识别性能方面的优势,与近年来性能优秀的成熟轻量级目标识别模型以及优秀文献方法进行对比实验。为了描述方便将本文建立的轻量化杂草识别模型取名为NEP-

YOLO v5s,文献[29]中使用轻量级网络MobileNet v2替换SSD模型原有的主干网络VGG16完成轻量化改造,将其命名为MBV2-SSD。文献[30]中使用轻量级网络MobileNet v3-Small替换YOLO v4模型原有的主干网络CSPdarknet53,将其命名为MBV3-YOLO v4。图15展示了测试集中部分图像的识别比较结果,表3展示了对比方法杂草识别性能评价结果。

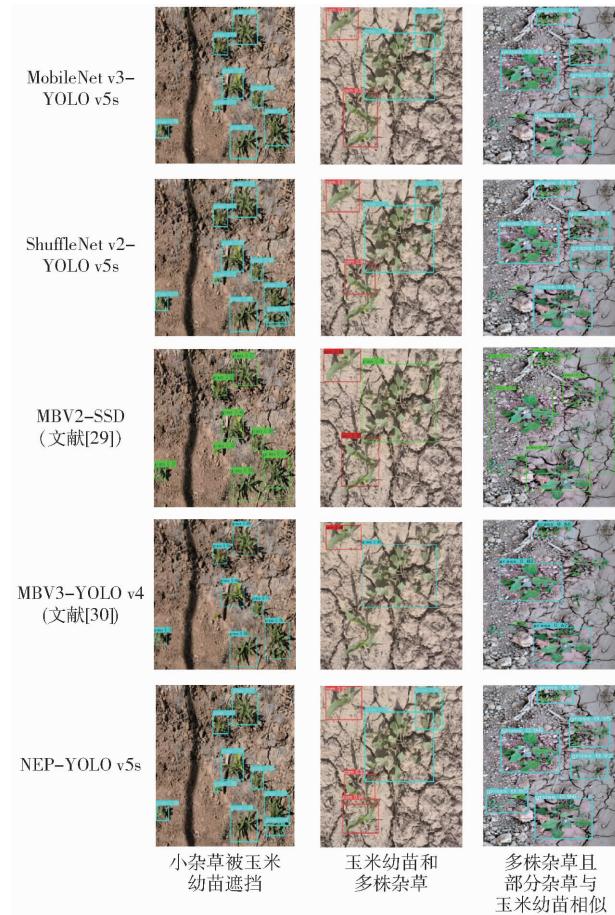


图 15 轻量化杂草识别模型及对比方法的识别结果

Fig. 15 Comparison of detection results of proposed identification models and multiple algorithms

从图15可以看出,这些轻量化目标检测方法对于第2幅图像中左上角的单株玉米幼苗都有较好的识别结果。但这些轻量化杂草识别方法和文献[29-30]方法对杂草和玉米幼苗伴生及相似的多株杂草识别都分别存在漏检的情况。本文所提出的NEP-YOLO v5s模型不受玉米与杂草互相遮挡、杂草目标较小、杂草与玉米幼苗相似等因素影响,可以检测出所有杂草和玉米幼苗目标且置信度高,预测框的位置准确。

从表3可以看出,在本文自建数据集,虽然MobileNet v3-YOLO v5s的检测速度最快,但是其mAP@0.5较低,比本文方法低5.1个百分点,识别精确率也只达到92.5%。文献[29-30]的方法

表3 不同轻量化杂草识别模型识别性能对比

Tab. 3 Performance comparison of different detection algorithms

模型	精确率/%	召回率/%	AP/%		mAP@ 0.5/%	内存占用量/MB	单幅图像检测时间/ms
			玉米	杂草			
MobileNet v3 - YOLO v5s	92.5	93.2	92.6	92.7	92.7	7.08	105.3
ShuffleNet v2 - YOLO v5s	92.2	93.5	94.4	92.5	93.4	7.60	142.0
MBV2 - SSD(文献[29])	91.9	84.7	85.3	93.4	89.3	14.80	361.1
MBV3 - YOLO v4(文献[30])	92.1	72.0	83.0	88.0	85.5	156.00	162.3
本文方法	97.3	93.9	99.1	96.6	97.8	6.23	118.1

表现一般,模型 mAP@ 0.5 分别为 89.3%、85.5%,且模型内存占用量较大,检测速度慢。本文方法的内存占用量为 6.23 MB,相较于成熟的轻量化目标检测算法 MobileNet v3 - YOLO v5s 和 ShuffleNet v2 - YOLO v5s,分别减少 12% 和 18%,同时也是对比方法中最小的。且对玉米幼苗和杂草识别平均精度分别达到 99.1% 和 96.6%,高于其它轻量化杂草识别模型。单幅图像识别时间为 118.1 ms,可以满足实时检测的要求。

综上分析,轻量化的 NEP - YOLO v5s 杂草识别模型在保证玉米幼苗和杂草识别精度的同时,满足了杂草识别模型的轻量化要求,可以将训练好的模型部署于计算和存储资源有限的玉米农田杂草快速识别设备上。

4 结论

(1) 使用 PP - LCNet 轻量化网络重构了原有的特征提取网络 CSPdarknet53,大幅削减了模型参数量和计算量。为了进一步减少计算量和提高识别速度,将 YOLO v5s 网络中特征融合 Neck 层中的 C3 模块中的 Bottleneck 模块用 Ghost 模块替换,降低了普通卷积计算的复杂度,节省了计算资源并加快了识别速度。轻量化后的杂草识别模型内存占用量为 6.23 MB,相比

YOLO v5s 减少 54.5%。与成熟的轻量化目标检测算法 MobileNet v3 - YOLO v5s 和 ShuffleNet v2 - YOLO v5s 相比,分别减少 12% 和 18%,实现了轻量化设计。

(2) 为了消除轻量化后对杂草识别模型识别精度的影响,对有噪声的样本图像使用 MSRCR 算法对目标特征进行增强。将 NAM 注意力机制嵌入到特征网络 Neck 层末端,使模型在学习时更加关注玉米幼苗和杂草特征。在 PP - LCNet 网络的 SE 注意力机制中,采用 SiLU 激活函数替换了原有的 Hard - Sigmoid 激活函数,提高了识别模型非线性拟合能力。优化后的轻量化杂草识别模型识别精确率提升到 97.3%,mAP@ 0.5 为 97.8%,比 YOLO v5s 提高 1.3 个百分点,提升了识别精度。

(3) 为了验证本文轻量化杂草识别模型的有效性,在自建数据集上与其它优秀的轻量化模型和表现良好的文献方法进行对比实验。实验结果表明,本文建立的轻量化杂草识别模型的 mAP@ 0.5 比 MobileNet v3 - YOLO v5s 高 5.1 个百分点,比 ShuffleNet v2 - YOLO v5s 高 4.4 个百分点,比文献[29-30]分别提高 8.5 个百分点和 12.3 个百分点。单幅图像检测时间缩短到 118.1 ms。与其他目标检测方法相比,识别模型最小,识别性能优,达到了轻量化识别要求。

参 考 文 献

- [1] WANG A C, ZHANG W, WEI X H. A review on weed detection using ground-based machine vision and image processing techniques[J]. Computers and Electronics in Agriculture, 2019, 158: 226 - 240.
- [2] 刘莫尘,高甜甜,马宗旭,等.基于 MSRCR - YOLOv4 - tiny 的田间玉米杂草检测模型[J].农业机械学报,2022,53(2): 246 - 255,335.
- [3] LIU Mochen, GAO Tiantian, MA Zongxu, et al. Target detection model of corn weeds in field environment based on MSRCR algorithm and YOLOv4 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246 - 255,335. (in Chinese)
- [4] 彭文,兰玉彬,岳学军,等.基于深度卷积神经网络的水稻田杂草识别研究[J].华南农业大学学报,2020,41(6):75 - 81.
- [5] PENG Wen, LAN Yubin, YUE Xuejun, et al. Research on paddy weed recognition based on deep convolutional neural network [J]. Journal of South China Agricultural University, 2020, 41(6):75 - 81. (in Chinese)
- [6] 袁洪波,赵努东,程曼.基于图像处理的田间杂草识别研究进展与展望[J].农业机械学报,2020,51(2):323 - 334.
- [7] YUAN Hongbo, ZHAO Nudong, CHENG Man. Review of weeds recognition based on image processing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2):323 - 334. (in Chinese)
- [8] LIU B, BRUCH R. Weed detection for selective spraying: a review[J]. Current Robotics Reports, 2020(1): 19 - 26.
- [9] WANG Z, GUO J, ZHANG S. Lightweight convolution neural network based on multi-scale parallel fusion for weed

- identification[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2022, 36(7): 2250028.
- [7] PETEINATOS G G, REICHEL P, KAROUTA J, et al. Weed identification in maize, sunflower, and potatoes with the aid of convolutional neural networks[J]. Remote Sensing, 2020, 12(24): 4185.
- [8] BAKHSHIPOUR A, JAFARI A. Evaluation of support vector machine and artificial neural networks in weed detection using shape features[J]. Computers & Electronics in Agriculture, 2018, 145: 153–160.
- [9] 邓向武,齐龙,马旭,等. 基于多特征融合和深度置信网络的稻田苗期杂草识别[J]. 农业工程学报,2018,34(14):165–172.
DENG Xiangwu, QI Long, MA Xu, et al. Recognition of weeds at seedling stage in paddy fields using multi-feature fusion and deep belief networks[J]. Transactions of the CSAE, 2018, 34(14):165–172. (in Chinese)
- [10] 孙艳霞,陈燕飞,金小俊,等. 基于人工智能的青菜幼苗与杂草识别方法[J]. 福建农业学报,2021,36(12):1484–1490.
SUN Yanxia, CHEN Yanfei, JIN Xiaojun, et al. AI differentiation of Bok choy seedlings from weeds[J]. Fujian Journal of Agricultural Sciences, 2021, 36(12):1484–1490. (in Chinese)
- [11] 孙俊,谭文军,武小红,等. 多通道深度可分离卷积模型实时识别复杂背景下甜菜与杂草[J]. 农业工程学报,2019,35(12):184–190.
SUN Jun, TAN Wenjun, WU Xiaohong, et al. Real-time recognition of sugar beet and weeds in complex backgrounds using multi-channel depth-wise separable convolution model [J]. Transactions of the CSAE, 2019, 35 (12): 184 – 190. (in Chinese)
- [12] WANG C Y, BOCHKOVSKIY A, LIAO H. Scaled – YOLOv4: scaling cross stage partial network [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021:13029 – 13038.
- [13] 孟庆宽,张漫,杨晓霞,等. 基于轻量卷积结合特征信息融合的玉米幼苗与杂草识别[J]. 农业机械学报,2020,51(12):238–245,303.
MENG Qingkuan, ZHANG Man, YANG Xiaoxia, et al. Recognition of maize seedling and weed based on light weight convolution and feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12):238 – 245, 303. (in Chinese)
- [14] 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)
- [15] 徐艳蕾,何润,翟钰婷,等. 基于轻量卷积网络的田间自然环境杂草识别方法[J]. 吉林大学学报(工学版),2021,51(6):2304–2312.
XU Yanlei, HE Run, ZHAI Yuting, et al. Weed identification method based on deep transfer learning in field natural environment[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(6):2304 – 2312. (in Chinese)
- [16] 亢洁,刘港,王勍. 基于动态剪枝神经网络的杂草检测算法研究[J]. 农业机械学报,2023,54(4):269–277.
KANG Jie, LIU Gang, WANG Qing, et al. Weed detection algorithm based on dynamic pruning neural network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4):269 – 277. (in Chinese)
- [17] 杨文静,陈明,冯国富. 基于图像增强的水下视频鱼类识别方法[J]. 激光与光电子学进展,2021,58(22):294–303.
YANG Wenjing, CHEN Ming, FENG Guofu. Fish recognition method for underwater video based on image enhancement[J]. Laser & Optoelectronics Progress, 2021, 58 (22):294 – 303. (in Chinese)
- [18] 罗志聪,李鹏博,宋飞宇,等. 嵌入式设备的轻量化百香果检测模型[J]. 农业机械学报,2022,53(11):262–269,322.
LUO Zhicong, LI Pengbo, SONG Feiyu, et al. Lightweight passion fruit detection model based on embedded device [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11):262 – 269,322. (in Chinese)
- [19] 马宁,曹云峰,王指挥,等. 基于 YOLO v5 网络架构的着陆跑道检测算法研究[J]. 激光与光电子学进展,2022,59(14):199–205.
MA Ning, CAO Yunfeng, WANG Zhihui, et al. Landing runway detection algorithm based on YOLO v5 network architecture [J]. Laser & Optoelectronics Progress, 2022, 59(14):199 – 205. (in Chinese)
- [20] 邱天衡,王玲,王鹏,等. 基于改进 YOLO v5 的目标检测算法研究[J]. 计算机工程与应用,2022,58(13):63–73.
QIU Tianheng, WANG Ling, WANG Peng, et al. Research on object detection algorithm based on improved YOLO v5 [J]. Computer Engineering and Applications, 2022, 58(13):63 – 73. (in Chinese)
- [21] CUI C, GAO T, WEI S, et al. PP – LCNet: a lightweight cpu convolutional neural network[J]. arXiv Preprint, arXiv:2109.15099, 2021.
- [22] ZHANG Q, JIANG Z, LU Q, et al. Split to be slim: an overlooked redundancy in vanilla convolution[C] // Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence (IJCAI'20), 2020:3195 – 3201.
- [23] 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: 1577 – 1586.
- [24] 李衍照,于镭,田金文. 基于改进 YOLO v5 的金属焊缝缺陷检测[J]. 电子测量技术,2022,45(19):70–75.
LI Yanzhao, YU Lei, TIAN Jinwen. Metal weld defect detection based on improved YOLO v5 [J]. Electronic Measurement Technology, 2022, 45 (19):70 – 75. (in Chinese)

- phosphorus to degradation in alpine meadows [J]. *Acta Agrestia Sinica*, 2023, 31(4): 1106–1114. (in Chinese)
- [42] 李培培, 汪强, 文倩, 等. 不同还田方式对砂质潮土理化性质及微生物的影响 [J]. *生态学报*, 2017, 37(11): 3665–3672.
- LI Peipei, WANG Qiang, WEN Qian, et al. Effects of the return of organic materials on soil physical and chemical properties and bacterial number in sandy soil [J]. *Acta Ecologica Sinica*, 2017, 37(11): 3665–3672. (in Chinese)
- [43] 王勇, 姬强, 刘帅, 等. 耕作措施对土壤水稳定性团聚体及有机碳分布的影响 [J]. *农业环境科学学报*, 2012, 31(7): 1365–1373.
- WANG Yong, JI Qiang, LIU Shuai, , et al. Effects of tillage practices on water-stable aggregation and aggregate-associated organic C in soils [J]. *Journal of Agro-Environment Science*, 2012, 31(7): 1365–1373. (in Chinese)
- [44] 周虎, 吕贻忠, 杨志臣, 等. 保护性耕作对华北平原土壤团聚体特征的影响 [J]. *中国农业科学*, 2007, 40(9): 1973–1979.
- ZHOU Hu, LÜ Yizhong, YANG Zhichen, et al. Effects of conservation tillage on soil aggregates in Huabei Plain, China [J]. *Scientia Agricultura Sinica*, 2007, 40(9): 1973–1979. (in Chinese)
- [45] 张赛, 王龙昌. 保护性耕作对土壤团聚体及其有机碳含量的影响 [J]. *水土保持学报*, 2013, 27(4): 263–267, 272.
- ZHANG Sai, WANG Longchang. The effect of conservation tillage on soil aggregates and their organic carbon content [J]. *Journal of Soil and Water Conservation*, 2013, 27(4): 263–267, 272. (in Chinese)
- [46] 房娜娜, 杨泽, 刘国栋, 等. 建三江地区土壤氮磷生态化学计量空间异质性特征及其影响因素分析 [J]. *物探与化探*, 2022, 46(5): 1121–1131.
- FANG Na'na, YANG Ze, LIU Guodong, et al. Spatial heterogeneity and influencing factors of the ecological stoichiometry of soil nitrogen and phosphorus in the Jiansanjiang area [J]. *Geophysical and Geochemical Exploration*, 2022, 46(5): 1121–1131. (in Chinese)
- [47] 杜思垚, 方娅婷, 鲁剑巍. 根系分泌物对作物养分吸收利用的影响研究进展 [J]. *华中农业大学学报*, 2023, 42(2): 147–157.
- DU Siyao, FANG Yating, LU Jianwei. Progress on effect of root exudates on nutrient uptake and utilization of crops [J]. *Journal of Huazhong Agricultural University*, 2023, 42(2): 147–157. (in Chinese)
- [48] CHEN J, SHAFI M, WANF Y, et al. Organic acid compounds in root exudation of Moso bamboo (*Phyllostachys pubescens*) and its bioactivity as affected by heavy metals [J]. *Environmental Science and Pollution Research*, 2016, 23(20): 20977–20984.
- [49] LIU Y, EVANS S E, FRIESEN M L, et al. Root exudates shifhow N mineralization and N fixation contribute to the plant-available N supply in low fertility soils [J]. *Soil Biology and Bio-chemistry*, 2022, 165: 108541.
- [50] 徐艳丽, 段焰, 刘芮, 等. 西南典型烟区水稳定性团聚体组成对土壤理化特征的影响 [J]. *中国烟草科学*, 2020, 41(6): 51–57.
- XU Yanli, DUAN Yan, LIU Rui, et al. Effects of water stable aggregate composition on soil physicochemical characteristics in typical tobacco-planting soil of Southwest China [J]. *Chinese Tobacco Science*, 2020, 41(6): 51–57. (in Chinese)
- [51] 张博文, 杨彦明, 李金龙, 等. 连续深松对黑土水热酶特性及细菌群落的影响 [J]. *生态学杂志*, 2018, 37(11): 3323–3332.
- ZHANG Bowen, YANG Yanming, LI Jinlong, et al. Effects of continuous subsoiling on temperature, water content, enzyme activity and bacterial community in black soil [J]. *Chinese Journal of Ecology*, 2018, 37(11): 3323–3332. (in Chinese)
- [52] BARGAZ A, NOYCE G L, FULTHORPE R, et al. Species interactions enhance root allocation, microbial diversity and P acquisition in intercropped wheat and soybean under P deficiency [J]. *Applied Soil Ecology*, 2017(8): 179–188.

(上接第 222 页)

- [25] 李晓艳, 符惠桐, 牛文涛, 等. 基于深度学习的多模态行人检测算法 [J]. *西安交通大学学报*, 2022, 56(10): 61–70.
- LI Xiaoyan, FU Huitong, NIU Wentao, et al. Multi-modal pedestrian detection algorithm based on deep learning [J]. *Journal of Xi'an Jiaotong University*, 2022, 56(10): 61–70. (in Chinese)
- [26] LIU Y, SHAO Z, TENG Y, et al. NAM: normalization-based attention module [J]. arXiv:2111.12419, 2021.
- [27] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C] // International Conference on Machine Learning, 2015: 448–456.
- [28] 马宾, 王一利, 徐健, 等. 基于双向生成对抗网络的图像感知哈希算法 [J]. *电子学报*, 2023, 51(5): 1405–1412.
- MA Bin, WANG Yili, XU Jian, et al. An image perceptual hash algorithm based on bidirectional generative adversarial network [J]. *Acta Electronica Sinica*, 2023, 51(5): 1405–1412. (in Chinese)
- [29] HUSSAIN M, CHEN T, HILL R. Moving toward smart manufacturing with an autonomous pallet racking inspection system based on MobileNetV2 [J]. *Journal of Manufacturing and Materials Processing*, 2022, 6(4): 75.
- [30] YING B, XU Y, ZHANG S, et al. Weed detection in images of carrot fields based on improved YOLOv4 [J]. *Traitement Du Signal*, 2021, 38(2): 341–348.