

引用格式:

赵辉, 李建成, 王红君, 岳有军. 基于改进YOLOv3的水稻叶部病害检测[J]. 湖南农业大学学报(自然科学版), 2024, 50(1): 100–106.

ZHAO H, LI J C, WANG H J, YUE Y J. The detection of rice leaf diseases based on improved YOLOv3[J].

Journal of Hunan Agricultural University(Natural Sciences), 2024, 50(1): 100–106.

投稿网址: <http://xb.hunau.edu.cn>



基于改进 YOLOv3 的水稻叶部病害检测

赵辉^{1,2}, 李建成^{1,2}, 王红君^{1,2}, 岳有军^{1,2}

(1.天津理工大学电气工程与自动化学院, 天津 300384; 2.天津市复杂系统控制理论与应用重点实验室, 天津 300384)

摘要: 为了解决水稻小病斑检测不准确的问题, 提出一种基于改进 YOLOv3 的水稻叶部病害检测方法 Rice-YOLOv3。首先, 采用 K-means++ 聚类算法, 计算新的锚框尺寸, 使锚框尺寸与数据集相匹配; 其次, 采用激活函数 Mish 替换 YOLOv3 主干网络中的 Leaky Relu 激活函数, 利用该激活函数的平滑特性, 提升网络的检测准确率, 同时将 CSPNet 与 DarkNet53 中的残差模块相结合, 在避免出现梯度信息重复的同时, 增加神经网络的学习能力, 提升检测精度和速率; 最后, 在 FPN 层分别引入注意力机制 ECA 和 CBAM 模块, 解决特征层堆叠处的特征提取问题, 提高对小病斑的检测能力。在训练过程中, 采用 COCO 数据集预训练网络模型, 得到预训练权重, 改善训练效果。结果表明: 在测试集下, Rice-YOLOv3 检测水稻叶部 3 种病害的平均精度均值(mAP)达 92.94%, 其中, 稻瘟病、褐斑病、白叶枯病的 mAP 值分别达 93.34%、89.68%、95.80%, 相较于 YOLOv3, Rice-YOLOv3 检测的 mAP 提高了 6.05 个百分点, 速率提升了 2.8 帧/s, 对稻瘟病和褐斑病的小病斑的检测能力明显增强, 可以检测出原始网络模型漏检的小病斑; 与 Faster-RCNN、YOLOv5 等模型对比, Rice-YOLOv3 提高了对相似病害和微小病害的识别能力, 并在原始的基础上提高了检测速率。

关键词: 水稻叶部病害; YOLOv3; 病害检测; 注意力机制; 图像处理; 目标检测

中图分类号: TP391.41; S435.111.4 文献标志码: A 文章编号: 1007-1032(2024)01-0100-07

The detection of rice leaf diseases based on improved YOLOv3

ZHAO Hui^{1,2}, LI Jiancheng^{1,2}, WANG Hongjun^{1,2}, YUE Youjun^{1,2}

(1.School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin 300384, China; 2.Tianjin Key Laboratory of Complex System Control Theory and Application, Tianjin 300384, China)

Abstract: In order to solve the problem of inaccurate detection of small spots in rice, a rice leaf disease detection method Rice-YOLOv3 based on the improved YOLOv3 was proposed in this study. First, the K-means++ clustering algorithm was used to compute the new anchor frame size for data matching. Second, the activation function Mish was used to replace the Leaky Relu activation function in the YOLOv3 backbone network with a goal to improve the detection accuracy of the network by use of the smoothing property. And, the CSPNet was combined with the residual module in DarkNet53 to avoid the repetition of the gradient information and increase the learning ability of the neural network to improve the detection accuracy and speed. Finally, the attention mechanism ECA and CBAM modules were introduced at the FPN layer to solve the feature extraction problem at the feature layer stacking and improve the detection ability of small spots. In the training process, the COCO dataset was used to pre-train the network model to get the pre-training weights and improve the training effect. The results showed that the mean average precision mean(mAP) of Rice-YOLOv3 for in the rice leaf disease amounted to 92.94%, of which the mAP values of rice blast, brown spot and

收稿日期: 2022-11-01 修回日期: 2024-01-25

基金项目: 天津市科技支撑计划项目(19YFZCSN00360)

作者简介: 赵辉(1963—), 男, 天津人, 博士, 教授, 主要从事复杂系统智能控制理论与应用及农业信息化研究, zhaohui3379@126.com

leaf blight reached 93.34%, 89.68%, 95.80%, respectively. Compared to the YOLOv3, the mAP of Rice-YOLOv3 detection increased by 6.05 percentage points and the speed was improved by 2.8 frames/s, and the detection ability of small spots of rice blast and brown spot was significantly enhanced including those small spots missed by the original network model. Comparing with the models of Faster-RCNN, YOLOv5, etc., the Rice-YOLOv3 improved the ability of recognizing the similar and tiny diseases as well as the detection speed.

Keywords: rice leaf disease; YOLOv3; disease detection; attention mechanism; image processing; target detection

水稻病害是造成水稻减产的主要原因之一,及时准确地识别水稻病害至关重要。水稻病害主要由植保专家和农业技术人员进行诊断,还缺乏基于现代信息检测技术的可靠的智能诊断方法。随着现代农业生产对水稻病害的预报要求越来越高,对水稻病害诊断技术提出了新的要求^[1]。稻瘟病、褐斑病和白叶枯病是水稻生产常见的病害,其中稻瘟病、白叶枯病对水稻的危害极其严重,而褐斑病染病初期为褐色水浸状小斑,当稻瘟病与褐斑病同时出现时难以区分,给病害的准确识别带来了困难。

近年来,深度学习技术发展迅速。邱靖等^[2]通过设置不同的卷积核大小和池化函数,对稻瘟病、纹枯病、稻曲病进行分类处理,预测准确率可以达到96.03%。NARMADHA等^[3]利用多层感知器的密集卷积神经网络(DenseNet)开发了一种水稻病害诊断方法,称为DenseNet169 MLP,对白叶枯病、褐斑病和叶黑穗病进行分类,最大精度达到97.68%;刘婷婷等^[4]采用卷积神经网络对纹枯病和健康叶片进行识别,精度可以达到97%。杨红云等^[5]通过改进AlexNet对8种水稻病害进行识别,准确率可以达到99.11%。上述研究多是对水稻病害进行分类处理,而当同一叶片上存在多种病害或者具有较小病斑时,上述分类检测无法区分同一叶片上的不同病害或者容易将较小病斑忽略,需要一种目标检测算法对病害进行准确识别。目标检测算法不需要人工设计复杂的特征,可以自动提取图像中的各种抽象特征,并根据提取结果对目标进行分类和定位,提高水稻病害检测的效率。

目前,用于病害检测的目标检测算法主要有2种。一种为二阶段目标检测算法,标志性的算法有Fast-RCNN^[6]、Faster-RCNN^[7]等。BARI等^[8]运用Faster-RCNN对3种水稻病害进行检测,虽然检测精度有所提高,但检测速率较慢,难以满足水稻病害检测的实时性要求。另一种是一阶段目标检测算

法,通过卷积神经网络,直接预测出目标的分类结果和位置,代表算法主要有SSD^[9]、YOLO^[10]系列等。TEMNIRANRAT等^[11]将YOLOv3应用在农业机器人上,由机器人对水稻病害进行检测,并将结果传输给农户和植保专家,可通过语音模块进行在线交流,从而进行病害的识别,但精度较低。由于目前检测速率较高的YOLOv3对小目标检测能力较弱,导致对稻瘟病、褐斑病等小病斑的识别准确率较低^[12-13]。为了同时满足病害检测对准确性和实时性的要求,笔者提出一种基于改进YOLOv3的水稻病害检测算法Rice-YOLOv3。

1 数据准备与处理

1.1 图像获取

以水稻叶部病害为检测对象,主要检测稻瘟病、褐斑病和白叶枯病等3种病害。所采用的图像来自Kaggle数据集竞赛网站、农业病虫害研究图库(IDADP)^[14]等。为了增强系统的鲁棒性,以适应各种自然环境,分别于早上、中午、傍晚在天津市西青区水稻田实地拍摄水稻病害图像。照明环境包括逆光、顺光、晴天、阴天等多种复杂的自然环境。共收集到水稻3种病害图片共1060张,其中褐斑病300张,稻瘟病300张,白叶枯病460张。

1.2 图像处理与数据集制作

为克服图像噪声对图像造成的干扰,首先进行高斯滤波去噪处理。将收集到的图像裁剪为640像素×640像素大小,并统一保存为JPG格式。由于收集到的图像只有1060张,数量不足,对图像进行随机数据增强处理,包括旋转、裁剪、对称等。为了缩短训练时间,将原图像数量扩大4倍,褐斑病图像1200张,稻瘟病图像1200张,白叶枯病图像1840张,合计4240张图像作为数据集。采用PASCAL VOC的数据集格式,对图像采用LabelImg进行标注,在标注过程中,尽可能少地标注背景,以确保矩形框

中的内容只包含水稻叶片和水稻病害,同时把病害放在标注框中央,提高标注质量。最终,按照约8:1:1随机划分训练集、验证集和测试集,其中训练集3434张,验证集382张,测试集424张。各病害图像数及样本数如表1所示。其中样本总量为每张图像上标出的病害总量。

表1 水稻叶部各病害图像数及样本数

| Table 1 Number of images and samples of each disease on rice leaves | | | | |
|---|-------|-----|-----|--------|
| 病害种类 | 训练集 | 验证集 | 测试集 | 样本总量 |
| 褐斑病 | 997 | 104 | 99 | 4 864 |
| 稻瘟病 | 962 | 102 | 136 | 2 552 |
| 白叶枯病 | 1 475 | 176 | 189 | 4 216 |
| 总计 | 3 434 | 382 | 424 | 11 632 |

2 改进YOLOv3的水稻病害检测算法

2.1 采用K-means++算法重新计算锚框

YOLOv3的anchor box是使用COCO数据集聚类而成的,该数据集种类多且目标大小不一。水稻病害具有病斑较小且发生位置密集的特点,为了使anchor box匹配水稻病害数据集,采用K-means++聚类算法,重新计算水稻病害数据集的anchor box尺寸。经过K-means++聚类算法后总共生成了9种新的anchor box尺寸,分别为(10×17)、(14×14)、(19×20)、(23×35)、(33×25)、(47×56)、(58×160)、(234×97)、(55×292)。

2.2 采用Mish激活函数替换Leaky Relu

采用Mish^[15]函数替代主干网络中的Leaky Relu函数,该激活函数更加平滑,可以更好的将信息渗透到神经网络中,获得更好的准确性和泛化性。在更换激活函数后,网络中也由原来的CBL模块更换为CBM模块,其结构如图1所示。




图1 CBM模块和CBL模块

Fig.1 CBM module and CBL module

2.3 引入CSPX模块

YOLOv3是由一系列残差模块串联而成,在维

持残差模块结构不变的前提下,首先,将CBL模块替换为CBM模块,其中残差模块的结构如图2所示;其次,使用CSPNet^[16]结构和原始残差块进行融合,构成CSPX模块,即将原来的残差模块的堆叠进行拆分,该模块在经过1个CBM模块后,将特征图分为2部分,一部分再经过1个CBM模块,另一部分经过CBM和X个残差块;最后,将这2部分进行堆叠操作。其结构图如图3所示。




图2 残差块

Fig.2 Residual block




图3 CSPX模块

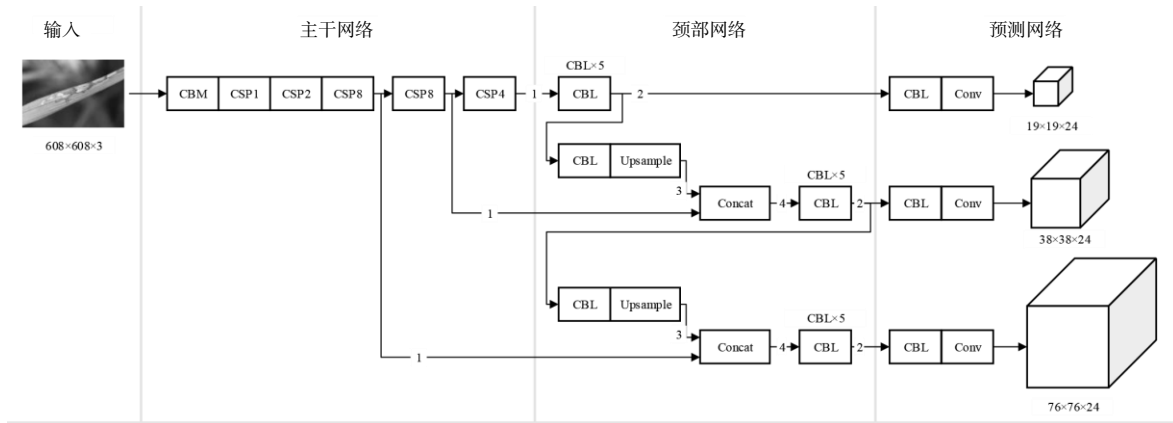
Fig.3 CSPX module

由于农业机器人的普及,对病害检测的实时性要求越来越高,原始的DarkNet53采用了过深的残差连接,虽然增加了准确性,但也大大降低了检测速率。CSPX模块将基础层的特征映射分为2部分,然后通过跨阶段层次结构将其合并,这样减少了梯度信息的重复,检测速率也得到了提高。同时,将梯度变化集成到特征图中,有效地增强了神经网络的学习能力,可以在减少计算量的同时提升检测精度。

2.4 添加注意力机制模块

由于水稻病害病斑较小,存在病害密集的区域,且同一叶片会存在不同病害,在病害检测中常常会存在漏检和错检的情况,从而导致准确率降低,需要通过增强感受野、加强有效特征提取来提高检测结果。为了能更好地提取特征,在FPN层不同位置施加不同的注意力机制,本研究中,主要运用CBAM^[17]、ECA^[18]以及2种混合的注意力机制。为了验证插入组合注意力模块的有效性,在替换激活函数和引入CSPX模块的基础上,分别在位置1(主干网络输出端)、位置2(经过5次卷积之后)、位置3(上采样之后)、位置4(特征层堆叠之后)施加ECA和CBAM注意力机制,进行对比试验。

修改后算法的结构如图4所示。



CBM表示Conv(卷积)、批量正则化BN(Batch Normalization)层以及Mish激活函数的组合模块；CSPX表示CSP模块的个数；CBL表示Conv、批量正则化BN层以及Leaky Relu激活函数的组合模块；Upsample表示对特征层进行上采样操作；Concat表示对输入进来的2个特征层进行堆叠，实现特征融合；x5表示含有5个该模块；连接线上的数字表示在不同位置施加注意力机制。

图 4 改进后的算法结构

Fig.4 Structure of the improved algorithm

3 模型训练

采用Ubuntu18.04操作系统；CPU配置为Intel Xeon(R) E5-2650 v4@2.20Hz×48，运行内存64 GB；GPU配置为 GTX1080Ti×2，NVIDIA驱动为450.102.04；CUDA和cuDNN版本分别为11.0和7.6.5。编程语言为python，版本为3.7，使用Pycharm作为IDE，深度学习框架为Pytorch1.7版本。

总训练轮数设置为350轮，批量尺寸设置为8，初始学习率设置为0.001，权值衰减设置为0.0005，动量设置为0.937，使用随机梯度下降算法SGD进行优化。

采用F1得分表示准确率和召回率的综合性能；平均精度(AP)表示不同类别的平均精度值；平均精度均值(mAP)作为整个模型性能的评价指标。

由于修改了原始DarkNet53的残差结构和激活

函数，导致原始的YOLOv3预训练权重将不能使用；因此，通过训练由微软提供的大规模数据集COCO数据集来得到预训练权重^[19]，COCO数据集相较于VOC数据集种类更多，具有更好的泛化能力。

4 试验及其结果

4.1 消融试验

为了验证对YOLOv3主干网络改进后以及使用新的anchor box尺寸的有效性，对改进后的主干网络进行消融试验，各性能指标如表2所示。从表2可以看出，在使用新的anchor box尺寸后，YOLOv3对3种水稻病害检测能力增强，检测速率不变；在使用了CSPNet结构后，神经网络的学习能力增强，可以保证水稻病害目标的特征信息在传播过程中不丢失，特征提取网络可以提取更多的水稻病害目

表 2 消融试验性能指标

Table 2 Ablation test performance index

| 目标检测算法 | 平均精度/% | | | 平均精度均值/% | F1得分/% | 检测速率/ (帧 s ⁻¹) |
|------------------------|--------|-------|-------|----------|--------|-------------------------------|
| | 褐斑病 | 稻瘟病 | 白叶枯病 | | | |
| YOLOv3 | 83.66 | 85.17 | 91.84 | 86.89 | 82.4 | 15.7 |
| YOLOv3-Mish | 85.28 | 85.73 | 91.35 | 87.46 | 82.9 | 13.2 |
| YOLOv3-anchor | 83.84 | 86.39 | 93.45 | 87.89 | 83.4 | 15.7 |
| YOLOv3-CSP | 85.66 | 89.58 | 89.14 | 88.13 | 84.1 | 20.3 |
| YOLOv3-anchor-Mish | 86.39 | 88.62 | 92.26 | 89.09 | 84.8 | 13.2 |
| YOLOv3-anchor-CSP | 85.72 | 90.94 | 91.81 | 89.49 | 85.3 | 20.3 |
| YOLOv3-Mish-CSP | 85.95 | 90.43 | 90.69 | 89.02 | 84.9 | 19.1 |
| YOLOv3-anchor-Mish-CSP | 86.64 | 91.52 | 92.78 | 90.31 | 85.5 | 19.1 |

标的有效特征信息,同时降低了输入部分的维度,减少了参数量,提高了检测速率;使用 Mish 激活函数替换原始 Leaky Relu 函数, Mish 函数曲线在横坐标负半轴时曲线更平滑,有一个很小的负梯度,这样可以保证信息不会缺失,同时具有无边界的特点,可以避免饱和的问题。但由于计算更复杂,会对检测速率有一定的影响,通过引入 CSPNet 结构解决了这一问题,改进后的主干网络较 YOLOv3 主干网络在检测速率和精度上都有一定的提升。

4.2 不同注意力机制及位置对比试验

从表3可以发现,在位置2施加注意力机制会降低精度,这是由于在位置2施加注意力机制,该特征层不仅会进行下一步的上采样,也会输入到头部网络中进行预测和输出,从而影响网络的精度;在位置4施加注意力机制,对网络精度提升不大,甚至施加CBAM注意力机制会降低网络精度;在位置1和位置3施加2种注意力机制,分别得到了不同的提升,其中,在位置1施加CBAM注意力机制,mAP值可以达到91.61%。这是由于位置1和位置3处于不同尺度信息的交汇处,可以提取到更丰富的语义信息。结果表明,在目标检测网络中应用注意力机制并不一定能提高检测精度,应根据具体任务进行选择。通道注意力模块保持通道维度不变,只压缩空间维度,对水稻病害种类信息敏感;空间注意模块保持空间维度不变,压缩通道维度,对水稻病害位置信息敏感。为了对同一叶片上存在的多种水稻病害进行准确识别,同时保证对水稻病害精准定位,在位置1施加CBAM注意力机制和在位置3施加ECA注意力机制,褐斑病、稻瘟病和白叶枯病平均精度分别提升3.04、1.82、3.02个百分点,mAP值达92.94%,检测能力明显增强,综合效果达到最优。

表 3 不同位置插入不同注意力机制对水稻叶部 3 种病害的检测精度

Table 3 Detection accuracy of three diseases of rice leaves by inserting different attention mechanisms at different locations %

| 注意力机制 | 平均精度 | | | 平均精度 |
|--------------|-------|-------|-------|-------|
| | 褐斑病 | 稻瘟病 | 白叶枯病 | 均值 |
| 无注意力机制 | 86.64 | 91.52 | 92.78 | 90.31 |
| 1-ECA | 88.92 | 92.37 | 91.45 | 90.91 |
| 2-ECA | 84.15 | 89.98 | 90.32 | 88.15 |
| 3-ECA | 88.62 | 92.01 | 93.28 | 91.30 |
| 4-ECA | 87.84 | 91.98 | 92.62 | 90.81 |
| 1-CBAM | 88.67 | 93.14 | 93.03 | 91.61 |
| 2-CBAM | 87.86 | 88.12 | 91.91 | 89.30 |
| 3-CBAM | 87.65 | 92.09 | 93.37 | 91.04 |
| 4-CBAM | 87.88 | 90.74 | 91.70 | 90.11 |
| 1-ECA+3-CBAM | 89.24 | 92.47 | 93.22 | 91.64 |
| 3-ECA+1-CBAM | 89.68 | 93.34 | 95.80 | 92.94 |

4.3 不同算法对比试验


使用数据集分别训练CenterNet、RetinaNet、Faster-RCNN、YOLOv3、Rice-YOLOv3和YOLOv5,结果如表4所示。通过对比发现,与YOLOv3相比,Rice-YOLOv3检测褐斑病、稻瘟病、白叶枯病的平均精度分别提升了6.02、8.17、3.96个百分点;整体精度提升了6.05个百分点;F1值提升了6.3个百分点。其中,通过使用CSPX模块,降低了计算量,在提高精度的同时,Rice-YOLOv3的检测速率较YOLOv3提高了2.8帧/s,比Faster-RCNN的提高了11.7帧/s,可以满足实时检测病害的需要。与CenterNet、RetinaNet、Faster-RCNN等目标检测网络相比,Rice-YOLOv3的mAP值分别高出3.24、31.28、5.49个百分点;CenterNet对白叶枯病的检测精度较Rice-YOLOv3的低8.62个百分点;RetinaNet的mAP值仅为61.66%;与YOLOv5进行对比,Rice-YOLOv3对3种病害的检测精度分别提高了

表 4 不同目标检测模型的性能

Table 4 Performance of different target detection models

| 目标检测算法 | 平均精度/% | | | 平均精度均值/% | F1得分/% | 检测速率/ (帧 s ⁻¹) |
|-------------|--------|-------|-------|----------|--------|-------------------------------|
| | 褐斑病 | 稻瘟病 | 白叶枯病 | | | |
| CenterNet | 86.33 | 95.59 | 87.18 | 89.70 | 81.8 | 25.6 |
| RetinaNet | 53.20 | 68.14 | 63.63 | 61.66 | 62.1 | 23.4 |
| Faster-RCNN | 85.28 | 85.73 | 91.35 | 87.45 | 81.3 | 6.8 |
| YOLOv3 | 83.66 | 85.17 | 91.84 | 86.89 | 82.4 | 15.7 |
| YOLOv5 | 82.88 | 90.94 | 88.26 | 87.36 | 80.8 | 21.1 |
| Rice-YOLOv3 | 89.68 | 93.34 | 95.80 | 92.94 | 88.7 | 18.5 |

6.80、2.40、7.54个百分点,平均精度均值提高了5.58个百分点。综合比较,Rice-YOLOv3在平均精度、mAP值、F1得分和检测速率上均优于YOLOv3,实现了多方面性能的提升。与其他算法相比,Rice-YOLOv3可以同时兼顾检测结果的准确性和实时性,综合效果较优。从部分检测结果(图5)可以看出,Rice-YOLOv3可以在实验室环境和自然环境下,



a 褐斑病检测效果;b 稻瘟病检测效果;c 白叶枯病检测效果。


图 5 Rice-YOLOv3 检测效果

Fig.5 Detection effect of Rice-YOLOv3

准确检测各类水稻病害,同时在病害密集区域以及小病斑区域具有良好的检测效果。

4.4 不同病害及小病斑检测试验

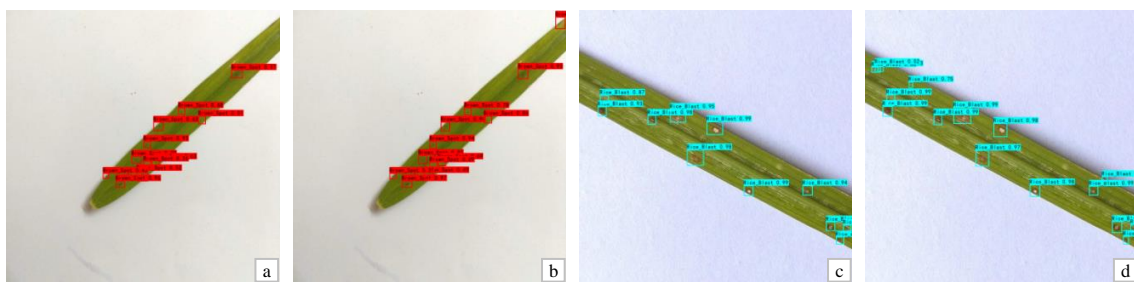
采用 YOLOv3 和 Rice-YOLOv3 分别对不同病害和小病斑(由于白叶枯病发病部位大,且易与褐斑病和稻瘟病区分,此处只检测褐斑病和稻瘟病)进行检测,结果如图 6 和图 7 所示。从图 6 可以看出,YOLOv3 漏检(图 6-a)甚至不能检出(图 6-c)存在于水稻叶片上的稻瘟病,对褐斑病也会漏检(图 6-c);而 Rice-YOLOv3 可以很好地识别稻瘟病和褐斑病,具有更好的检测效果。从图 7 可以看出,YOLOv3 对小病斑区域存在漏检,这可能是由于特征提取中信息缺失所致;Rice-YOLOv3 能检测出更多的病斑,具有更好的检测效果。



a、c YOLOv3检测结果;b、d Rice-YOLOv3检测结果。

图 6 YOLOv3 和 Rice-YOLOv3 对不同病害的检测结果

Fig.6 Detection result of different diseases by YOLOv3 and Rice-YOLOv3



a、c YOLOv3检测结果;b、d Rice-YOLOv3检测结果。

图 7 YOLOv3 和 Rice-YOLOv3 对小病斑的检测结果

Fig.7 Detection result of small-area diseases by YOLOv3 and Rice-YOLOv3

5 结论

采用K-means++聚类算法聚类锚框,用Mish激活函数替换YOLOv3主干网络中的Leaky Relu激活函数并引入CSPX模块和ECA、CBAM模块,进一步完善YOLOv3,解决了原始算法对不同病害和小病斑检测效果差的问题。

1) 与YOLOv3相比,改进后的算法对褐斑病、稻瘟病、白叶枯病的检测平均精度分别提升了6.02、8.17、3.96个百分点;F1得分和mAP分别提升了6.3、6.05个百分点;检测速率也提升了2.8帧/s,所有性能均高于YOLOv3,能够满足对水稻病害检测的实时性和准确性要求。

2) 施加注意力机制能否提升精度,既与施加的

注意力机制种类有关,也与施加注意力机制的位置有关。本研究中,在位置1和位置3施加CBAM和ECA注意力机制,可以达到最好的效果,对水稻病害检测的准确率提升明显。

3) 改进后的YOLOv3可以很好地识别同一叶片上的不同病害和小病斑区域,弥补了YOLOv3对小目标检测弱的缺点,具有更好的检测效果。

参考文献:

- [1] LU Y, YI S J, ZENG N Y, et al. Identification of rice diseases using deep convolutional neural networks[J]. *Neurocomputing*, 2017, 267: 378–384.
- [2] 邱靖, 刘继荣, 曹志勇, 等. 基于卷积神经网络的水稻病害图像识别研究[J]. *云南农业大学学报(自然科学)*, 2019, 34(5): 884–888.
- [3] NARMADHA R P, SENGOTTAIYAN N, KAVITHA R J. Deep transfer learning based rice plant disease detection model[J]. *Intelligent Automation & Soft Computing*, 2022, 31(2): 1257–1271.
- [4] 刘婷婷, 王婷, 胡林. 基于卷积神经网络的水稻纹枯病图像识别[J]. *中国水稻科学*, 2019, 33(1): 90–94.
- [5] 杨红云, 万颖, 王映龙, 等. 基于批归一化与AleNxt网络的水稻病害识别[J]. *激光与光电子学进展*, 2021, 58(6): 0610007.
- [6] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision(ICCV). Santiago, Chile: IEEE, 2015: 1440–1448.
- [7] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137–1149.
- [8] BARI B S, ISLAM M N, RASHID M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework[J]. *PeerJ Computer Science*, 2021, 7: e432.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]//European Conference on Computer Vision. Cham: Springer, 2016: 21–37.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer vision and Pattern Recognition(CVPR). Las Vegas, USA: IEEE, 2016: 779–788.
- [11] TEMNIRANRAT P, KIRATIRATANAPRUK K, KITVIMONRAT A, et al. A system for automatic rice disease detection from rice paddy images serviced via a Chatbot[J]. *Computers and Electronics in Agriculture*, 2021, 185: 106156.
- [12] 王超学, 祁昕, 马罡, 等. 基于YOLO V3的葡萄病害人工智能识别系统[J]. *植物保护*, 2022, 48(6): 278–288.
- [13] 文斌, 曹仁轩, 杨启良, 等. 改进YOLOv3算法检测三七叶片病害[J]. *农业工程学报*, 2022, 38(3): 164–172.
- [14] 陈雷, 袁媛. 大田作物病害识别研究图像数据集[J]. *中国科学数据(中英文网络版)*, 2019, 4(4): 85–91.
- [15] ANMOL P, RAKESH C B. Enhancement of license plate recognition performance using xception with Mish activation function[J]. *Multimedia Tools and Applications*, 2023, 82(11): 16793–16815.
- [16] WANG C Y, MARK LIAO H Y, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Seattle, USA: IEEE, 2020: 1571–1580.
- [17] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C]//European Conference on Computer Vision. Cham: Springer, 2018: 3–19.
- [18] 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, USA: IEEE, 2020: 11531–11539.
- [19] YU Y, ZHANG K L, YANG L, et al. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN[J]. *Computers and Electronics in Agriculture*, 2019, 163: 104846.

责任编辑: 邹慧玲
英文编辑: 柳正