

杨玉青, 朱德泉, 刘凯旋, 等. 基于改进的 LSN-YOLOv8 模型和无人机遥感图像的水稻稻曲病检测方法[J]. 江苏农业学报, 2025, 41(5): 905-915.

doi: 10.3969/j.issn.1000-4440.2025.05.009

基于改进的 LSN-YOLOv8 模型和无人机遥感图像的水稻稻曲病检测方法

杨玉青¹, 朱德泉¹, 刘凯旋¹, 严从宽¹, 孟凡凯¹, 唐七星¹, 廖娟^{1,2}

(1.安徽农业大学工学院,安徽 合肥 230036; 2.安徽农业大学新农村发展研究院皖东综合试验站,安徽 明光 239400)

摘要: 本研究针对无人机采集的水稻稻曲病图像中存在的背景复杂、病斑目标小且与背景表征相似等问题,构建了一种水稻稻曲病检测模型 LSN-YOLOv8。该模型以 YOLOv8 模型为基本框架,在骨干网络中融入大选择性核网络(LSKNet),通过动态调整感受野范围增强模型对小目标的特征提取能力;在骨干网络中加入坐标注意力机制(CA)模块,将病斑空间位置信息与通道注意力相结合,增强模型对关键区域的关注度同时减少背景干扰;利用梯度加权类激活映射(Grad-CAM)技术实现检测过程的可视化分析,为模型决策提供直观解释。为验证模型性能,利用无人机拍摄不同发病时期、不同背景条件下的水稻稻曲病图像,构建水稻稻曲病数据集,用于模型训练与测试。试验结果表明,本研究提出的 LSN-YOLOv8 模型精准度、召回率和交并比阈值为 0.50 时的平均精度值均值(mAP_{50})分别为 94.8%、87.3%和 92.3%,均高于 YOLOv5、YOLOv7、YOLOv8、Faster R-CNN 模型等经典目标检测模型。梯度加权类激活映射(Grad-CAM)技术可视化分析结果表明,LSN-YOLOv8 模型能够更准确地聚焦于图像中的病害区域。本研究提出的 LSN-YOLOv8 模型可为稻曲病监测、病害防治和水稻抗病性鉴定提供技术支持。

关键词: 稻曲病; 病害识别; 无人机; YOLOv8 模型; 大选择性核网络(LSKNet); 坐标注意力机制(CA)

中图分类号: S435.115 **文献标识码:** A **文章编号:** 1000-4440(2025)05-0905-11

A method for rice false smut detection based on improved LSN-YOLOv8 model and unmanned aerial vehicle remote sensing images

YANG Yuqing¹, ZHU Dequan¹, LIU Kaixuan¹, YAN Congkuan¹, MENG Fankai¹, TANG Qixing¹, LIAO Juan^{1,2}

(1. School of Engineering, Anhui Agricultural University, Hefei 230036, China; 2. Wan-Dong Comprehensive Experimental Station, New Rural Development Research Institute, Anhui Agricultural University, Mingguang 239400, China)

Abstract: To address the challenges of complex backgrounds, small lesion targets, and the similarity between lesion targets and background features in rice false smut images collected by unmanned aerial vehicles (UAVs), we proposed the LSN-YOLOv8 detection model. The model was based on the YOLOv8 framework, and the large selective kernel network (LSKNet) was incorporated into the backbone network. By dynamically adjusting the receptive field range, the model enhanced its ability to extract features of small targets. Additionally, a coordinate attention mechanism (CA) module was integrated into the backbone network to combine the spatial

收稿日期: 2024-07-22

基金项目: 国家重点研发计划项目(2022YFD2001801-3); 国家自然科学基金项目(32201665)

作者简介: 杨玉青(2001-), 男, 安徽六安人, 硕士研究生, 研究方向为农作物病害识别。(E-mail)23720754@stu.ahau.edu.cn

通讯作者: 廖娟, (E-mail)liaojuan@ahau.edu.cn

location information of lesions with channel attention, thereby enhancing the model's focus on key regions while reducing background interference. The detection process was visualized and analyzed using the gradient-weighted class activation mapping (Grad-CAM) technique, thereby

providing intuitive explanations for the model's decision-making. To verify the model's performance, rice false smut images captured by UAVs at different disease stages and under various background conditions were used to construct a rice false smut dataset. This dataset was utilized for model training and testing. The experimental results indicated that the precision, recall, and mean average precision at an intersection over union threshold of 0.50 (mAP_{50}) of the LSN-YOLOv8 model proposed in this study were 94.8%, 87.3%, and 92.3%, respectively. These indices were all higher than those of classic object detection models such as YOLOv5, YOLOv7, YOLOv8 and Faster R-CNN. The visualization analysis results using Grad-CAM technology indicated that the LSN-YOLOv8 model was capable of more accurately focusing on the diseased regions in the images. The LSN-YOLOv8 model proposed in this study can provide technical support for the monitoring of rice false smut, disease control and prevention, and the identification of rice disease resistance.

Key words: rice false smut; disease identification; unmanned aerial vehicle; YOLOv8 model; large selective kernel network (LSKNet); coordinate attention mechanism (CA)

水稻是全球最重要的粮食作物之一^[1],其产量与质量的提升是水稻生产的核心目标。在生长过程中,水稻会遭遇各种病虫害的侵袭,由稻绿核菌引起的稻曲病已成为全球水稻栽培区三大主要真菌病害之一^[2]。该病害不仅导致水稻产量下降,还产生有害毒素,严重影响食用安全^[3]。目前,稻曲病的防治主要依赖化学药剂,但长期使用化学药剂易引发土壤污染和农药残留等问题^[4]。选育抗病品种是防治稻曲病的有效途径^[5],而准确识别稻曲病的症状及判断其发病阶段是抗病品种选育和精准施药的关键。传统的稻曲病检测主要依赖人工目测,存在效率低、劳动强度大、主观性强等缺陷,难以实现实时监测,且准确率较低^[6]。深度学习模型能够从作物图像中提取病斑特征,实现对病害类型的早期准确识别,从而减少农业损失^[7]。Zeng 等^[8]提出了一种自注意卷积神经网络(SACNN),该方法融合图像的全局与局部特征,对作物病害的识别准确率超过 95%。杨峰等^[9]基于 YOLOv8 模型,采用改进的轻量级卷积神经网络 ShuffleNetV2 作为主干网络,显著提升了模型对病虫害检测的鲁棒性。李仁杰等^[10]针对自然环境下背景复杂和密集遮挡等问题,提出一种改进的 YOLOv5 模型,实现了对番茄叶片病害的实时检测,模型精度达到 98.9%。Wang 等^[11]结合卷积神经网络(CNN)和门控循环单元(GRU),提出了一种用于冬小麦产量估算的模型。尽管这些研究在作物病害识别方面取得了一定进展,但其主要依赖地面相机获取图像,地面相机难以在短时间内覆盖大面积农田,无法满足大范围病害快速识别与防治的需求。

无人机遥感技术凭借其覆盖范围广、速度快、成本低等特点,在作物病害检测领域已展现出了独特优势^[12]。Hu 等^[13]构建 DDYOLOv5 模型,并基于无人机获取的松树遥感影像数据集对模型进行训练和测

试,实现了对不同病害程度松树的检测与分类。Bao 等^[14]提出了一种基于 DDMA-YOLO 的无人机遥感目标检测方法,用于检测茶叶枯病。Tetila 等^[15]对深度学习模型进行了优化,并基于无人机拍摄的大豆虫害图像数据集对模型进行训练和测试,结果表明,该模型分类性能显著提升,准确率达到 93.82%。孙钰等^[16]通过简化 SSD300 目标检测框架避免了复杂的图像预处理步骤,有效提升了无人机监测的效率和准确性。Kerkech 等^[17]提出基于可见光与红外图像配准的葡萄藤霜霉病检测方法,该方法对融合图像的检测精度达到 92%。胡根生等^[18]利用无人机采集野外茶园的遥感图像并构建轻量级网络 LiTLBNet,在动态监测茶叶枯病中,该模型的检测精度达到 75.1%,平均精度均值达到 78.5%。

目前,水稻稻曲病的检测仍面临诸多挑战。病害目标尺寸小,多次下采样操作易造成特征信息丢失;水稻稻曲病病斑随机分布在稻穗上,且不同时期的病斑尺寸、形状不一;水稻稻曲病病斑的颜色与背景相似,复杂背景会对检测造成干扰。针对这些问题,本研究拟将 YOLOv8 作为基本网络框架,融入大选择性核网络(Large selective kernel network,LSKNet)^[19],通过动态调整感受野增强模型对小目标特征的提取能力,集成坐标注意力机制(Coordinate attention,CA)^[20]以去除冗余特征,结合 GradCAM 算法^[21]实现检测过程的可视化,为模型决策提供直观解释。以期提升模型对复杂背景下水稻稻曲病的识别性能。

1 材料与方 法

1.1 病害图像采集

本研究使用的水稻稻曲病病害图像于 2023 年 9 月-2023 年 10 月采集自安徽省农业科学院合肥

市南岗试验基地和牛角大圩试验基地。采用搭载 2.000×10^7 像素 CMOS 传感器的大疆御 2 专业版 (DJI Mavic2 Pro) 无人机进行巡飞和视频录制。为减少无人机旋翼气流对水稻冠层的干扰,根据水稻株高调整无人机飞行高度和镜头焦距。飞行高度设置为 $1.2 \sim 1.8$ m, 摄像头俯仰角设置为 $-60^\circ \sim -30^\circ$,

以避免拍摄正下方受气流扰动较大的冠层区域,采集图像如图 1 所示。为了提高图像数据的多样性和模型的环境适应性,本研究对试验基地不同田块和不同发病阶段的水稻进行了视频录制,共录制 13 段视频,每段时长为 $2 \sim 4$ min, 视频格式为 MP4, 分辨率为 $3\ 840$ 像素 \times $2\ 160$ 像素。




图 1 无人机采集的水稻病害图像

Fig.1 Rice disease images collected by an unmanned aerial vehicle

1.2 数据集构建

采用 CRVideoMate 对录制的视频进行分帧处理,输出图像分辨率为 $3\ 840 \times 2\ 160$, 以 JPG 格式保存。如图 2 所示,为确保图像质量,剔除了模糊和相似度较高的帧,并将每幅图像均等分割为 4 个分辨率为 $1\ 920$ 像素 \times $1\ 080$ 像素的图像,最终获得 860 张裁剪图

像。将 860 张裁剪图像按照 $7:2:1$ 的比例划分为训练集 (600 张)、验证集 (180 张) 和测试集 (80 张)。如图 3 所示,使用 LabelImg 工具对图像进行单目标标注,并生成对应的标签文件,用于后续模型训练和数据处理。




图 2 遥感图像剪切方法

Fig.2 Remote sensing image cropping method



图3 图像标注
Fig.3 Image annotation

1.3 水稻稻曲病识别模型设计

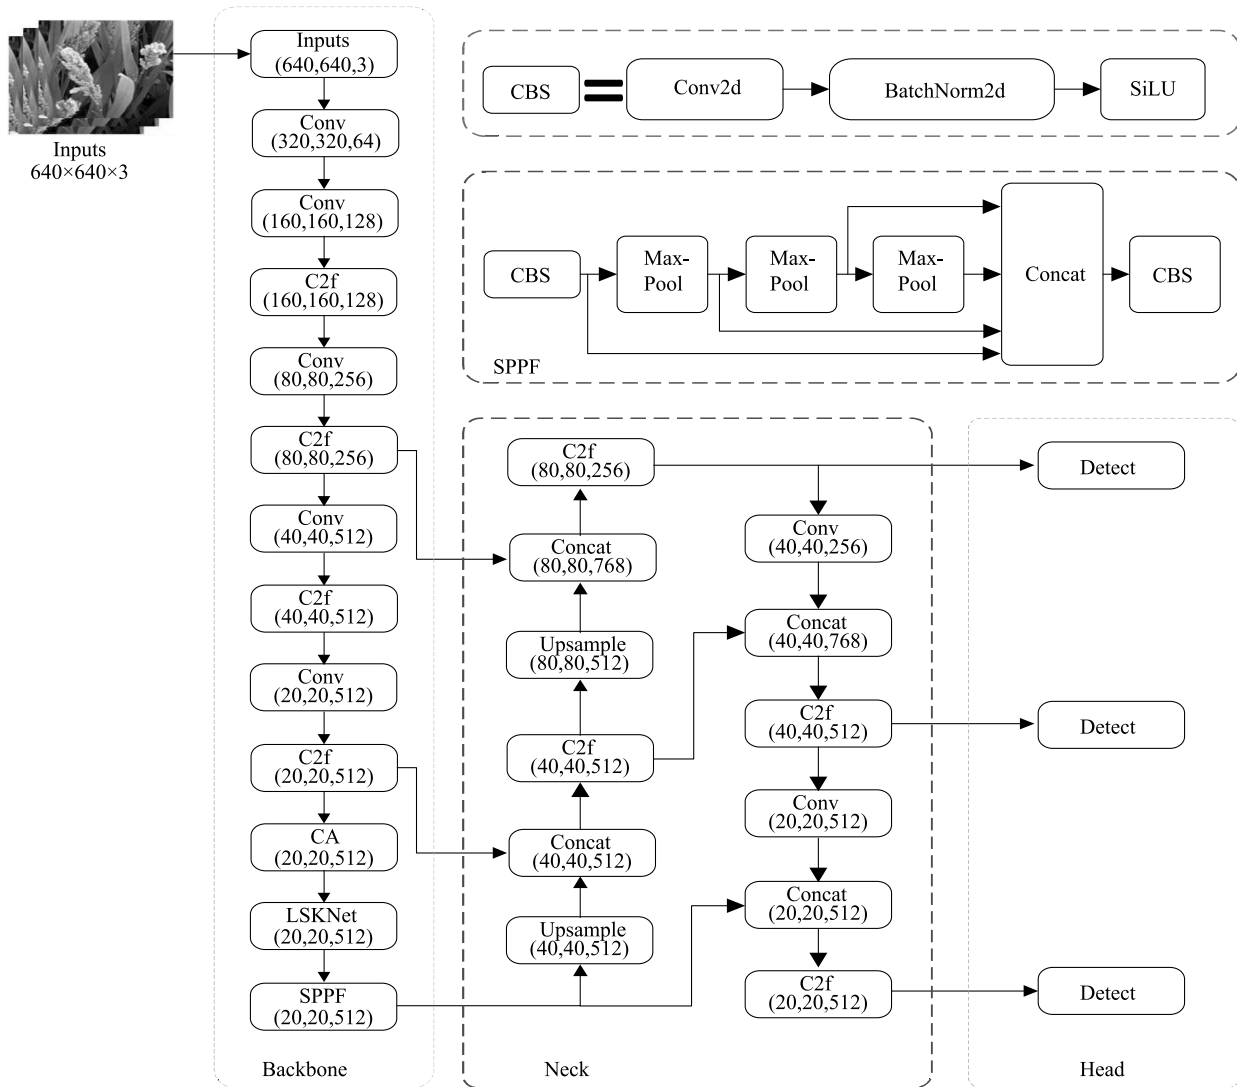
1.3.1 基本框架模型选择 YOLO 系列模型具有检测精度高和检测速度快的优势,目前已成为目标检测的主流模型。其中, YOLOv8 模型是在 YOLOv5 模型基础上进行的更新和改进^[22],该模型由输入端、骨干网络 (Backbone)、颈部网络 (Neck) 和输出端 4 个部分组成。在骨干网络中, YOLOv8 采用 C2f 特征提取模块替代 YOLOv5 模型的 C3 特征提取模块,通过融合低分辨率和高分辨率特征,增强模型对目标语义信息和细节特征的提取能力^[23]。YOLOv8 模型的特征金字塔网络 (Feature pyramid networks) 沿用了 YOLOv5 模型的路径聚合网络 (PANet) 架构,但在上采样过程中删除了原有的卷积结构。YOLOv8 模型的输出端采用解耦头设计,通过无锚 (Anchor-Free) 机制替代传统的锚定 (Anchor-Based) 机制,显著提升了模型对不规则物体的检测性能。YOLOv8 有 n, s, m, l, x 5 种参数量^[24],本研究选择轻量化的 YOLOv8n 作为基线模型,以兼顾检测效率与计算资源消耗。

1.3.2 LSN-YOLOv8 模型设计 本研究基于 YOLOv8n 模型进行了 3 个方面的改进。第一,在骨干网络中引入大选择性核网络 (LSKNet),通过动态调整机制自适应选择不同尺寸的空间感受野,增强模型对小目标的特征提取能力。第二,在骨干网络末端的 C2f 特征提取模块后引入坐标注意力机制 (CA),坐标注意力机制通过融合位置信息与通道注意力,为不同区域分配差异化权重,使网络更加聚焦

于稻曲病病斑区域,进一步提升特征提取的准确性和鲁棒性。第三,采用梯度加权类激活映射 (Grad-CAM) 对模型进行特征可视化分析,直观展示网络在病害识别过程中的关注区域,验证模型决策的合理性,增强模型的可解释性。改进后的 LSN-YOLOv8 模型结构如图 4 所示。

1.3.2.1 大选择性核网络 (LSKNet) 引入 无人机遥感图像中,水稻稻曲病部位仅占少量像素,且缺乏明显的颜色、纹理、形状等外观特征,易被漏检。此外,经过多次下采样操作后,图像的分辨率降低,特征信息减弱,导致主干网络难以提取其特征信息。在这种情况下,仅依赖有限的背景信息进行检测,往往容易出错。遥感图像通常包含丰富的背景先验信息,这些信息能够引导模型关注关键特征,从而学习到更具区分度的特征表达。本研究采用的大选择性核网络 (LSKNet) 通过空间选择机制,对经过大深度卷积核处理的特征进行自适应加权和空间融合。该网络能够根据输入特征动态调整各目标的感受野范围,从而获取更全面的上下文信息。这种空间维度上的自适应感受野调整机制,特别适用于无人机多视角拍摄图像和复杂田间环境下的稻曲病检测任务。将 LSKNet 集成到 YOLOv8n 的特征提取网络中,可显著提升模型对小尺度稻曲病特征的关注能力,进而提高整体识别准确率。

大选择性核网络 (LSKNet) 的结构如图 5 所示,主要由前馈网络模块 (FFN) 和大内核选择模块 (LK Selection) 2 个子模块组成。FFN 模块通过全连接层



Inputs: 输入; Backbone: 主干网络; Conv: 卷积操作; C2f: 特征提取模块; CA: 坐标注意力模块; LSKNet: 大选择性核网络; SPPF: 空间金字塔池化模块; CBS: 组合模块; Conv2d: 二维卷积层; MaxPool: 最大池化层; BatchNorm2d: 批量归一化层; SiLU: 激活函数; Neck: 颈部网络; Concat: 融合; Upsample: 上采样; Head: 检测头。

图4 LSN-YOLOv8 模型结构

Fig.4 The structure of LSN-YOLOv8 model

(FC)、深度卷积(DWConv)、激活函数(GELU)和第2个全连接层(FC)的级联结构实现通道混合和特征细化。大内核选择模块(LK Selection)由全连接层、大内核选择子模块(LSK Module)、GELU 激活函数和第2个全连接层组成。LSK Module 作为 LSK-Net 的核心组件,采用大核卷积和空间核选择机制实现特征提取。大核卷积通过将 LSK Module 分解为一系列深度可分离卷积序列实现高效计算。这些深度可分离卷积的卷积核尺寸和扩张率逐步增加,从而在捕捉更广泛上下文信息的同时,减少了计算

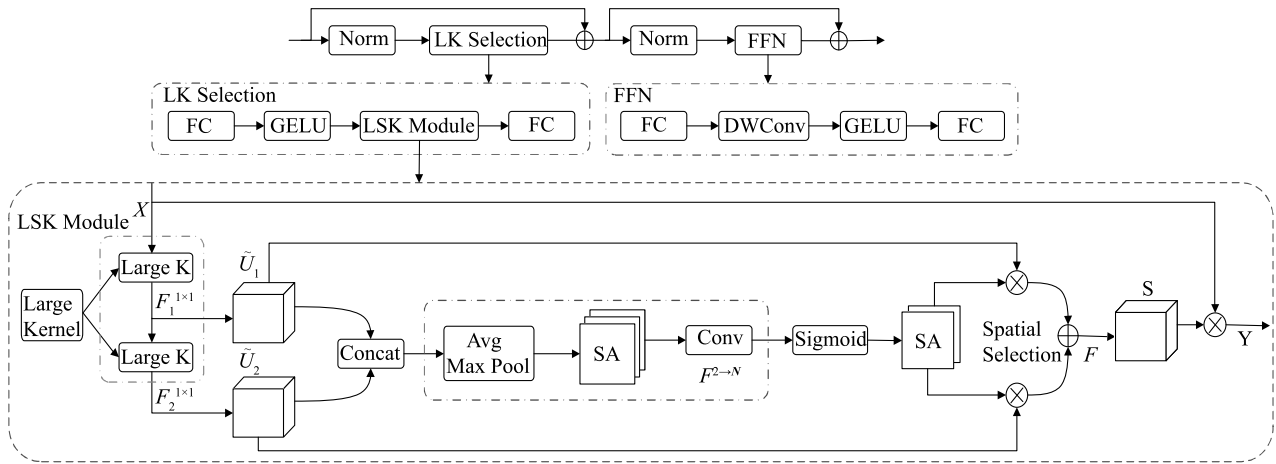
量和参数量。序列中,第 i 次深度可分离卷积的核大小(k)、扩张率(d)和接受野(RF)满足以下递推关系:

$$k_{i-1} \leq k_i; d_1 = 1, d_{i-1} < d_i \leq RF_{i-1} \quad (1)$$

$$RF_1 = k_1, RF_i = d_i(k_i - 1) + RF_{i-1}$$

式中, k_{i-1} 为第 $i-1$ 次深度可分离卷积核大小; k_i 为第 i 次深度可分离卷积核大小; d_1 为初始扩张率; d_{i-1} 为第 $i-1$ 次扩张率; d_i 为第 i 次扩张率; RF_{i-1} 为第 $i-1$ 个感受野; RF_i 为第 i 个感受野。

这种设计保证了感受野的快速扩展,同时通过



LK Selection: 大内核选择模块; FC: 全连接层; GELU: 激活函数; LSK Module: 大内核选择子模块; Norm: 规范化; FFN: 前馈网络; DWConv: 深度可分离卷积; Large Kernel: 大内核模块; Large K: 大型内核; Concat: 融合; Avg Max Pool: 平均池化和最大池化; SA: 自注意力机制; Conv: 卷积处理; Sigmoid: 激活函数; Spatial Selection: 空间选择模块。

图 5 大选择性核网络 (LSKNet) 结构

Fig.5 The structure of the large selective kernel network (LSKNet)

限制最大扩张率避免了特征映射间出现间隙,显著减少了参数量^[25]。在特征提取过程中,模型通过不同尺度的感受野对输入特征(X)进行逐层分解,获取多尺度上下文信息。分解公式如下:

$$U_0 = X, U_{i+1} = F_i^{dw}(U_i) \quad (2)$$

$$\tilde{U}_i = F_i^{1 \times 1}(U_i), \text{ for } i \text{ in } [1, N] \quad (3)$$

式中, U_0 为初始输入; X 为输入特征; U_{i+1} 为第 $i+1$ 次输入; U_i 为第 i 次输入; F_i^{dw} 为第 i 次深度可分离卷积操作; \tilde{U}_i 为 U_i 第 i 次经过 1×1 卷积变换的结果; $F_i^{1 \times 1}$ 为第 i 次 1×1 卷积操作; $[1, N]$ 为第 1 层到第 N 层。

LSKNet 通过空间核选择机制,从不同尺度的大卷积核中筛选出对特征映射最具有信息量的空间区域,具体步骤如下:

(1) 将不同感受野对应的卷积核所提取的特征图拼接在一起,形成一个包含多尺度信息的特征向量:

$$\tilde{U} = [\tilde{U}_1; \dots; \tilde{U}_i] \quad (4)$$

式中, \tilde{U} 为串接后的特征表示; \tilde{U}_i 为第 i 个特征表示。

(2) 对融合特征执行通道平均池化和最大池化操作,将得到的双通道池化特征通过卷积层 $F^{2 \rightarrow N}(\cdot)$ 映射为 N 个空间注意力图,利用 Sigmoid 激活函数为每个解耦的大卷积核生成独立的的空间选择

掩膜,将解耦的大卷积核序列与对应的空间选择掩膜进行加权处理,并通过 $F(\cdot)$ 融合获得关注特征 S 。计算公式如下:

$$SA_{avg} = P_{avg}(\tilde{U}) \quad SA_{max} = P_{max}(\tilde{U}) \quad (5)$$

$$\hat{S} = F^{2 \rightarrow N}(SA_{avg}; SA_{max}) \quad (6)$$

$$\tilde{S} = \sigma(\hat{S}) \quad (7)$$

$$S = F[\sum_{i=1}^N (\tilde{S}_i \cdot \tilde{U}_i)] \quad (8)$$

式中, SA_{avg} 为平均池化结果; P_{avg} 为平均池化操作; SA_{max} 为最大池化结果; P_{max} 为最大池化操作; \tilde{U} 为特征表示; $F^{2 \rightarrow N}$ 为将 2 个通道的池化特征变换为 N 个空间注意力图操作; \hat{S} 为经过 $F^{2 \rightarrow N}$ 操作后的特征表示; σ 为激活函数; \tilde{S}_i 为第 i 个池化特征; \tilde{S}_i 为 \hat{S}_i 经过激活函数(σ)处理后的特征表示; S 为关注特征; F 为卷积层融合操作; $\sum_{i=1}^N (\tilde{S}_i \cdot \tilde{U}_i)$ 为 \tilde{S}_i 和 \tilde{U}_i 2 个特征在 $i=1$ 到 $i=N$ 层的所有项求和。

(3) 将输入特征(X)和注意力特征(S)进行逐元素相乘,获得输出特征。计算公式如下:

$$Y = X \cdot S \quad (9)$$

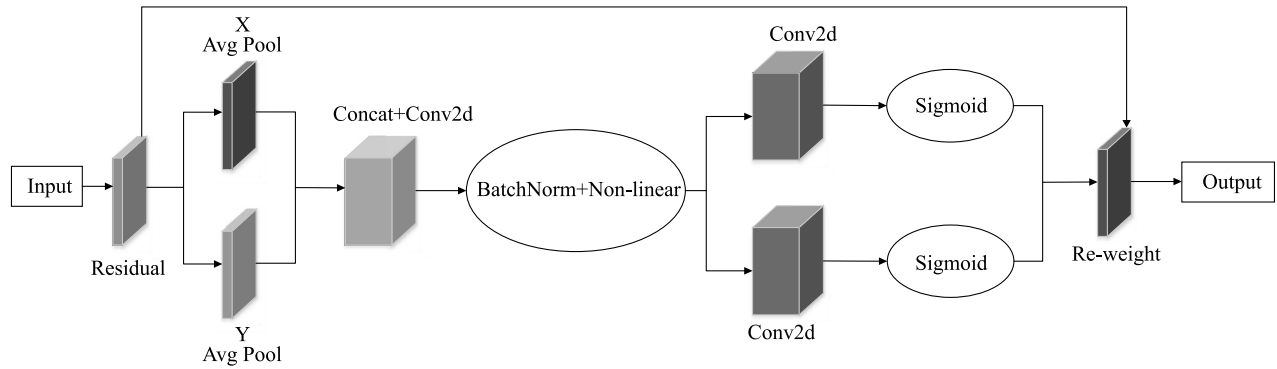
式中, Y 为输出特征; X 为输入特征; S 为关注特征。

LSKNet 通过动态调整感受野范围,有效整合遥感图像的背景先验信息,显著提升了模型的多尺度上下文信息捕获能力、小目标病害特征的提取精度、

无人机视角下稻曲病的识别准确率。

1.3.2.2 坐标注意力机制(CA)引入 自然环境下,无人机遥感采集的水稻病害图像存在复杂背景(如健康的水稻叶片、健康的稻穗、阴影等)干扰问题。由于稻曲病在图像中表现为小目标,随着网络层数的加深,病害特征容易被大量背景信息淹没而逐渐

丢失,导致模型识别精度下降。为解决这一问题,本研究在特征提取网络中引入了坐标注意力机制(CA)。该机制能够获取特征图像的位置信息和通道间关系,从而增强模型对稻曲病区域的关注,减少复杂背景的干扰。坐标注意力机制模块结构如图6所示。



Input:输入;Residual:残差连接;X Avg Pool:水平方向的全局平均池化;Y Avg Pool:垂直方向的全局平均池化;Concat:拼接水平和垂直方向;BatchNorm:批量归一化;Non-linear:非线性激活函数;Conv2d:分解为两个方向的卷积操作;Sigmoid:激活水平方向和垂直方向的注意力权重;Re-weight:将注意力权重与原始特征相乘;Output:加权后的输出特征图。

图6 坐标注意力机制(CA)模块结构

Fig.6 The structure of the coordinate attention mechanism (CA) module

坐标注意力机制通过坐标信息嵌入和坐标注意力生成将输入特征图中的目标位置信息嵌入通道注意力中。首先,对输入特征图分别沿水平和垂直方向进行平均池化,获得 $(H, 1)$ 和 $(1, W)$ 的位置信息。随后,将这些位置信息与通道注意力结合,生成具有空间感知能力的注意力图。该机制保留了空间特征细节,同时精确捕捉目标位置信息,使模型能够准确定位病害区域。计算公式如下:

$$z_c^H(H) = \frac{1}{W} \sum_{0 \leq i < W} x_c(H, i) \quad (10)$$

$$z_c^W(W) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, W) \quad (11)$$

式中, $z_c^H(H)$ 为高度 H 的全局平均池化结果; $z_c^W(W)$ 为宽度 W 的全局平均池化结果; $\frac{1}{W} \sum_{0 \leq i < W} x_c(H, i)$ 为在通道 c 上,对于给定的高度 H ,沿着宽度方向 i 对所有位置的特征值 $x_c(H, i)$ 进行平均池化; W 为宽度; $\frac{1}{H} \sum_{0 \leq j < H} x_c(j, W)$ 为在通道 c 上,对于给定的宽度 W ,沿着高度方向 j 对所有位置的特征值 $x_c(j, W)$ 进行平均池化; H 为高度。

CA提供精确的位置引导,而LSKNet则基于位置信息进行自适应核选择,这种协同作用显著提升了模型的识别精度。此外,CA输出的位置权重增强了模型的可解释性,使决策过程更加透明。

1.4 试验方法

1.4.1 试验平台与参数设置 本研究的模型训练与测试试验在配备Intel Core i7-11700K CPU(主频2.30 GHz)、NVIDIA GeForce RTX 4080 GPU和Windows10(64位)操作系统的计算机平台上进行。迭代次数(Epoch)设置为300,批处理大小(Batch size)设置为16。模型优化采用随机梯度下降算法(SGD),主干网络通过加载预训练权重进行初始化,初始学习率设置为0.01,整个模型基于PyTorch深度学习框架实现,使用Python编程语言开发。

1.4.2 评价指标 为了评估模型性能,本研究采用精准度(P)、召回率(R)和交并比阈值为0.50时的平均精度值均值(mAP_{50})3个通用评价指标。检测结果的判定标准为:当预测边界框与真实边界框的交并比(IoU)超过阈值0.5时,判定为正样本;否则判定为负样本。

2 结果与分析

2.1 LSKNet 模块和 CA 模块对模型的影响

基于自制的水稻稻曲病数据集验证 LSN-YOLOv8 中 LSKNet 模块和 CA 模块的有效性。如表 1 所示,与 YOLOv8 模型相比,YOLOv8+LSKNet 模型精准度、召回率和 mAP_{50} 分别提高了 10.7 个百分点、3.4 个百分点和 13.8 个百分点,表明 LSKNet 模块通过动态调整感受野能有效增强模型对小目标特征的提取能力。与 YOLOv8 模型相比,YOLOv8+CA 模型精准度和 mAP_{50} 分别提高了 2.8 个百分点和 0.4 个百分点,而召回率降低了 3.3 个百分点。表明 CA 模块能够提升定位精度,但可能漏掉一些真正的正样本。与 YOLOv8 模型相比,LSN-YOLOv8 模型的精准度提高了 13.5 个百分点,召回率提高了 11.5 个百分点, mAP_{50} 提高了 14.9 个百分点,表明 LSKNet 模块和 CA 模块的协同作用能够显著提升模型对小目标特征的关注能力。

表 1 大选择性核网络 (LSKNet) 和坐标注意力机制 (CA) 模块消融试验结果

Table 1 Results of ablation experiments on the large selective kernel network (LSKNet) and coordinate attention mechanism (CA) module

模型	精准度 (%)	召回率 (%)	mAP_{50} (%)
YOLOv8	81.3	75.8	77.4
YOLOv8+LSKNet	92.0	79.2	91.2
YOLOv8+CA	84.1	72.5	77.8
LSN-YOLOv8	94.8	87.3	92.3

YOLOv8:原始模型;LSKNet:大选择性核网络;CA:坐标注意力机制;LSN-YOLOv8:本研究提出的模型。 mAP_{50} :交并比阈值为 0.50 时的平均精度值均值。

2.2 不同模型识别性能对比

进一步将 LSN-YOLOv8 模型和主流检测模型 Faster R-CNN、YOLOv5、YOLOv7 和 YOLOv8 分别进行对比。如图 7 所示,YOLOv5 模型能够识别图像中形态特征较完整的病害目标,但对被健康叶片遮挡的病害目标存在重复识别的情况。YOLOv7 模型较好地解决了重复识别和错误识别的问题,但其识别精度较低。YOLOv8 模型的漏识别率较低,但精度仍有待提高。Faster R-CNN 模型对病害的特征变化或尺度变化的适应性差,而病害表征与叶片特征相似度高,导致出现漏识别的

情况。LSN-YOLOv8 模型对不同尺度、不同发病阶段的病害均能实现准确识别,表明该模型具有更强的特征提取能力,在田间环境中表现出更好的适应性。


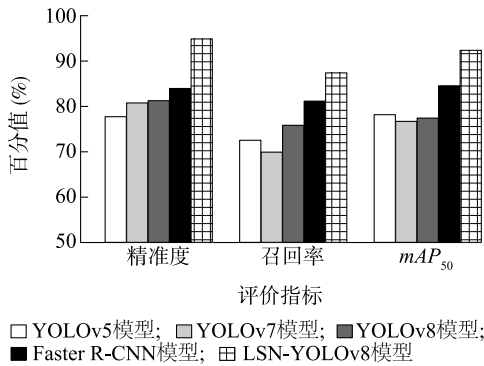


图 7 不同模型检测效果对比

Fig.7 Comparison of detection performance among different models

将 YOLOv5、YOLOv7、YOLOv8、Faster R-CNN 模型性能进行对比。如图 8 所示,LSN-YOLOv8 模型的精准度、召回率和 mAP_{50} 分别达到了 94.8%、87.3% 和 92.3%。与 YOLOv5 模型相比,LSN-YOLOv8 模型的精准度、召回率和 mAP_{50} 分别提高 17.0 个百分点、14.8 个百分点和 14.2 个百分点。与 YOLOv7 模型相比,LSN-YOLOv8 模型的精准度、召回率和 mAP_{50} 分别提高 14.0 个百分点、17.3 个百分点和 15.6 个百分点。与 YOLOv8 模型相比,LSN-YOLOv8 模型的精准度、召回率和 mAP_{50} 分别提高了 13.5 个百分点、11.5 个百分点和 14.9 个百分点。与 Faster R-CNN 模型相比,LSN-YOLOv8 模型的精准度、召回率和 mAP_{50} 分别提高了 10.8 个百分点、6.1 个百分点和 7.7 个百分点。



YOLOv5、YOLOv7、YOLOv8、Faster R-CNN 为经典目标检测模型；LSN-YOLOv8:本研究改进的模型；mAP₅₀:交并比阈值为 0.50 时的平均精度值均值。

图 8 不同模型检测性能对比

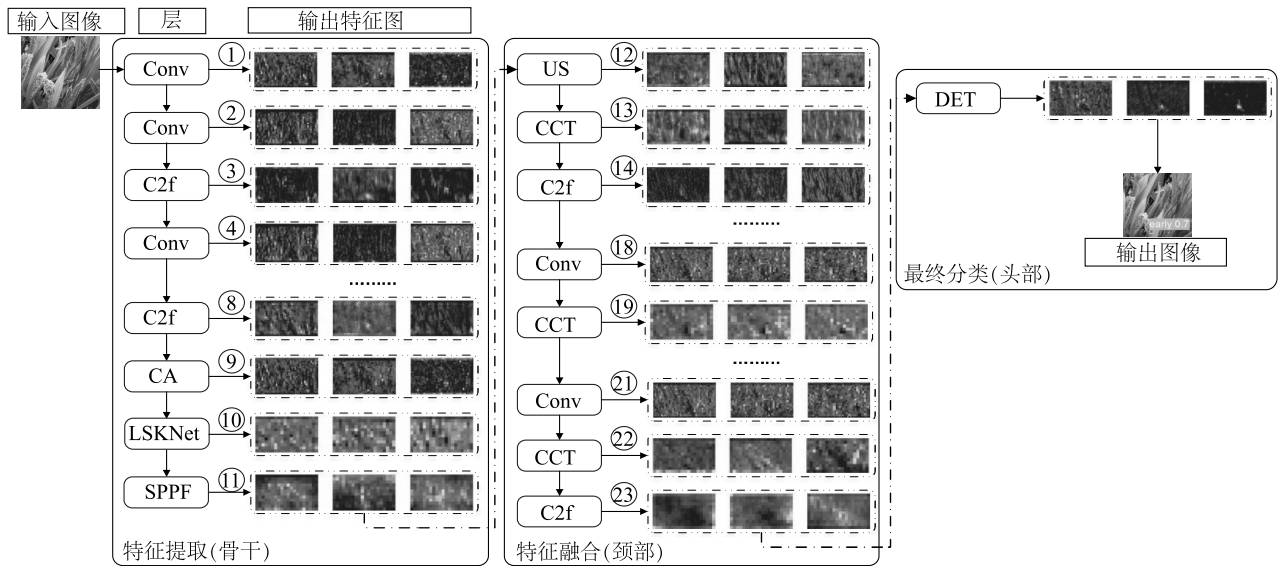
Fig.8 Comparison of detection performance among different models

2.3 模型关注特征可视化

为验证 LSN-YOLOv8 模型的性能,采用梯度加权类激活映射 (Grad-CAM) 技术对 LSN-YOLOv8 模

型决策过程进行可视化分析。具体为,从模型输出层获取水稻稻曲病的预测信息,沿着梯度传播路径将信息传递至网络前端各层。在此过程中,预测信息以梯度权重的形式被分配到每一层的特征图上,最终生成一系列针对水稻稻曲病目标的热力图。这些热力图直观地展示了模型在识别过程中所关注的关键特征区域,清晰地揭示了模型的预测逻辑和决策依据。

如图 9 所示,在第 9 层的坐标注意力模块 (CA) 能够有效捕捉病害图像的位置信息,并对不同区域赋予差异化的关注权重,为后续 LSKNet 模块的特征提取提供了良好的空间引导。第 10 层的大选择性核网络 (LSKNet) 则在 CA 模块定位的基础上,对重点区域实现了像素级的特征增强;而 C2f 模块在整个可视化过程中展现出平滑的特征过渡能力,使得病害特征的呈现更加自然连贯。整体可视化结果表明,LSN-YOLOv8 模型不仅实现了对病害区域的精确定位,其决策过程也具有好的可解释性。



Conv:卷积层;C2f:特征提取模块;CA:坐标注意力模块;LSKNet:大选择性核网络;SPPF:空间金字塔池化模块;US:上采样;CCT:融合;DET:检测输出。

图 9 模型关注特征热力图

Fig.9 Heatmap of model attention features

利用 Grad-CAM 技术对 YOLOv8 和 LSN-YOLOv8 进行可视化分析,如图 10 所示,YOLOv8 模型对关键病害区域的关注程度不足,并且存在对非

病害区域的关注。相比之下,LSN-YOLOv8 模型在保持全局关注的同时,能够更准确地聚焦于图像中的病害区域,对非病害区域的关注较少,这一表现完

全符合模型设计的预期目标。




图 10 改进前后模型关注特征的热力图对比

Fig.10 Comparison of heatmaps of model attention features before and after improvement

3 结论

水稻稻曲病检测是筛选和培育抗病水稻品种的关键环节。为实现在自然田间条件下水稻稻曲病的快速准确检测,本研究基于无人机遥感图像数据集,针对无人机视角下水稻稻曲病图像特征,以 YOLOv8 模型为基础,提出了一种改进的 LSN-YOLOv8 模型。该模型主要在以下 3 个方面进行了改进:在骨干网络中集成大选择性核网络 (LSK-Net);在主干网络特征提取阶段引入坐标注意力机制(CA)模块;采用 Grad-CAM 技术对模型决策过程的可视化分析。试验结果表明,LSN-YOLOv8 模型精度、召回率、 mAP_{50} 分别为 94.8%、87.3% 和 92.3%,均高于 YOLOv5、YOLOv7、YOLOv8、Faster R-CNN 等经典目标检测模型。梯度加权类激活映射(Grad-CAM)技术可视化分析结果表明,LSN-YOLOv8 模型能够更准确地聚焦于图像中的病害区域。本研究提出的 LSN-YOLOv8 模型可为稻曲病监测、病害防治和水稻抗病性鉴定提供技术支持。未来可以进一步探究 LSKNet 的轻量化设计,以实现模型在资源受限设备上的高效部署,从而进一步拓展其在实际应用场景中的适用性。

参考文献:

[1] BIN RAHMAN A N M R, ZHANG J H. Trends in rice research: 2030 and beyond[J]. Food and Energy Security, 2023, 12(2): e390.
[2] SUN W X, FAN J, FANG A F, et al. Ustilaginoidea virens; in-

sights into an emerging rice pathogen[J]. Annual Review of Phytopathology, 2020, 58:363-385.

- [3] QIU J, MENG S, DENG Y, et al. Ustilaginoidea virens; a fungus infects rice flower and threatens world rice production[J]. Rice Science, 2019, 26(4): 199-206.
[4] ZHOU L, MUBEEN M, IFTIKHAR Y, et al. Rice false smut pathogen; implications for mycotoxin contamination, current status, and future perspectives[J]. Frontiers in Microbiology, 2024, 15:1344831.
[5] ROY A, SAHU P K, DAS C, et al. Conventional and new-breeding technologies for improving disease resistance in lentil (*Lens culinaris* Medik) [J]. Frontiers in Plant Science, 2023, 13:1001682.
[6] 陆煜, 俞经虎, 朱行飞, 等. 基于卷积神经网络的轻量化水稻叶片病害识别模型[J]. 江苏农业学报, 2024, 40(2): 312-319.
[7] BUJA I, SABELLA E, MONTEDURO A G, et al. Advances in plant disease detection and monitoring: from traditional assays to in-field diagnostics[J]. Sensors, 2021, 21(6): 2129.
[8] ZENG W, LI M. Crop leaf disease recognition based on self-attention convolutional neural network [J]. Computers and Electronics in Agriculture, 2020, 172:105341.
[9] 杨锋, 姚晓通. 基于改进 YOLOv8 的小麦叶片病虫害检测轻量化模型[J]. 智慧农业(中英文), 2024, 6(1): 147-157.
[10] 李仁杰, 宋涛, 高婕, 等. 基于改进 YOLOv5 的自然环境下番茄患病叶片检测模型[J]. 江苏农业学报, 2024, 40(6): 1028-1037.
[11] WANG J, WANG P X, TIAN H R, et al. A deep learning framework combining CNN and GRU for improving wheat yield estimates using time series remotely sensed multi-variables [J]. Computers and Electronics in Agriculture, 2023, 206:107705.
[12] 鲍文霞, 吴育桢, 胡根生, 等. 基于改进 RDN 网络的无人机茶叶图像超分辨率重建[J]. 农业机械学报, 2023, 54(4): 241-249.
[13] HU G S, YAO P, WAN M Z, et al. Detection and classification of diseased pine trees with different levels of severity from UAV remote sensing images [J]. Ecological Informatics, 2022, 72:101844.
[14] BAO W X, ZHU Z Q, HU G S, et al. UAV remote sensing detection of tea leaf blight based on DDMA-YOLO [J]. Computers and Electronics in Agriculture, 2023, 205:107637.
[15] TETILA E C, MACHADO B B, ASTOLFI G, et al. Detection and classification of soybean pests using deep learning with UAV images [J]. Computers and Electronics in Agriculture, 2020, 179: 105836.
[16] 孙钰, 周焱, 袁明帅, 等. 基于深度学习的森林虫害无人机实时监测方法[J]. 农业工程学报, 2018, 34(21): 74-81.
[17] 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.
[18] 胡根生, 谢一帆, 鲍文霞, 等. 基于轻量化网络的无人机遥感图像中茶叶枯病检测方法[J]. 农业机械学报, 2024, 55(4): 165-175.

- [19] LI Y X, LI X, DAI Y M, et al. Lsknet: a foundation lightweight backbone for remote sensing[J]. *International Journal of Computer Vision*, 2024, 133: 1410-1431.
- [20] SONG Y F, ZHANG Z, SHAN C F, et al. Constructing stronger and faster baselines for skeleton-based action recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(2): 1474-1488.
- [21] JAHMUNAH V, NG E Y K, AN R S, et al. Explainable detection of myocardial infarction using deep learning models with Grad-CAM technique on ECG signals [J]. *Computers in Biology and Medicine*, 2022, 146: 105550.
- [22] SHEN L Y, LANG B H, SONG Z X. DS-YOLOv8-Based object detection method for remote sensing images [J]. *IEEE Access*, 2023, 11: 125122-125137.
- [23] SOLIMANI F, CARDELLICCHIO A, DIMAURO G, et al. Optimizing tomato plant phenoty detection: boosting YOLOv8 architecture to tackle data complexity [J]. *Computers and Electronics in Agriculture*, 2024, 218: 108728.
- [24] YANG S Z, WANG W, GAO S, et al. Strawberry ripeness detection based on YOLOv8 algorithm fused with LW-Swin Transformer [J]. *Computers and Electronics in Agriculture*, 2023, 215: 108360.
- [25] PAN P, GUO W L, ZHENG X M, et al. Xoo-YOLO: a detection method for wild rice bacterial blight in the field from the perspective of unmanned aerial vehicles [J]. *Frontiers in Plant Science*, 2023, 14: 1256545.

(责任编辑:成纾寒)