

靳新宇, 于复兴, 索依娜, 等. 基于改进 YOLOv8 的水稻病害检测算法[J]. 江苏农业学报, 2025, 41(3): 537-548.
doi: 10.3969/j.issn.1000-4440.2025.03.013

基于改进 YOLOv8 的水稻病害检测算法

靳新宇¹, 于复兴^{1,2}, 索依娜¹, 宋小明³

(1. 华北理工大学人工智能学院, 河北 唐山 063210; 2. 河北省工业智能感知重点实验室, 河北 唐山 063210; 3. 华北理工大学生命科学院, 河北 唐山 063210)

摘要: 为提升对水稻病害的检测性能, 本研究提出了一种改进的 YOLOv8n 检测算法。首先, 在颈部网络中引入 Slim-Neck 结构, 采用 GSConv (Ghost shuffle convolution) 降低计算成本, 同时结合基于一次性聚合方法设计的跨阶段部分网络模块 (VoVGSCSP) 简化计算过程和网络结构, 利用相似性感知注意力机制 (SimAM) 增强模型对病斑细微颜色变化的敏感性, 最后将自适应特征金字塔网络 (AFPN) 模块和头部结构相结合, 通过非相邻层的特征融合, 精准捕捉病害区域的颜色、形状与纹理。试验结果显示, 改进后的模型 YOLOv8n-SMAF 精确度、召回率和交并比阈值为 0.50 的平均精度 (mAP_{50}) 分别达到 85.1%、79.7% 和 83.7%。与原始模型 YOLOv8n 相比, 改进后的模型 YOLOv8n-SMAF 精确度、召回率和 mAP_{50} 分别提高了 3.8 个百分点、4.5 个百分点和 2.7 个百分点。与 SSD、YOLOv7-tiny、YOLOv10n 等其他主流模型相比, YOLOv8n-SMAF 模型具有更高的检测精度, 尤其在复杂场景下的检测任务中表现出优势。本研究改进的模型为水稻病害的早期预警和精准防治提供了技术支持。

关键词: 水稻病害; 目标检测; YOLOv8; 深度学习; 图像处理

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-4440(2025)03-0537-12

Rice disease detection algorithm based on improved YOLOv8

JIN Xinyu¹, YU Fuxing^{1,2}, SUO Yina¹, SONG Xiaoming³

(1. College of Artificial Intelligence, North China University of Science and Technology, Tangshan 063210, China; 2. Hebei Key Laboratory of Industrial Intelligent Perception, Tangshan 063210, China; 3. College of Life Sciences, North China University of Science and Technology, Tangshan 063210, China)

Abstract: To improve the detection performance of rice diseases, this study proposed an improved YOLOv8n detection algorithm. Firstly, the Slim-Neck structure was introduced into the neck network. Ghost shuffle convolution (GSConv) was adopted to reduce the computational cost. At the same time, the cross-stage partial network module based on the one-shot aggregation method (VoVGSCSP) was combined to simplify the calculation process and network structure. The similarity-aware activation module (SimAM) attention mechanism was utilized to enhance the model's sensitivity to subtle color changes of disease spots. Finally, the adaptive feature pyramid network (AFPN) module was combined with the head structure. Through the feature fusion of non-adjacent layers, the color, shape, and texture of the diseased areas were accurately captured. The experimental results showed that the precision, recall, and mean average precision at an intersection over union threshold of 0.50 (mAP_{50}) of the improved model YOLOv8n-SMAF reached 85.1%, 79.7%, and 83.7% respectively. Compared with the original model YOLOv8n, the precision, recall, and mAP_{50} of the improved model YOLOv8n-SMAF in-

creased by 3.8 percentage points, 4.5 percentage points, and 2.7 percentage points respectively. Compared with other mainstream models such as SSD, YOLOv7-tiny and YOLOv10n, the YOLOv8n-SMAF model had higher detection accuracy, especially showing advantages in detection tasks in complex scenarios. The improved model in this

收稿日期: 2024-08-31

基金项目: 国家自然科学基金项目 (32172583)

作者简介: 靳新宇 (2001-), 女, 河北承德人, 硕士研究生, 研究方向为深度学习、图像处理、目标检测。(E-mail) 767339849@qq.com

通讯作者: 索依娜, (E-mail) suoyina203@126.com

study provides technical support for the early warning and precise prevention and control of rice diseases.

Key words: rice diseases; target detection; YOLOv8; deep learning; image processing

水稻是中国重要的粮食作物,其种植面积约占全国耕地总面积的 1/4^[1]。然而,水稻在生长发育过程中易受多种病害侵袭,严重影响其质量和产量^[2]。传统的人工病害识别方法效率低且主观性较强,而计算机视觉技术的发展为水稻病害的自动检测提供有效的解决方案^[3]。

决策树、支持向量机(SVM)^[4]和 K-最近邻(KNN)^[5]等机器学习算法已在水稻病害识别中被广泛应用。尽管这些方法训练速度快,但其性能受限于训练数据质量和数量^[6]。路阳等^[7]提出了一种基于超绿特征分割和主成分分析的病害识别方法,通过提取病斑的颜色和形状特征,并结合改进的支持向量机算法,显著提高了模型对水稻稻瘟病的识别准确率。Javidan 等^[8]采用 K-means 聚类算法实现了对病害的自动诊断。然而,传统机器学习方法只能处理小规模数据,无法自动学习特征之间的复杂关系,导致其识别效率和准确率难以满足实际应用需求。

随着计算机视觉和深度学习技术的不断发展,人工智能在农业领域的应用日益广泛,尤其在病害检测和识别方面展现出巨大潜力。基于深度学习的目标检测方法分为单阶段检测方法和双阶段检测方法两类。单阶段检测方法包括 YOLO 系列^[9-12]、SSD^[13]和 EfficientDet^[14],这些方法将目标框生成与特征提取合并为一步,无需生成候选框,因此识别速度更快,实时性更强。双阶段检测方法包括 Mask R-CNN^[15]和 Faster R-CNN^[16]。双阶段检测方法需要先生成候选框,再进行卷积运算,该方法识别速度较慢,实时性差。李志良等^[17]提出了一种基于 YOLOv8n 的轻量化玉米害虫识别算法,该算法融合了 EfficientNet-B0 轻量级网络和深度可分离卷积结构,有效减少了模型的参数量和计算复杂度,同时在网络的颈部结构中引入 RepVGG 模块,用于整合多分支特征,并采用 MP-DIoU 损失函数来提高预测框的精度。Priya 等^[18]在 YOLOv8 模型上引入轻量级头部架构和相似性感知注意力机制(SimAM),显著增强了模型在复杂环境下的特征提取能力。Wang 等^[19]提出了一种基于 YOLOv8 的植物病害识别算法,通过引入全局注意力机制(GAM)和感受野注意力卷积(RFACConv),进一步提升了特征处理能力和网络性能。

尽管上述改进提升了 YOLO 系列模型的性能,但改进后的模型仍存在一定的局限性。李志良等^[17]改进的模型在轻量化和精度提升方面取得了较好的平衡,但模型在极端光照和复杂背景下的稳定性仍需进一步验证。Priya 等^[18]等通过引入注意力机制增强了特征提取能力,但在复杂自然环境中对细节特征的处理仍存在不足。Wang 等^[19]提升了模型的特征处理能力,但其采用的全局注意力机制可能对局部特征处理不够精准,感受野注意力卷积(RFACConv)的计算复杂度较高,可能影响模型的实际部署效率。综上,现有方法在复杂环境下细节特征提取和计算效率仍存在不足,需要进一步优化,以期使拟对 YOLOv8n 进行结构优化,以降低其计算复杂度,同时提高模型在复杂环境下的目标检测精度以期水稻病害的早期预警和精准防治提供技术支持。

1 材料与方法

1.1 图像数据集和预处理

1.1.1 数据采集 试验数据均来源于公开的网络数据集,包括稻瘟病、褐斑病、枯心病、霜霉病、稻曲病和纹枯病 6 种常见病害,同时以健康水稻作为对照。部分水稻病害图像如图 1 所示。




图 1 部分水稻病害图像

Fig.1 Images of some rice diseases

1.1.2 数据预处理与增强 数据集的质量直接影响模型的鲁棒性和泛化能力。为了提高数据集的多

样性和质量,本研究采用一系列数据增强方法,包括旋转、添加椒盐噪声和高斯噪声等。如图 2 所示,数据集涵盖了不同光照条件(强光和弱光)和不同拍摄角度(正面、侧面和俯视)的图像。使用 Labellmg 工具对图像数据进行病害位置和类别的标注,并将标注信息保存为 txt 格式的文件。数据集按 7 : 2 : 1 的数量比例划分为训练集、测试集和验证集。

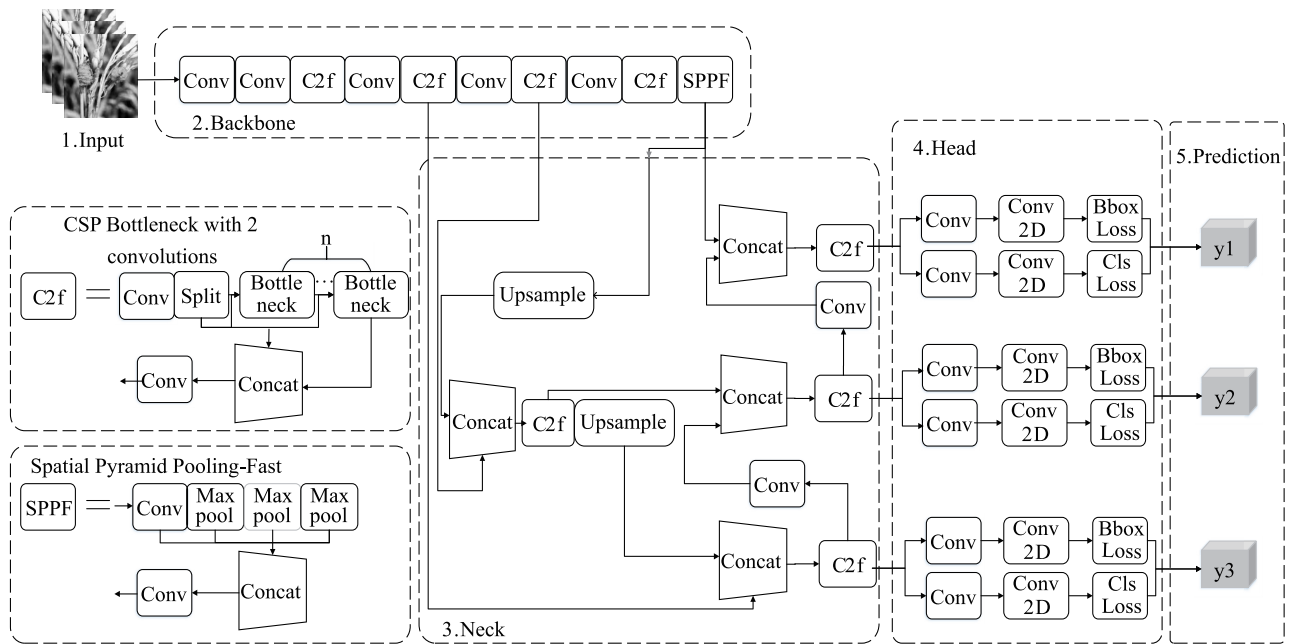


图 2 不同环境下收集的病害图像

Fig.2 Disease images collected under different environmental conditions

1.2 YOLOv8n 模型

YOLOv8n 是 YOLO 系列的一种轻量化版本^[20-22]。其基本原理是将输入图像划分为多个网格单元,并检测每个单元中心位置的物体^[23]。如图 3 所示,YOLOv8n 由 3 个主要部分组成:主干网络、颈部网络和头部结构。在主干网络部分,YOLOv8n 采用 Darknet-53 架构,该架构由 53 层卷积层组成,能够在提高特征提取效率的同时降低计算负担。颈部网络采用结合特征金字塔网络和路径聚合网络的深度学习架构(PAN-FPN)^[24],通过上采样操作融合主干网络提取的特征图,构建特征金字塔。头部结构采用解耦设计,将分类任务和检测任务分离到不同分支中,有效提升了模型的检测效率。



Input: 输入; Backbone: 主干网络; Concat: 融合; Upsample: 上采样; Neck: 颈部网络; C2f: 带有 2 个卷积的跨阶段部分聚合瓶颈层; Split: 分割模块; Bottleneck: 瓶颈结构; SPPF: 空间金字塔池化模块; Head: 头部结构; BboxLoss: 边界框回归损失函数; ClsLoss: 分类损失函数; Conv: 卷积操作; Max pool: 最大池化; Conv2D: 2 维卷积操作; Prediction: 预测部分; y1、y2、y3: 模型在 3 种不同尺度上生成的输出。

图 3 YOLOv8n 结构框架

Fig.3 YOLOv8n structural framework

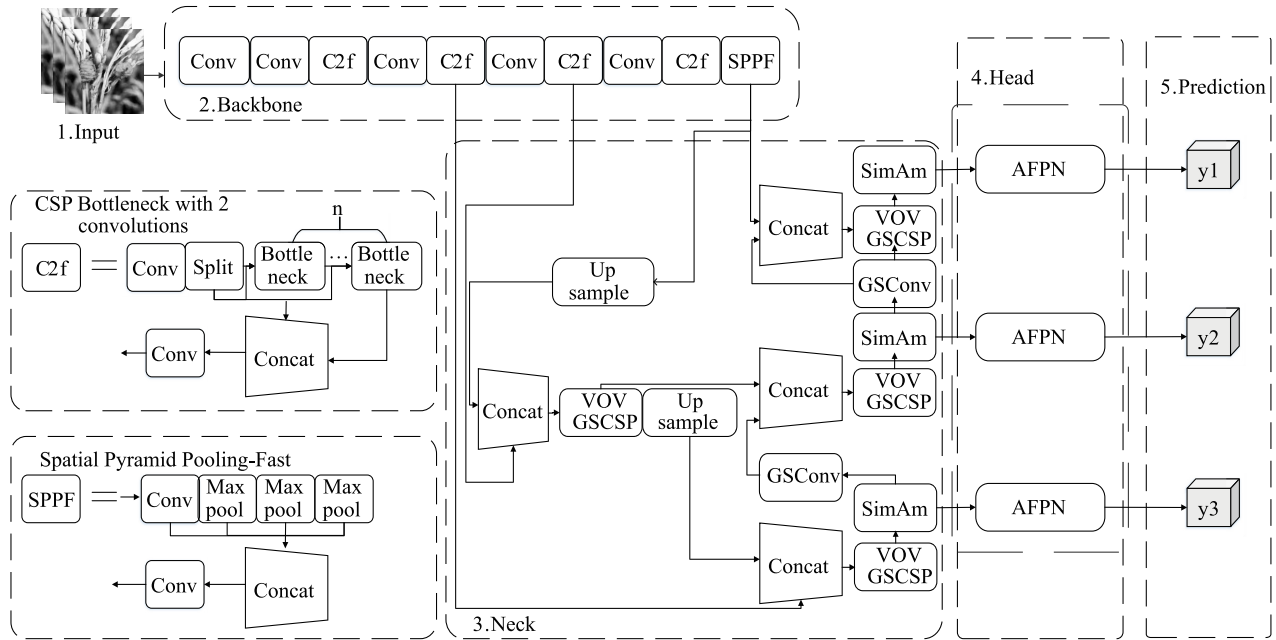
1.3 YOLOv8n-SMAF 模型

针对 YOLOv8n 在复杂环境(如光照强度变化、泥土干扰等)下存在的检测精度不足和收敛速度较慢等问题,本研究提出了一种改进模型 YOLOv8n-

SMAF。如图 4 所示,该模型通过以下 3 个方面的创新提升了水稻病害检测性能。首先,本研究采用细颈结构(Slim-Neck)优化颈部网络,在减少模型参数量和计算复杂度的同时,显著增强了模型对稻瘟病

和褐斑病病斑颜色及纹理特征的提取能力;其次在颈部网络中引入相似性感知注意力机制(SimAM),使模型聚焦任务相关特征,增强了对枯心病和霜霉病多种特征的识别能力;在头部结构中引入自适应

特征金字塔网络(AFPN)结构,支持非相邻层之间的直接交互,改善了模型对稻曲病和纹枯病等具有复杂特征病害的检测效果。改进后的YOLOv8n-SMAF具有更高的精度和效率。



Input:输入;Backbone:主干网络;Concat:融合;Upsample:上采样;Neck:颈部网络;C2f:带有2个卷积的跨阶段部分聚合瓶颈层;Split:分割模块;Bottleneck:瓶颈模块;SPPF:空间金字塔池化模块;Head:头部结构;Conv:卷积处理;Max pool:最大池化;VOVGSCSP:基于一次性聚合方法设计的跨阶段部分网络模块;GSCConv:结合了幽灵(Ghost)模块和通道重排(Channel Shuffle)操作的卷积;SimAM:相似性感知注意力机制;AFPN:自适应特征金字塔网络;Prediction:预测部分;y1、y2、y3:3种不同尺度的输出。

图4 YOLOv8n-SMAF 结构框架

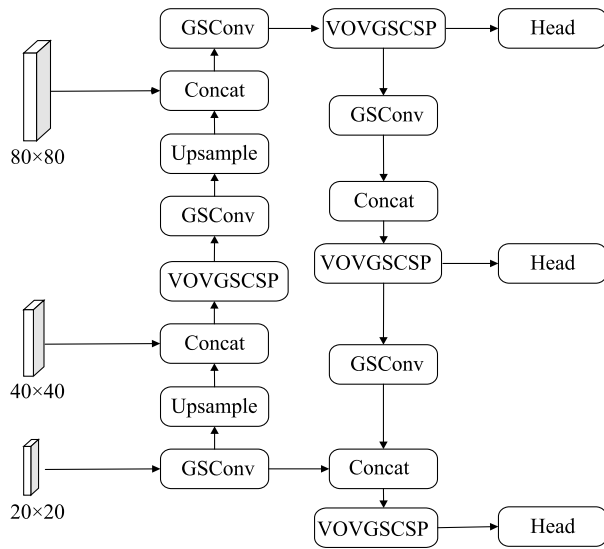
Fig.4 YOLOv8n-SMAF structural framework

1.3.1 细颈结构(Slim-Neck) 在水稻病害检测中,病害特征的复杂性导致卷积层的堆叠,从而增加了特征提取模块的体积和参数量。为解决这一问题,本研究引入细颈结构(Slim-Neck),该结构针对水稻病害的多样化特征,优化模型特征提取过程,进而提高计算效率。如图5所示,Slim-Neck由2个主要模块组成:GSCConv模块和基于一次性聚合方法(VoV)设计的跨阶段部分网络(GSCSP),即VoVGSCSP^[25]。通过高效的降维策略,该方案能够减少冗余特征,同时保留关键的判别信息,从而在提高特征提取效率的同时提升模型精度。

传统的卷积神经网络(CNN)在处理高维特征图时,常面临计算复杂度和参数量过大的问题,为此本研究采用GSCConv模块替代传统的标准卷积(Conv)。与标准卷积不同,GSCConv将输入特征图

的通道分为两部分,一部分通过深度可分离卷积(DSC)进行处理,另一部分直接输出,并与深度可分离卷积的输出进行拼接(Concat)。GSCConv模块的详细结构如图6所示,SC和DSC的计算流程如图7所示。

具体过程为输入特征图的通道数(C_1)经过 1×1 卷积操作后,被压缩为输出特征图的通道数(C_2)的一半($C_2/2$),随后通过 5×5 深度可分离卷积(DW-Conv)提取空间特征,DWConv的输出与 1×1 卷积的结果在通道维度进行拼接,形成特征图X2。接着,通过通道重排(Shuffle)对X2进行处理,以增强特征信息的混合效果。最后,重排后的特征图被拼接并输出,确保输出的特征图在表达能力上与传统卷积相当。通过这一设计,GSCConv在显著降低计算成本的同时,实现了模型轻量化且保持了模型精度。



VOVGSCSP:基于一次性聚合方法设计的跨阶段部分网络模块;
GSConv:结合了幽灵(Ghost)模块和通道重排(Channel Shuffle)
操作的卷积;Concat:融合;Upsample:上采样;Head:头部结构。

图5 细颈(Slim-Neck)结构

Fig.5 Slim-Neck structure

SC、DSC 及 GSConv 的时间复杂度计算公式如下:

$$Time_{SC} \sim O(W \times H \times K_1 \times K_2 \times C_1 \times C_2) \quad (1)$$

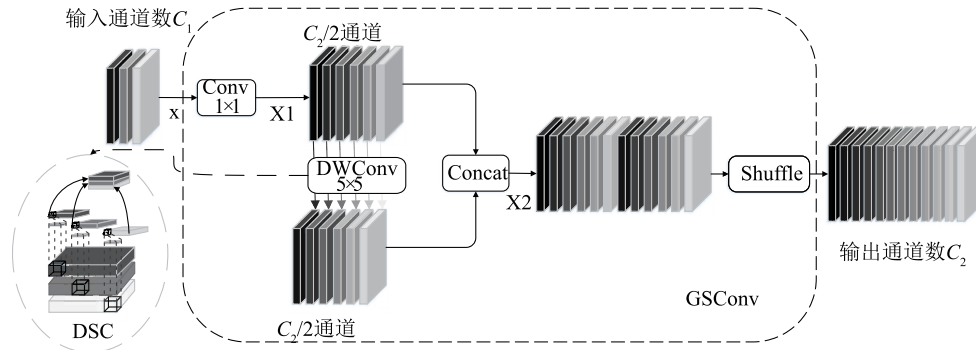
$$Time_{DSC} \sim O(W \times H \times K_1 \times K_2 \times 1 \times C_2) \quad (2)$$

$$Time_{GSConv} \sim O[W \times H \times K_1 \times K_2 \times \frac{C_2}{2} (C_1 + 1)] \quad (3)$$

式中, W 、 H 分别为输出特征图的宽度和高度;
 $K_1 \times K_2$ 为卷积核的大小; C_1 为输入特征图的通道数;
 C_2 为输出特征图的通道数。

时间复杂度是衡量模型计算负担的关键指标。
通过对比公式(1)、公式(2)、公式(3)可以发现,
GSConv 在轻量级模型中具有较优的性能。

为进一步提升模型性能, Slim-Neck 在 GSConv
基础上引入 VoVGSCSP 模块。该模块适用于处理
水稻病害图像的多样化特征, 包括稻瘟病的斑点扩
展、褐斑病和枯心病的病斑形态差异, 以及霜霉病和
稻曲病在高湿条件下的纹理与颜色变化。




Conv 1×1 : 1×1 卷积; DWConv 5×5 : 5×5 深度可分离卷积; Shuffle: 通道重排; Concat: 融合; DSC: 深度可分离卷积; C_1 : 输入特征图的通道数; C_2 :
输出特征图的通道数; $C_2/2$: 输出特征图的通道数的一半, 经 1×1 卷积操作后, 特征图的通道数被压缩为 C_2 的一半。GSConv: 结合了幽灵
(Ghost) 模块和通道重排(Channel shuffle) 操作的卷积。

图6 GSConv 结构

Fig.6 GSConv structure

如图8所示, 首先, 输入特征图通过 1×1 卷积降
维, 将通道数从 C_1 压缩为 $C_2/2$, 以减少计算量并保
留关键信息。然后, 降维后的特征图被分成 2 条并
行支路。其中一条支路直接输出降维后的特征图。
另一条支路通过 GSbottleneck 结构进行处理。GS-
bottleneck 结构由 2 条路径串联组成, 一条路径包含
2 个 GSConv 模块的串联, 另一条路径包含一个 1×1
卷积操作。在串联路径中, 第一层使用 1×1 GSConv
进行通道分离, 第二层通过 3×3 GSConv 提取深层特
征, 在此过程中, GSConv 模块利用深度可分离卷积

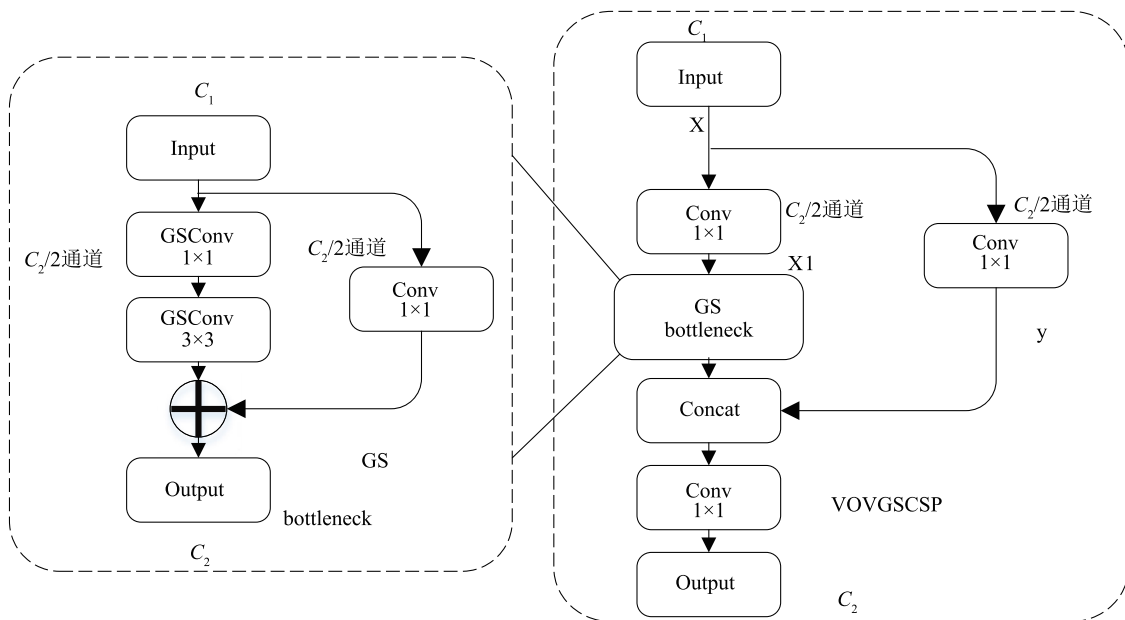
在通道维度上高效重组特征图, 有助于捕捉病斑的
细节和全局信息, 从而提升对稻瘟病、褐斑病等不
同形状病斑的识别能力。2 条路径的特征图在通道
维度上拼接后, 与第一条支路的输出进一步拼接, 这
种融合方式增强了模型对浅层和深层特征的感知能
力, 提升了对水稻病害不同尺度特征的识别能力。
最终, VoVGSCSP 模块通过拼接和 1×1 卷积操作
融合来自浅层和深层网络的特征信息, 增强模型对
多尺度特征的感知能力, 显著提高了水稻病害图像
的识别精度。



Input: 输入; Output: 输出; Kernel: 卷积核; Channels: 通道; Single channel: 单通道。 C_1 : 输入特征图; C_2 : 输出特征图。

图 7 标准卷积 (SC) 和深度可分离卷积 (DSC) 的计算流程

Fig.7 The computational processes of standard convolution (SC) and depthwise separable convolution (DSC)

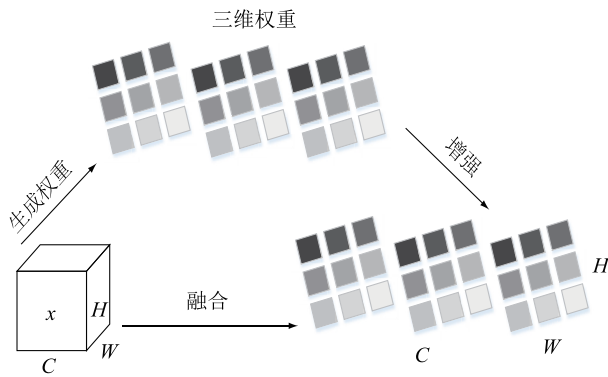


Input: 输入; Conv 1×1 : 1×1 卷积; GSConv 1×1 : 1×1 GSConv 卷积; GSConv 3×3 : 3×3 GSConv 卷积; Concat: 融合; Output: 输出。 C_1 : 输入特征图的通道数; C_2 : 输出特征图的通道数; $C_2/2$: 经 1×1 卷积操作后, 特征图的通道数被压缩为 C_2 的一半。GSConv: 结合了幽灵 (Ghost) 模块和通道重排 (Channel shuffle) 操作的卷积。GSBottleneck: 结合 GSConv 的瓶颈结构。

图 8 基于一次性聚合方法设计的跨阶段部分网络模块 (VoVGSCSP) 结构

Fig.8 Structure of cross-stage partial network module based on one-shot aggregation method (VoVGSCSP)

1.3.2 相似性感知注意力机制 (SimAM) 针对水稻病害图像中因光照变化和病害类型差异导致的颜色、形状和纹理特征的显著变化问题,例如稻瘟病斑点在不同光照条件下呈现不同颜色,使得病害检测与识别面临较大挑战。如图 9 所示,本研究引入相似性感知注意力机制^[26],该机制通过计算特征图中每个神经元的三维(3D)注意力权重增强与水稻病害相关的关键区域特征,同时有效抑制无关的背景信息(如杂草和土壤)。这一过程无需引入额外参数,显著提升了模型在复杂背景下对水稻病害的识别能力。



W, H : 输出特征图的宽度和高度; C : 通道数。

图 9 相似性感知注意力机制 (SimAM) 结构

Fig.9 Structure diagram of similarity-aware attention mechanism (SimAM)

SimAM 通过标准化输入特征图,计算像素间的差异并生成注意力权重,进而对特征进行加权。首先,输入特征图 $x \in R^{B \times C \times H \times W}$,其中 B 为批次大小, C 为通道数, H 和 W 分别为特征图的高度和宽度。对于每个批次中的特征图,计算其空间均值 $\mu \in R^{B \times C \times 1 \times 1}$ 和方差 $\sigma^2 \in R^{B \times C \times 1 \times 1}$,得到标准化的特征图 $\hat{x} \in R^{B \times C \times 1 \times 1}$,计算公式如下:

$$\hat{x} = \frac{x - \mu}{\sqrt{\sigma^2 + \delta}} \quad (4)$$

式中, δ 是一个较小的平滑项,用于避免分母为零的情况。标准化后的特征图确保了各通道具有一致的空间尺度,从而能够衡量通道之间的局部差异。

计算每个通道上所有像素点 $x_{i,j} \in \hat{x}$ 的相似度 ($Y_{i,j}$)。计算公式如下:

$$Y_{i,j} = \frac{x_{i,j}^2}{4 \left(\frac{1}{n-1} \sum_{k \neq i,j} x_k^2 + \delta \right)} + 0.5 \quad (5)$$

式中, n 为特征图的像素点数目; (i,j) 为坐标, $x_{i,j}$ 为像素点 (i,j) ; x_k 为与 $x_{i,j}$ 不同的其他像素点相似度 $Y_{i,j}$ 将 $x_{i,j}$ 与其他像素点的平方差进行归一化,并加入偏置项 0.5,将每个空间位置的响应权重限制在 $[0,1]$ 范围内。然后将原始特征图 x 与相似度矩阵 Y 相乘,得到加权特征图 $Z \in R^{B \times C \times W \times G}$, $Z_{i,j} = x_{i,j} \times Y_{i,j}$ 。最后,通过 Sigmoid 激活函数对 Z 进行归一化,得到最终输出特征图。


1.3.3 融合自适应特征金字塔网络 (AFPN) 在水稻病害检测中,传统的金字塔注意力网络 (PAN) 在处理高层和底层特征交互时,通常需要经过多个中间尺度的特征传播,这一过程可能导致特征信息的丢失或退化,从而影响检测精度。水稻病害图像中包含了多种复杂特征,如褐斑病的褐色斑点、枯心病的枯萎区域等,这些特征在尺度和语义上存在显著差异,传统方法在处理这些病害特征时,往往存在一定的局限性。为解决这些问题,本研究采用了改进的金字塔网络结构——自适应特征金字塔网络 (AFPN)^[27],并将其与头部结构进行融合。AFPN 从颈部结构中提取的特征层 ($\{C3, C4, C5\}$) 按从低级到高级的顺序逐步融合。如图 10 所示,AFPN 首先融合低分辨率的底层特征 $C3$,接着逐步引入更高层次的特征 $C4$ 和 $C5$,形成多尺度特征集 $\{P3, P4, P5\}$ 。这一逐步融合的策略旨在初期处理底层特征,随后融合深层特征,并在最终阶段整合顶层特征,从而优化特征融合效果。

在 AFPN 中,采用自适应空间特征融合 (ASFF) 机制实现多层次特征融合,AFPN 通过为各层特征分配不同的空间权重,突出关键层次的重要性,从而减少不同对象间的干扰。其结构如图 11 所示。3 级特征的自适应空间融合公式如下:

$$y_{ij}(l) = \delta_{ij}(l) \times x_{ij}(1l) \times \beta_{ij}(l) \times x_{ij}(2l) \times \gamma_{ij}(l) \times x_{ij}(3l) \quad (6)$$

式中, $x_{ij}(nl)$ 表示从级别 n 到级别 l 的特征向量, $y_{ij}(l)$ 表示融合后的结果特征向量, $\delta_{ij}(l)$, $\beta_{ij}(l)$ 和 $\gamma_{ij}(l)$ 分别表示 3 个级别的特征在级别 l 处的空间权重,并且受到约束。约束公式如下:


$$\delta_{ij}(l) + \beta_{ij}(l) + \gamma_{ij}(l) = 1 \quad (7)$$



Head: 头部结构, C1~C5: 融合前特征值; P1~P5: 融合后特征值; Predict: 预测部分。

图 10 自适应特征金字塔网络 (AFP) 结构框架

Fig.10 The structural framework of the adaptive feature pyramid network (AFP)



ASF-1~ASF-3: 自适应空间特征融合 (ASF) 的具体结构。

图 11 自适应空间融合

Fig.11 Adaptive spatial fusion

在多级特征融合过程中, ASF 技术用于匹配不同级别特征的空间权重, 调整不同层次特征的影响力, 从而提高关键层的重要性, 并减少来自不同层的信息冲突。

1.4 试验环境

试验使用了 Pytorch 框架。Pytorch 是一个开源深度学习库, 提供了灵活直观的工具, 用于构建和训练深度神经网络模型。试验环境和参数设置如表 1 所示。

1.5 评价指标

模型性能评估在模型验证中尤为重要, 为了选择最优模型, 本研究采用精确率 (P)、召回率 (R)、平均精度值均值 (mAP) 作为评估模型性能的关键指标, 计算公式如下:

表 1 试验环境

Table 1 Experimental environment

试验环境	参数配置
操作系统	Windows 11
显卡 (GPU)	NVIDIA GeForce RTX 3060 Laptop GPU
深度学习框架	Torch 2.1.2
GPU 加速器	CUDA 12.1
编程语言	Python 3.11.7
编程软件	PyCharm Community Edition
训练轮次 (Epochs)	500
批量大小 (Batch)	16

$$P = \frac{TP}{TP+FP} \quad (8)$$

$$R = \frac{TP}{TP+FN} \quad (9)$$

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum AP}{N(c)} \quad (11)$$

式中, TP 为模型正确预测为正类且实际为正类的样本数; FN 为模型错误预测为负类但实际为正类的样本数; FP 为模型错误预测为正类但实际为负类的样本数; AP 为平均精度值; $N(c)$ 为类别总数。

$GFLOPS$ 为每 $1s$ 1×10^9 次浮点运算量。 $Param$ 为模型的参数量。 $GFLOPS$ 和 $Param$ 越低, 表明模型的复杂性和参数量越低。在目标检测系统中, 性能参数的优先级从高到低依次为 mAP 值、精确率和召回率。 mAP 能够综合考虑精确率和召回率, 减少单一指标对整体结果的影响, 因此是评估模型性能的核心指标。

2 结果与分析

2.1 引入模块的性能对比

为了评估各模块对 YOLOv8n 识别准确性的影响, 在相同的计算机配置和参数设置下进行消融试验。如表 2 所示, 与原始 YOLOv8n 模型相比, YOLOv8n+Slim-Neck 参数量下降 0.21 MB, mAP_{50} 提高 1.5 个百分点, 表明 Slim-Neck 模块通过高效的卷积操作、特征重组和通道压缩, 能够在减少计算量和参数量的同时有效提升模型的精度。与原始 YOLOv8n 模型相比, YOLOv8n+SimAM 参数量

仅上升 0.01 MB,交并比阈值为 0.5 的平均精度 (mAP_{50}) 提高 0.9 个百分点。尽管 SimAM 注意力机制的引入略微增加了复杂度、参数量,但其他性能指标均有所提升。与原始 YOLOv8n 模型相比,

YOLOv8n+AFPN 参数量仅上升 0.72 MB,而 mAP_{50} 提升 2.4 个百分点。表明利用 AFPN 改进头部结构后,模型可以更有效地处理和融合来自不同特征图的信息。

表 2 引入模块对比

Table 2 Comparison of introduced modules

模型	精确度 (%)	召回率 (%)	mAP_{50} (%)	$GFLOPS$ (G)	Param (MB)
YOLOv8n	81.3	75.2	81.0	8.0	3.00
YOLOv8n+Slim-Neck	86.3	74.0	82.5	7.3	2.79
YOLOv8n+SimAM	83.4	75.3	81.9	8.9	3.01
YOLOv8n+AFPN	83.5	77.6	83.4	11.3	3.72
YOLOv8n+Slim-Neck+SimAM	81.4	76.8	82.6	9.6	2.80
YOLOv8n+Slim-Neck+AFPN	83.7	78.4	82.5	9.7	3.37
YOLOv8n+SimAM+AFPN	82.2	79.0	82.4	11.3	3.73
YOLOv8n+Slim-Neck+SimAM+AFPN	85.1	79.7	83.7	9.6	3.37

mAP_{50} : 交并比阈值为 0.50 的平均精度; $GFLOPS$: 每 1 s 1×10^9 次浮点运算量; $Param$: 参数量; Slim-Neck: 细颈结构; SimAM: 相似性感知注意力机制; AFPN: 自适应特征金字塔网络。

本研究提出的 YOLOv8n+Slim-Neck+SimAM+AFPN 参数量为 3.37 MB, 仅比原始模型 YOLOv8n 参数量增加 0.37 MB, 但其他指标上均优于原始模型 YOLOv8n, 引入的各模块的协同作用进一步提升了模型的整体性能。

2.2 注意力机制的对比

为验证不同注意力机制对模型的影响, 基于 YOLOv8n+Slim-Neck+AFPN 分别引入 SE^[28]、CBAM^[29]、CAA^[30] 和 BRA^[31] 注意力机制, 与本研究使用的 Si-

mAM 注意力机制进行对比。如表 3 所示, 和引入 SimAM 注意力机制的模型相比, 引入 SE 注意力机制、BRA 注意力机制、CAA 注意力机制的模型参数量增加, 且 mAP_{50} 显著下降。和引入 SimAM 注意力机制的模型相比, 引入 CBAM 注意力机制的模型 mAP_{50} 略有上升, 但参数量显著增加。引入 SimAM 注意力机制的模型精确度、召回率显著高于引入其他注意力机制的模型, 参数量和浮点运算量显著低于引入其他注意力机制的模型。

表 3 注意力机制对比

Table 3 Comparison of attention mechanisms

模型	精确度 (%)	召回率 (%)	mAP_{50} (%)	$GFLOPS$ (G)	Param (MB)
YOLOv8n+Slim-Neck+ AFPN	83.7	78.4	82.5	9.7	3.37
YOLOv8n+Slim-Neck+ AFPN+SE	80.3	79.5	82.7	9.8	3.38
YOLOv8n+Slim-Neck+ AFPN+BRA	85.1	77.3	82.4	9.9	3.73
YOLOv8n+Slim-Neck+ AFPN+CAA	81.8	77.3	82.6	10.1	3.57
YOLOv8n+Slim-Neck+ AFPN+CBAM	83.5	78.7	83.8	9.7	3.47
YOLOv8n+Slim-Neck+ AFPN+SimAM	85.1	79.7	83.7	9.6	3.37

mAP_{50} : 交并比阈值为 0.50 的平均精度; $GFLOPS$: 每 1 s 1×10^9 次浮点运算量; $Param$: 参数量; YOLOv8n: 原始模型; Slim-Neck: 细颈结构; AFPN: 特征金字塔网络; SE: 压缩和激励注意力机制; BRA: 双层路由注意力机制; CAA: 上下文描点注意力机制; CBAM: 卷积块注意力机制; SimAM: 相似性感知注意力机制。

2.3 与其他模型的对比

为进一步验证所提出的模型的性能, 将 YOLOv8n-SMAF 与当前主流模型进行比较。如表 4 所示, SSD 模型和 Faster-RCNN 模型 mAP_{50} 明显低于

YOLOv8n-SMAF 模型, 浮点计算量和参数量明显高于 YOLOv8n-SMAF 模型。EfficientDet-B0 模型参数量明显高于 YOLOv8n-SMAF 模型, mAP_{50} 明显低于 YOLOv8n-SMAF 模型。与 EfficientDet-B0 模型相

比, YOLOv8n-SMAF 模型 mAP_{50} 提高了 2.1 个百分点。这是因为这些传统模型通常采用复杂的网络结构, 导致计算效率低, 参数量大且推理速度慢。

YOLOv5n 模型浮点计算量和参数量略低于 YOLOv8n-SMAF 模型, 然而 mAP_{50} 显著低于 YOLOv8n-SMAF 模型。与 YOLOv5n 模型相比, YOLOv8n-SMAF 模型 mAP_{50} 提高了 2.5 个百分点。YOLOv5n 虽然轻量, 但由于缺乏强大的注意力机制和细粒度特征融合能力, 在复杂场景和小目标检测中的表现欠佳。YOLOv6 模型浮点计算量和参数量显著高于 YOLOv8n-SMAF 模型, 且精确度、召回率、 mAP_{50} 显著低于 YOLOv8n-SMAF 模型。与 YOLOv6 模型相比, YOLOv8n-SMAF 模型精确度、召回率、 mAP_{50} 分别提高 4.5 个百分点、11.8 个百分点、7.8 个百分点。YOLOv6 在检测多目标时存在精度较低的问题。YOLOv7-tiny 模型浮点计算量和参数量显著高于 YOLOv8n-SMAF 模型, 且 mAP_{50} 显著低于 YOLOv8n-SMAF 模型。作为轻量版的 YOLOv7-tiny, 参数量以及复杂度仍高于本研究的 YOLOv8n-SMAF 模型, 且在大规模数据集上, YOLOv7-tiny 的精度较低。原始模型 YOLOv8n 浮点计算量和参数量略低于 YOLOv8n-SMAF 模型, 但精确度、召回率、 mAP_{50} 显著低于 YOLOv8n-SMAF 模型, 充分证明了改进的有效性。与 YOLOv8n 模型相比, YOLOv8n-SMAF 模型精确度、召回率、 mAP_{50} 分别提高 3.8 个百分点、4.5 个百分点、2.7 个百分点。YOLOv10n 模型浮点计算量和参数量略低于 YOLOv8n-SMAF 模型, 但精确度、召回率、 mAP_{50} 显著低于 YOLOv8n-SMAF 模型。与 YOLOv10n 模型相比, YOLOv8n-SMAF 模型精确度、召回率、 mAP_{50} 分别提高 1.1 个百分点、1.8 个百分点、1.3 个百分点。YOLOv10n 是较新的模型, 但对复杂场景下的小目标检测能力不足, 仍需进一步改进。

与改进模型 Tea-YOLOv5s^[10] 和 Maize-YOLO^[11] 相比, YOLOv8n-SMAF 模型的 mAP_{50} 分别提高了 1.6 个百分点和 7.4 个百分点, 同时浮点计算量和参数量显著下降, 表明本研究的模型的性能更佳。

为验证改进模型 YOLOv8n-SMAF 对水稻病害检测的准确性, 选取 6 种不同病害类别的图像进行测试。采用 EfficientDet-B0、YOLOv5n、YOLOv10n、Tea-YOLOv5s、原始模型 YOLOv8n 以及改进模型 YOLOv8n-SMAF 对验证集中的图像进行检测。如图 12 所示, EfficientDet-B0、YOLOv5n、YOLOv8n 和 Tea-

YOLOv5s 模型在检测强光下的露珠病时均存在漏检现象。且 EfficientDet-B0 模型在检测褐斑病时, 会漏检密集分布的小目标。YOLOv8n-SMAF 模型的精度高于其他模型, 尤其是在小目标和多目标的检测中表现出色。

表 4 不同模型性能对比


Table 4 Performance comparison of different models

模型	精确度 (%)	召回率 (%)	mAP_{50} (%)	GFLOPS (G)	Param (MB)
SSD	83.2	65.9	73.7	62.8	26.74
Faster-RCNN	68.4	76.8	72.9	121.4	28.34
EfficientDet-B0	80.7	74.4	81.6	2.5	7.90
YOLOv5n	84.2	71.9	81.2	7.1	2.51
YOLOv6	80.6	67.9	75.9	11.8	4.23
YOLOv7-tiny	77.1	70.7	77.7	13.2	6.03
YOLOv8n	81.3	75.2	81.0	8.0	3.00
YOLOv10n	84.0	77.9	82.4	7.9	2.59
Tea-YOLOv5s ^[10]	80.4	80.3	82.1	16.9	7.33
Maize-YOLO ^[11]	73.3	77.3	76.3	38.9	33.41
YOLOv8n-SMAF	85.1	79.7	83.7	9.6	3.37

SSD、Faster-RCNN、EfficientDet-B0、YOLOv5n、YOLOv6、YOLOv7-tiny、YOLOv10n 为当前主流目标检测模型; YOLOv8n: 本研究原始模型; Tea-YOLOv5s^[10]: 基于 YOLOv5s 改进的模型; Maize-YOLO^[11]: 基于 YOLOv7 改进的模型; YOLOv8n-SMAF: 本研究提出的模型。 mAP_{50} : 交并比阈值为 0.50 的平均精度; GFLOPS: 每 1 s 1×10^9 次浮点运算量; Param: 参数量。

3 结论

为提升 YOLOv8n 在水稻病害检测任务中的性能, 本研究在颈部网络中引入 Slim-Neck 结构, 采用 GSConv 降低计算成本, 同时结合 VoVGSCSP 模块简化计算过程和网络结构; 利用 SimAM 注意力机制增强模型对病斑细微颜色变化的敏感性; 此外, 将 AF-PN 模块与头部结构相结合, 支持非相邻层直接互动, 优化了特征融合效果, 减少了语义差异, 从而提升模型对病害图像中复杂形状和纹理特征的提取能力。试验结果表明, 与原始模型 YOLOv8n 相比, 改进后的 YOLOv8n-SMAF 模型精确度、召回率和 mAP_{50} 分别提高了 3.8 个百分点、4.5 个百分点和 2.7 个百分点, 能够满足精确识别水稻病害的需求, 为农业监测提供了更高效的技术支持。未来研究将进一步简化模型结构, 并探索其在嵌入式设备中的应用。



EfficientDet-B0, YOLOv5n, YOLOv10n: 当前主流目标检测模型; YOLOv8n: 本研究原始模型; Tea-YOLOv5s^[10]: 基于 YOLOv5s 改进的模型; YOLOv8n-SMAF: 本研究基于 YOLOv8n 改进的模型; Brown-Spot: 褐斑病; Blast: 稻瘟病; Dead Heart: 枯心病; Downy: 霜霉病; False: 稻曲病; Sheath Blight: 纹枯病。

图 12 不同模型检测效果对比

Fig.12 Comparison of detection effects of different models

参考文献:

[1] 王忠培, 谢成军, 董伟, 等. 基于多维间注意力机制的水稻病害识别模型[J]. 江苏农业学报, 2024, 40(4): 625-635.

[2] 邓楠, 方达, 李成. 改进 YOLOv7 的水稻叶片病害检测算法研究[J]. 中国农机化学报, 2024, 45(11): 196-201.

[3] GONG H, LIU T H, LUO T Y, et al. Based on FCN and DenseNet framework for the research of rice pest identification methods[J]. Agronomy, 2023, 13(2): 410.

[4] CHAUDHARI D J, MALATHI K. Detection and prediction of rice leaf disease using a hybrid CNN-SVM model[J]. Optical Memory and Neural Networks, 2023, 32(1): 39-57.

[5] DEMILIE W B. Plant disease detection and classification techniques: a comparative study of the performances[J]. Journal of Big Data, 2024, 11(1): 5.

[6] LI F, XIONG Y. Automatic identification of butterfly species based on HoMSC and GLCMoIB[J]. The Visual Computer, 2018, 34(11): 1525-1533.

[7] 路阳, 杨化龙, 陈宇, 等. 基于 TSDPSO-SVM 的水稻稻瘟病

- 图像识别[J]. 江苏农业科学,2022,50(23):164-170.
- [8] JAVIDAN S M, BANAKAR A, VAKILIAN K A, et al. Diagnosis of grape leaf diseases using automatic K-means clustering and machine learning [J]. Smart Agricultural Technology, 2023, 3: 100081.
- [9] 周 维,牛永真,王亚炜,等.基于改进的YOLOv4-GhostNet水稻病虫害识别方法[J]. 江苏农业学报,2022,38(3):685-695.
- [10] 王梦妮,顾寄南,王化佳,等.基于改进YOLOv5s模型的茶叶嫩芽识别方法[J]. 农业工程学报,2023,39(12):150-157.
- [11] YANG S, XING Z Y, WANG H B, et al. Maize-YOLO: a new high-precision and real-time method for maize pest detection [J]. Insects, 2023, 14(3):278.
- [12] 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.
- [13] WANG J, YU L Y, YANG J, et al. DBA_SSD: A novel end-to-end object detection algorithm applied to plant disease detection [J]. Information, 2021, 12(11):474.
- [14] ARUN R A, UMAMAHESWARI S. Effective and efficient multi-crop pest detection based on deep learning object detection models [J]. Journal of Intelligent & Fuzzy Systems, 2022, 43(4):5185-5203.
- [15] AFZAAL U, BHATTARAI B, PANDEYA Y R, et al. An instance segmentation model for strawberry diseases based on mask R-CNN [J]. Sensors, 2021, 21(19):6565.
- [16] 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.
- [17] 李志良,李梦霞,董 勇,等.基于改进YOLOv8的轻量化玉米害虫识别方法[J]. 江苏农业科学,2024,52(14):196-206.
- [18] PRIYA A P, SUDHAKAR C V, KUMAR A P, et al. Pest detection and prevention for agricultural crops using yolov8 algorithm [C]//IEEE. International conference on intelligent systems for cybersecurity (ISCS). Piscataway:IEEE,2024.
- [19] WANG Y C, YI C C, HUANG T, et al. Research on intelligent recognition for plant pests and diseases based on improved YOLOv8 model [J]. Applied Sciences, 2024, 14(12):5353.
- [20] REIS D, KUPEC J, HONG J, et al. Real-time flying object detection with YOLOv8 [J]. arXiv preprint arXiv, 2023. DOI:https://doi.org/10.48550/arXiv.2305.09972.
- [21] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once; unified, real-time object detection [C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway:IEEE Computer Society, 2016:779-788.
- [22] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas [J]. Machine Learning and Knowledge Extraction, 2023, 5(4):1680-1716.
- [23] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway:IEEE Computer Society, 2018:8759-8768.
- [24] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE Computer Society, 2017:2117-2125.
- [25] LI H L, LI J, WEI H B, et al. Slim-Neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles [J]. arXiv preprint arXiv, 2022. DOI:https://doi.org/10.1007/s11554-024-01436-6.
- [26] YANG L X, ZHANG R Y, LI L D, et al. SimAm: a simple, parameter-free attention module for convolutional neural networks [C]//IMLS. International conference on machine learning. New York:ACM, 2021.
- [27] YANG G Y, LEI J, ZHU Z K, et al. AFPN: Asymptotic feature pyramid network for object detection [C]//IEEE. International conference on systems, Man, and Cybernetics. Prague: IEEE, 2023.
- [28] JIN X, XIE Y P, WEI X S, et al. Delving deep into spatial pooling for squeeze-and-excitation networks [J]. Pattern Recognition, 2022, 121:108159.
- [29] WOO S, PARK J, LEE J Y, et al. Cham: convolutional block attention module [C]//ECVA. Proceedings of the European conference on computer vision (ECCV). Berlin:Springer, 2018.
- [30] CAI X H, LAI Q X, WANG Y W, et al. Poly kernel inception network for remote sensing detection [C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway:IEEE Computer Society, 2024.
- [31] ZHU L, WANG X J, KE Z H, et al. Biformer: vision transformer with bi-level routing attention [C]//IEEE. Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway:IEEE Computer Society, 2023.

(责任编辑:成纾寒)