doi:10.6041/j.issn.1000-1298.2025.09.050

基于改进 YOLO 11 - seg 的田间水稻分蘖数原位检测方法

孙　燕[1]　汪　苗[1]　苏宇辰[1]　何　坤[1]　曹成茂[1]　侯文慧[1]　王玉伟[1,2]　刘　路[1,3]

(1.安徽农业大学工学院, 合肥 230036; 2.农业农村部农业传感器重点实验室, 合肥 230036;
3.安徽农业大学皖东综合试验站, 滁州 239000)

摘要: 水稻分蘖动态数据是影响产量的关键指标,对其关键生长期进行有效监测可为田间管理措施的优化提供重要依据。针对复杂田间环境下水稻有效分蘖检测存在的遮挡、光照变化干扰及表型特征缺失等问题,本研究提出一种基于改进 YOLO 11 - seg 的实例分割模型。通过使用融合大型选择性内核网络(Large selective kernel network, LSKNet)构建的 CP_LSK 模块,替换主干网络中原有的 C3k2 模块,增强模型对多尺度特征的适应性;在主干末端引入注意力机制 CBAM(Convolutional block attention module)优化特征权重分配,显著提升模型在复杂场景下的鲁棒性。试验结果表明:改进模型在检测任务中 Box 分支的精确度、召回率、F1 分数、mAP50 和 mAP50 - 95 分别达到 90.3%、85.3%、87.7%、92.7%、61.4%,较原模型提升 2.2、3.5、2.9、0.8、2.1 个百分点;Mask 分支的对应指标分别提升 2.5、5.1、3.9、2.3、1.5 个百分点。测试集分蘖计数结果显示,全局平均绝对误差(Mean absolute error, MAE)和均方根误差(Root mean square error, RMSE)分别为 0.24、0.70 个,决定系数 R^2 为 0.950,其中 98.1% 的样本计数误差在 3 个分蘖以内,其中检测准确率较原模型提高 28.9 个百分点。研究提出的算法实现了田间复杂场景下水稻分蘖的原位检测和计数,其误差控制能力可为基于分蘖计数的有效穗数估算提供技术支撑,对于水稻植株生长监测与产量预测具有重要应用价值。

关键词: 水稻分蘖数; 实例分割; 原位检测; 产量预估; YOLO 11 - seg

中图分类号: TP391; S24　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)09-0596-11　　**OSID**:

In-situ Detection of Rice Tiller Number in Field Based on Improved YOLO 11 - seg

SUN Yan[1]　WANG Miao[1]　SU Yuchen[1]　HE Kun[1]　CAO Chengmao[1]　HOU Wenhui[1]
WANG Yuwei[1,2]　LIU Lu[1,3]

(1. *School of Engineering*, *Anhui Agricultural University*, *Hefei* 230036, *China*
2. *Key Laboratory of Agricultural Sensors*, *Ministry of Agriculture and Rural Affairs*, *Hefei* 230036, *China*
3. *Wandong Comprehensive Experimental Station*, *Anhui Agricultural University*, *Chuzhou* 239000, *China*)

Abstract: Rice tiller dynamics is a key agronomic trait in the yield formation process, so the monitoring of rice tiller growth period is of great significance in guiding agronomic management decisions. Aiming at the problems of shading, interference of light changes and missing phenotypic features for effective tiller detection in rice under complex field environments, an instance segmentation model was proposed based on improved YOLO 11 - seg. The CP_LSK module constructed by integrating large selective kernel network (LSKNet) was used to replace the original C3k2 module in the backbone network to enhance the adaptability of the model to multi-scale features; the CBAM attention mechanism was introduced at the end of the backbone to optimize the allocation of the feature weights, which significantly improved the robustness of the model in the complex scene. The experimental results showed that the improved model achieved 90.3%, 85.3%, 87.7%, 92.7%, and 61.4% for Box branch precision, recall, F1 score,

收稿日期: 2025 - 03 - 26　修回日期: 2025 - 04 - 24

基金项目: 安徽省高校科学研究项目(2023AH040140)、农业农村部农业传感器重点实验室开放课题(KLAS2023KF003)和先进数控和伺服驱动安徽省重点实验室开放基金项目(XJSK202306)

作者简介: 孙燕(1978—),女,副教授,主要从事智能农机装备研究,E-mail: syxk119@ahau.edu.cn

通信作者: 刘路(1988—),男,副教授,博士,主要从事智能农业装备和农业传感器研究,E-mail: vliulu@ahau.edu.cn

mAP50, and mAP50 - 95, respectively, in the detection task, which was 2.2, 3.5, 2.9, 0.8, and 2.1 percentage points higher than that of the original model; and the corresponding metrics for Mask branch were respectively improved by 2.5, 5.1, 3.9, 2.3 and 1.5 percentage points. The results of tiller counting in the test set showed that the global mean absolute error (MAE) and root mean square error (RMSE) were 0.24 and 0.70, respectively, and the coefficient of determination R^2 was 0.950, of which 98.1 percent of the samples had a counting error of less than three tillers, of which the accurate counting rate was increased by 28.9 percentage points compared with that of the original model. The proposed algorithm realized in-situ detection and counting of rice tillers in complex scenarios in the field, and its error control ability can provide technical support for the estimation of effective spike number based on tiller counting, which was of great application value for rice plant growth monitoring and yield prediction.

Key words: rice tiller number; example partitioning; in-situ detection; yield estimation; YOLO 11 - seg

0　引言

水稻作为全球主要粮食作物之一,在农业生产中地位重要,全球超半数人口以稻米为主食[1-2]。分蘖指单子叶植物中能形成谷粒的分枝,其为水稻重要生育特性之一[3]。水稻分蘖动态是植株生长表型诊断的关键参数,其数量变化具有阶段性指示作用:营养生长期的分蘖速率可表征植株生长状况,生殖生长期的有效分蘖保留率是评估作物耐受性的关键表型参数。基于分蘖动态监测数据,可在气候变化背景下用于水稻生长评价、产量预估,并为追肥时间调整、晒田及病虫害防治等田间管理策略提供依据[4]。其中有效分蘖数是决定水稻产量的关键因素[5],每株有效分蘖数决定了穗数,其中有效分蘖是指最终能形成有效穗并结实的分蘖,而穗数是构成水稻籽粒产量的关键组成部分[6]。

鉴于分蘖形成与粮食产量密切相关,农艺管理措施(如养分供给、水分调控等)[7]显著影响水稻营养生长期分蘖,因此需掌握分蘖信息以评价种质生长、支撑育种。当前田间有效分蘖数主要依赖人工测量或收割后计数,存在耗时费力、时效性差、数据准确性低等问题,主观判断偏差易致数据无法精准反映分蘖关键期农艺性状,因此亟需开展高效精准的测量方法研究。研究人员持续探索高效精准的大田水稻分蘖数普查技术,如 YANG 等[6]借助 X 射线计算机断层扫描系统,通过盆栽传送扫描实现单簇水稻的高通量分蘖计数;HUANG 等[8]利用磁共振成像技术获取水稻茎秆横截面无损图像,经图像分离处理后计算分蘖数量。

近年来,深度学习、图像处理等技术快速发展,在农业自动化领域的应用场景越来越多。例如通过采集作物收获前的冠层图像来获取小麦[9-10]和水稻[11]等作物穗、水稻害虫检测识别[12]、利用多模态信息判别水稻施肥期[13]等应用。目前对于水稻分蘖数检测也有了一定的研究方法,例如 SINGH 等[3]利用田间机器人采集水稻 3 个阶段的分蘖期俯视图,结合 YOLO v4 模型进行分蘖数估算,DESAI 等[14]使用滑动窗口机制与卷积神经网络(Convolutional neural network, CNN)分类器相结合来自动估计水稻的抽穗日期。DENG 等[15]、崔家乐等[16]分别利用目标检测领域中基于区域的快速卷积网络算法(Fast region-based convolutional neural network, Fast R - CNN)和融合 GhostNet 轻量化策略的 YOLO v8 改进模型对植株成熟收获后暴露的茎秆进行检测,从而确定有效分蘖的数量。

在复杂野外场景中,现有方法受数据获取装置适应性和破坏性检测缺陷制约,需研究轻便快速的无损获取方案。研究显示,YOLO(You only look once)模型凭借端到端特征金字塔网络设计,在目标重叠、遮挡等复杂环境下的检测中具有架构优势,可通过针对目标特征和应用场景改进模型来提升检测性能[17-20]。

本研究聚焦大田水稻分蘖关键期(开始分蘖至单株形成 10 ~ 20 个有效分蘖),针对传统检测方法缺陷,提出基于改进 YOLO 11 - seg 的水稻生长期分蘖的原位检测方法:通过融合大型选择性内核网络(Large selective kernel network, LSKNet)构建 CP_LSK 模块,并在主干末端引入注意力机制 CBAM[21](Convolutional block attention module)来优化特征权重分配,以期增强多尺度适应性。

1　数据采集与建立

1.1　水稻生长期分蘖状态分析

水稻分蘖是由一次枝梗、二次枝梗和籽粒组成的专化枝梗,成熟后的有效分蘖具有结实穗粒。通常,分蘖芽从水稻植株主茎上的每片叶子腋部产生,水稻生长到第 4 片叶时,出现第一个分蘖,分蘖的发生符合 $n-3$ 的规律,主茎达到 3 片叶第一个分蘖开始发育。理论上,每一片叶的腋芽都能形成分蘖,但只有那些在未生长的基部节间上的分蘖芽才具有发

育成分蘖的潜力。其中,分蘖的形成包括分蘖芽的起始和分蘖芽的生长,如图 1 所示,其中红色圆圈表示从叶腋生出的分蘖芽[22]。

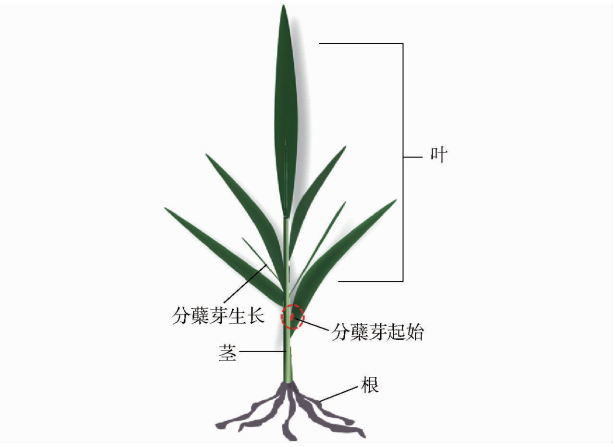


图 1 水稻生长期分蘖形态

Fig. 1 Tillering morphology of rice during growth period

1.2 图像采集

数据集图像于 2024 年 7 月 19—31 日在安徽农业大学皖东综合试验站拍摄,保障了农业视觉数据的真实性。选取晨锋优 8612、科远一号、茎两优 532、茎优 822、泰优油香、玮两优 8549、玮两优 8612 共 7 个品种,分别编号为 1 ~ 7,于 7 月 19、22、25、28、31 日 5 个不同时期分别进行数据采集,此为该 7 个品种水稻秧苗从移栽 18 d 到生长有效分蘖最重要的时间段。因稻田环境复杂,水深泥陷,目前采用手机作为数据采集设备,并选择一块 30 cm × 40 cm 的白色背景板垂直放置在单株水稻后方,以减少背景干扰。所采集图像原始像素为 4 284 像素 × 5 712 像素,将图像尺寸调整为 1 024 像素 × 1 024 像素。拍摄时间段为 06:00—07:30。7 个水稻品种及以其中一个水稻品种为例的 5 个时期分蘖情况图像如图 2 所示,其中,图 2b 所示的复杂天气条件包括自然光、光照不均、光线昏暗及模糊等不同拍摄效果,以增强模型对不同天气条件的适应能力。选择 609 幅原始图像,其中保留一部分目标遮挡、图像画质模糊等因素造成的识别困难图像来提升模型在真实农田场景的泛化能力。

1.3 数据集建立

共收集到原始图像(包含 7 个品种分别在 5 个不同时期的图像)609 幅。其中 504 幅图像用于训练集和验证集的划分,105 幅图像作为测试集。具体涵盖的品种、植株分布及所处时期的统计如图 3 所示,其中,柱状图中的数字 12、15、3 均为该品种的图像数量。

在首次的采集日期中,由于水稻处于分蘖前期,



图 2 部分采集图像示例

Fig. 2 Example of some of captured images

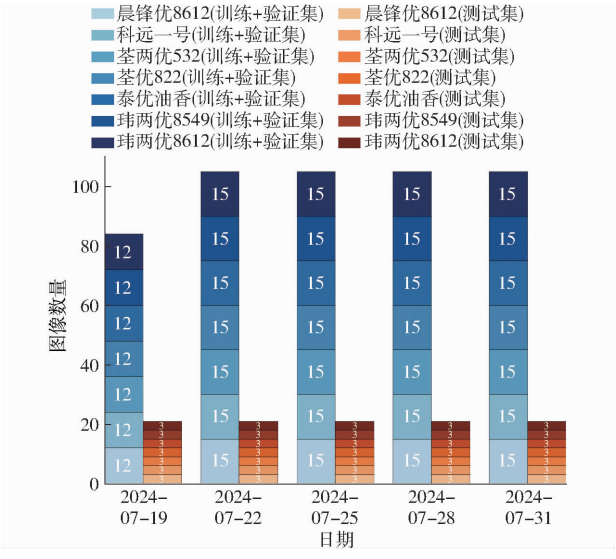


图 3 具体涵盖的品种、植株分布及所处时期统计

Fig. 3 Specific species covered, plant distribution and time period statistics

分蘖数相对较少。因此,相较于后续 4 个时期,此阶段获取了相对较少的数据量,这一数据采集量的差异仅基于该时期水稻生长的实际特性而定,并不存在其他特殊考虑。为了保证测试集检测的真实性,对测试集不作任何预处理,而使用开源图像标注工具 LabelMe[23] 对 504 幅原始图像中的水稻分蘖个体实例进行标注,标签名为“tiller”,其余部分视为“背景”。将标注好的图像按照比例 8∶2 划分为训练集 403 幅和验证集 101 幅,而为了保证数据的真实性和有效性,只对训练集进行数据增强至806 幅图像,其数据集的详细信息如表 1 所示。

表 1 数据集详情

Tab. 1 Datasets details

数据集类别	图像数量	标签数量	单幅图像最小分蘖数	单幅图像最大分蘖数
训练集	806	6 480	2	17
验证集	101	774	3	15
测试集	105		2	16

本研究中主要利用旋转、调整亮度以及添加噪声等图像增强方式，并采用这几种增强方式的随机组合进行图像数量的扩增，经过上述预处理的图像示例如图 4 所示。

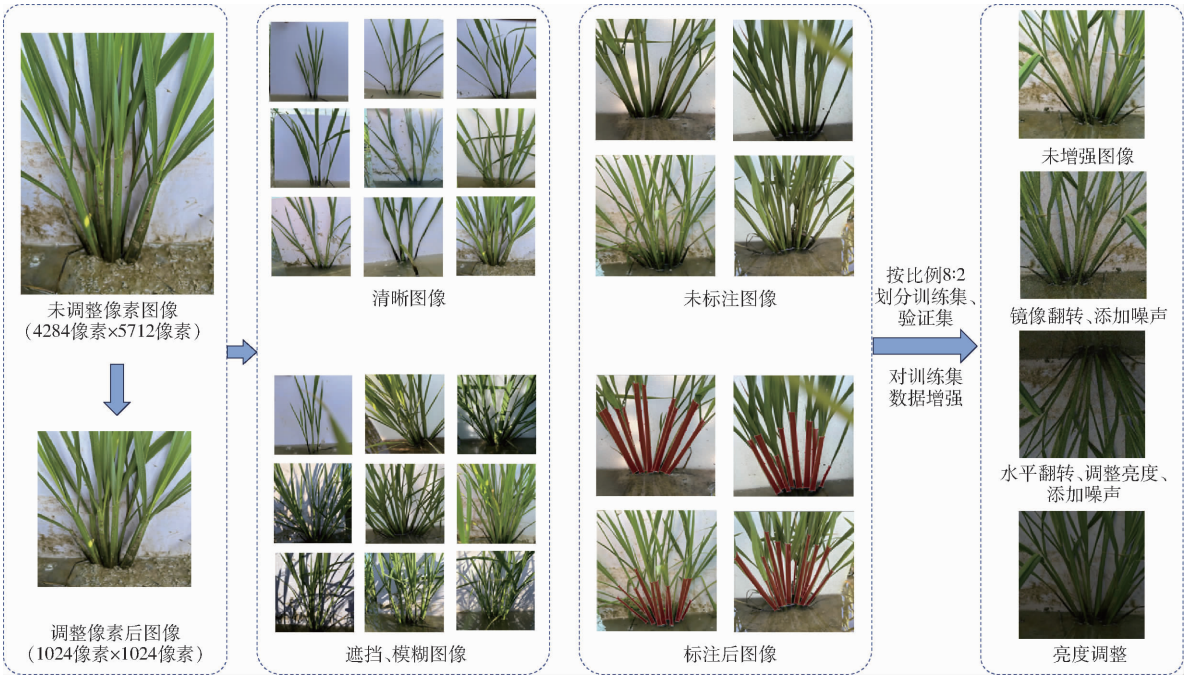


图 4　数据预处理

Fig. 4　Data preprocessing

2　水稻生长期分蘖图像分割模型

2.1　YOLO 11－seg 网络

YOLO 11[24] 延续了 YOLO[25] 的技术路线，支持包括目标检测、实例分割、旋转检测和姿态估计多种图像处理任务，提供 n、s、m、l、x 5 种参数量级的模型以适配差异化场景需求。其整体网络架构由 Input、Backbone 和 Head 3 部分构成，其中 Backbone 是 YOLO 架构的关键组成部分，通过堆叠卷积层与专用模块实现多尺度图像特征提取，生成不同分辨率的特征图。YOLO 11 的重要改进包括引入 C3k2 模块替代原有 C2f 模块，通过跨阶段部分（Cross stage partial，CSP）瓶颈结构实现计算效率优化；保留空间金字塔池-快速区块（Spatial pyramid pooling－fast，SPPF）的基础上，在其后嵌入新型跨阶段部分与空间注意力融合模块 C2PSA 区块。Head 部分，通过多个 C3k2 模块实现特征图的高效处理与细化，该模块通过 c3k 参数控制结构变体：当 c3k = False 时采用标准瓶颈结构（类 C2f 模块），当 c3k = True 时切换为 C3 模块以支持更深层次的特征提取。

2.2　YOLO 11s－CP_LSK 实例分割模型

为了解决原始 YOLO 11－seg 网络模型在水稻生长分蘖期受到光照不均、遮挡等具有挑战的条件下检测困难的问题，本研究提出面向分蘖表型检测的 ResLSK 双路径残差模块，基于遥感目标检测的大选择内核块（Large selective kernel block，LSKBlock）架构创新性融合并行空洞卷积路径与自适应空间选择机制，实现特征信息的融合，有效克服密集分蘖群体中叶片遮挡与反光干扰等因素导致的检测目标不清晰问题，将该模块命名为 CP_LSK，将该模块替换主干网络中的 C3k2 模块，优化多尺度特征提取。另外，在注意力机制改进方面，本研究采用 CBAM 模块替代原 C2PSA 模块，利用通道注意力和空间注意力的协同作用，实现特征的自适应增强和跨层级特征的判别性融合，优化模型的检测精度。将改进模型命名为 YOLO 11s－CP_LSK，其结构如图 5 所示。

2.2.1　CP_LSK 模块

CP_LSK 模块通过卷积层、ResLSK 模块的组合以及特征图的分割和融合，实现对输入特征图的有效处理和特征提取。基于 LSKNet[26]，引入其中的 LSKBlock 构建双路径残差模块 ResLSK，进行特征解耦到增强的模块重构，实现特征信息的融合。其中，大选择内核模块（Large selective kernel module，LSK Module）是选择相关核的选择性机制的关键部分，通过协同整合小核与大核的双尺度卷积机制，实现多层次特征建模。LSKBlock 是由大内核选择（Large kernel selection，LK Selection）和前馈神经网络（Feedforward neural network，FFN）两个主要子块组成。LI 等[26] 通过在层的开始和结

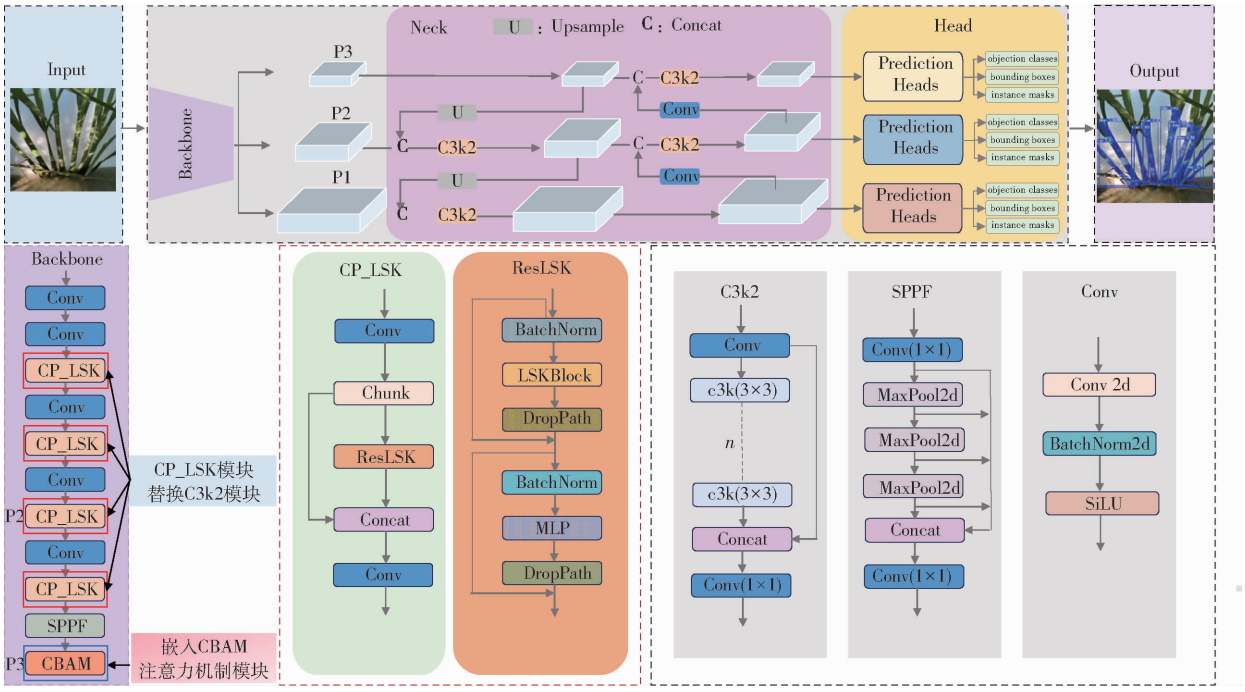


图 5 YOLO 11s－CP_LSK 结构图

Fig. 5 YOLO 11s－CP_LSK structure diagram

束放置 1×1 卷积层来开发 LK 选择子块。1×1 卷积层的目的是实现降维和特征变换[27-28]。FFN 子块的主要部分是深度卷积。SHUAI 等[29]使用深度卷积来维护空间细节和模式，同时减少计算成本和参数量。GAO 等[30]验证了该设想，提出为增强深度卷积的特征表达能力，可在深度卷积后引入点向卷积。通过 1×1 卷积对深度卷积输出进行逐点处理，能够有效捕获跨通道交互信息，提升模型对复杂特征的学习能力。LSK Module 与 LSKBlock 结构关系如图 6 所示。

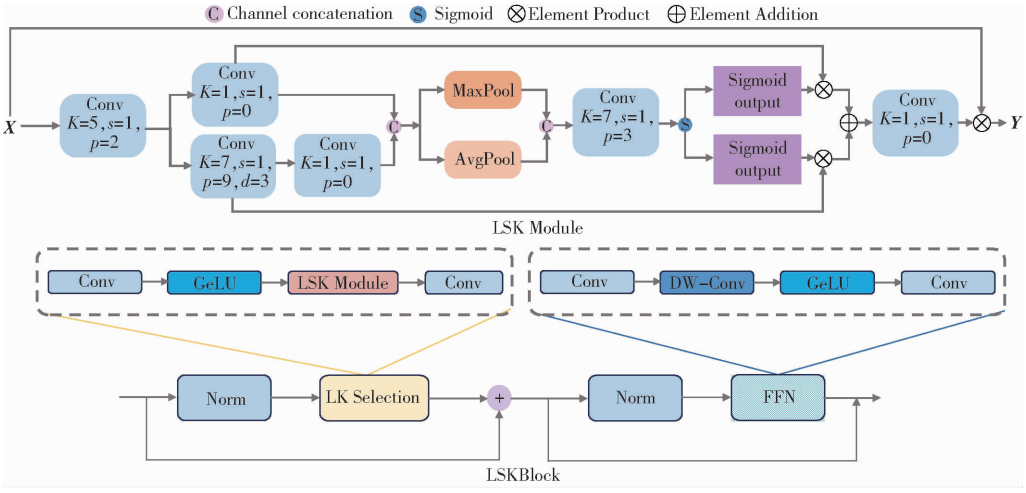


图 6 LSK Module 与 LSKBlock 结构关系图

Fig. 6 Diagram of structure between LSK Module and LSKBlock

CP_LSK 模块采用模块化设计对输入特征图进行多尺度特征提取与动态融合。该架构首先通过标准卷积层进行浅层特征编码，随后沿通道维度对特征张量进行均等分割(Chunk)，生成 2 个并行分支：一个分支通过 ResLSK 模块进行深度特征提取，该模块通过大核卷积与空间选择性机制实现长程上下文建模；另一个分支则保持原始特征流形以保留低频结构信息。这种双路径设计通过参数化残差学习策略实现特征信息的解耦与互补，既避免了单一处理路径导致的高频细节损失，又通过可控的计算复杂度维持了网络效率。特征融合阶段采用通道维度拼接(Concat)操作实现跨域特征整合，继而通过 1×1 卷积进行通道重标定与非线性映射，形成从局部到全局的多级感受野融合机制。

其中 ResLSK 模块分为两个阶段，利用残差结构的变体，将各阶段通过跳跃连接与主路径融合。

残差单元的正向传播计算过程为

$$\boldsymbol{Y} = \boldsymbol{X} + D_\theta(F_{LSK} \circ \mathrm{BN}(\boldsymbol{X})) \tag{1}$$

式中　$\boldsymbol{X}$——输入张量(通道 × 高度 × 宽度),$X \in \mathbf{R}^{C \times H \times W}$

$\boldsymbol{Y}$——输出张量

D_θ——随机路径丢弃操作

F_{LSK}——大选择性内核模块处理

$\circ$——函数复合

$+$——残差连接

BN(Batch normalization)表示批标准化操作,满足 $\dim(x) = \dim(F(x))$。第 1 阶段:①通过 BN 的操作对输入数据进行批标准化,加速训练并提升模型稳定性。②引入上文中描述的 LSKBlock,通过动态调整卷积核的感受野,增强局部特征与全局上下文的融合能力。③应用随机路径丢弃,防止过拟合并增强模型鲁棒性。第 2 阶段:①对第 1 阶段输出再次标准化,稳定梯度流。②通过全连接层进行非线性变换,建模高阶特征交互机制。③二次应用路径丢弃,进一步正则化模型。其具体结构如图 5、6 所示。

2.2.2　CBAM 注意力机制

CBAM 是一种自适应的注意力机制模块,实现了通过级联的通道域注意力与空间域注意力操作来改进标准前馈卷积神经网络的功能。CBAM 由通道注意力模块(Channel attention module,CAM)和空间注意力模块(Spatial attention module,SAM)两个顺序子模块构成。

针对水稻分蘖图像的输入特征图,CBAM 通过顺序执行通道域压缩校准和空间域卷积聚焦的级联操作,分别生成一维通道权重向量和二维空间热力图,结构流程可视化图如图 7a 所示。

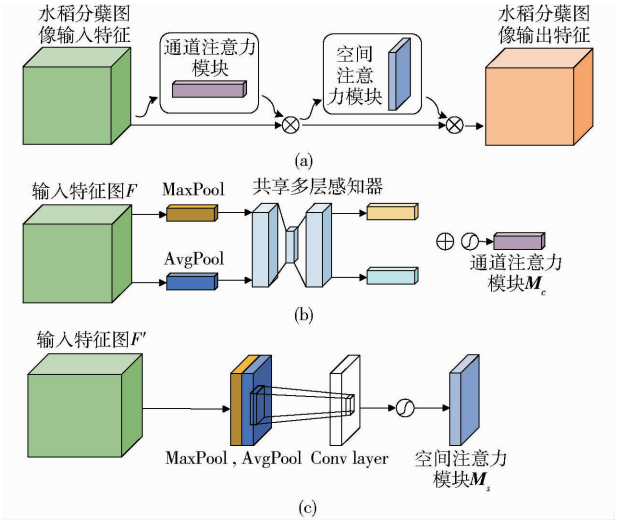


图 7　CBAM 结构图

Fig. 7　CBAM structure diagram

其整体计算过程可以表示为

$$\boldsymbol{F}' = \boldsymbol{M}_c(F) \otimes F \tag{2}$$

$$\boldsymbol{F}'' = \boldsymbol{M}_s(\boldsymbol{F}') \otimes \boldsymbol{F}' \tag{3}$$

式中　$\boldsymbol{M}_c$——一维通道注意力向量

F——输入特征图　　$\otimes$——元素任意相乘

$\boldsymbol{M}_s$——二维空间注意力矩阵

$\boldsymbol{F}'$——一维通道注意力权重向量与输入特征图的逐通道元素相乘的输出结果,可以实现特征通道维度的自适应校准

$\boldsymbol{F}''$——最终输出的双注意力协同优化的特征张量

(1)CAM:利用特征通道之间的关系生成通道特征图,以高效地计算通道关注。首先分别采用最大池化(MaxPool)和平均池化(AvgPool)双路径并行提取空间维度统计特征,形成两个单通道空间特征描述符;继而通过 MLP 网络进行特征融合与维度映射,获得初步注意力分布;最后使用 Sigmoid 函数进行激活操作,生成通道注意力掩膜,该掩膜与原始输入特征进行逐通道调制后,输出至空间注意力模块。CBAM 中的通道注意力模块如图 7b 所示。

(2)SAM:在 SAM 模块中,通过构建像素级特征响应自适应机制实现空间维度关注度的动态分配,其处理流程采用双模态特征压缩策略:输入特征图依次经最大池化(MaxPool)与平均池化(AvgPool)提取空间域互补统计特征,拼接后通过卷积核压缩实现特征降维,最终经 Sigmoid 激活生成空间注意力权重矩阵。该机制基于像素区域特征变异度实施动态权重调节,对显著性变化区域增强特征响应,对稳态区域实施特征抑制。CBAM 中空间注意力模块结构如图 7c 所示。

2.3　试验参数设置与评价指标

2.3.1　试验参数设置

基于本研究中构建的数据集开展模型训练和测试。试验环境包含硬件环境和软件环境,其中硬件环境配置包括:6 核 Xeon Gold 6142 CPU, NVIDIA GeForce RTX 3090 GPU。软件环境包括:Python 3.10,Pytorch 2.0.1,Cuda 11.8。所有试验均在相同环境下进行。试验参数设置:模型输入尺寸设定为 640 像素 × 640 像素,以降低训练过程中的内存消耗;初始学习率统一设置为 0.01,动量 0.937,权重衰减系数为 0.000 5,批次大小为 16。训练过程中不加载预训练权重,训练轮次设定为 200。

2.3.2　模型评价指标

采用精确度(Precision,P)、召回率(Recall,R)、F1 分数(F1 score)以及平均精度均值(mean Average Precision,mAP)来衡量模型的检测准确性,其中,

mAP50 为使用 IoU 阈值为 0.50 来计算平均精度均值,mAP50 - 95 为使用 IoU 阈值从 0.50 到 0.95,每隔 0.05 一个间隔,计算 10 个 mAP,对这 10 个值取平均得到的;并采用内存占用量和帧率多维度联合全面评估模型性能。

基于 7 个水稻品种(每个品种 15 幅样本)共 105 幅田间分蘖图像的不同品种测试集,采用全局平均绝对误差(Mean absolute error, MAE)、均方根误差(Root mean square error, RMSE)和决定系数 R^2,系统量化模型在分蘖计数任务中的预测精度、误差离散度及数据拟合程度,进而验证其品种泛化性能与农艺实用价值。

分为两种计算场景:当样本数为 15 时表示计算单品种的各评价指标,当样本数为 105 时表示计算整体的各评价指标。

3 结果与分析

3.1 消融试验结果

采用消融试验验证模型改进效果,系统分析 YOLO 11 - seg 基准模型与改进版本中各模块以及独立作用和协同作用的有效性。针对目标检测(Box)与实例分割(Mask)双任务性能逐步引入 CP_LSK 模块和 CBAM 注意力机制的量化评价结果如表 2、3 所示。

表 2 消融试验结果(Box)

Tab. 2 Ablation experiment results(Box)

模型编号	CP_LSK	CPN_Ghost	CBAM	SimAM	精确度/%	召回率/%	F1 分数/%	mAP50/%	mAP50 - 95/%	模型内存占用量/MB
1	×	×	×	×	88.1	81.8	84.8	91.9	59.3	55.9
2	√	×	×	×	91.2	83.7	87.5	92.6	59.8	58.5
3	×	√	×	×	87.6	82.2	84.8	91.0	57.5	48.7
4	×	×	√	×	89.3	84.0	86.6	92.1	59.8	53.1
5	×	×	×	√	89.5	81.7	85.4	91.1	57.6	52.9
6	√	×	√	×	90.3	85.3	87.7	92.7	61.4	55.8
7	√	×	×	√	88.6	86.1	87.3	92.0	59.8	55.6

注:√表示加入该模块,×表示未加入该模块。下同。

表 3 消融试验结果(Mask)

Tab. 3 Aablation experiment results (Mask)

模型编号	CP_LSK	CPN_Ghost	CBAM	SimAM	精确度/%	召回率/%	F1 分数/%	mAP50/%	mAP50 - 95/%	模型内存占用量/MB
1	×	×	×	×	86.6	79.4	82.8	87.8	42.3	55.9
2	√	×	×	×	88.8	81.9	85.2	89.4	43.7	58.5
3	×	√	×	×	88.7	80.9	84.6	89.3	42.3	48.7
4	×	×	√	×	87.4	81.4	84.3	88.5	42.8	53.1
5	×	×	×	√	86.4	79.3	82.7	87.4	42.1	52.9
6	√	×	√	×	89.1	84.5	86.7	90.1	43.8	55.8
7	√	×	×	√	85.1	85.3	85.2	89.1	43.7	55.6

如表 2、3 所示,对比模型 1、2、6 可知,引入 CP_LSK 模块后,模型的各项精度指标均有提升,可以证明引入 CP_LSK 模块有着针对水稻分蘖形态学特征的高效表征能力。进一步在主干网络末端集成 CBAM 双域注意力机制后,模型 6 相较于单独使用 CP_LSK 的模型 2,在复杂光照干扰场景下除了检测(Box)中的精确度略有下降(但其权重也相应减少),其他各项精度指标均有一定提升。

为探究不同模块及注意力机制对模型改进优化的影响差异,本研究展开了一系列试验的对比分析。分别单独引入 CP_LSK 模块以及其他改进模块(如 CPN_Ghost)进行对比,由表 2、3 中模型 1 ~ 3 可看出,CP_LSK 模块最适合本研究中的研究对象。另外,对比了 SimAM 注意力机制,由表 2、3 中模型 1、4 ~ 7 的数据可见,在未引入 CP_LSK 模块的基础上,CBAM 注意力机制相较于 SimAM 机制展现出更优的综合特征表征能力,仅精确度这一项指标略低于后者;当引入 CP_LSK 模块后,CBAM 注意力机制与 CP_LSK 的宽感受野特性形成层次化互补优势。值得注意的是,SimAM 注意力机制与 CP_LSK 模块的组合虽在召回率方面呈现局部优化潜力,但其整体性能均衡性仍劣于 CBAM 注意力机制与 CP_LSK 模块的组合,这表明通道-空间双域协同优化策略更适合处理分蘖检测中复杂的形态学变异与背景干扰问题。因此,本研究采用了改进的 CP_LSK 模块和 CBAM 注意力机制组合的模型,相比于原始模型,检测(Box)的精确度、召回率、F1 分数、mAP50、mAP50 - 95 分别提升 2.2、3.5、2.9、0.8、2.1 个百分点,掩膜

(Mask)的精确度、召回率、F1 分数、mAP50、mAP50－95 分别提升 2.5、5.1、3.9、2.3、1.5 个百分点。同时，模型内存占用量相较原始模型降低 0.1 MB，满足对水稻生长分蘖检测的需求。

3.2　不同实例分割算法的性能对比试验结果

为了验证本研究模型在水稻分蘖数据集上的优越性，与最常见的图像实例分割模型(Mask R－CNN、Yolact、YOLO v7－seg、YOLO v8－seg)进行了对比试验。通过统一硬件配置、软件环境及超参数设定，在自建水稻分蘖测试集上系统评估检测精度、内存占用量以及推理速度的性能差异。结果如表 4 所示。

表 4　不同模型评估结果

Tab. 4　Results of different models for assessing indicators

模型	mAP50/%	模型内存占用量/MB	帧率/(f·s^{-1})
Mask R－CNN	68.0	351.1	21.3
Yolact	59.4	189.0	32.4
YOLO v7－seg	84.7	72.7	78.1
YOLO v8－seg	85.3	84.0	49.5
YOLO 11－seg	91.9	55.9	23.9
YOLO 11s－CP_LSK	92.7	55.8	36.2

注：mAP50 为检测(Box)的指标。

由表 4 可知，YOLO 11s－CP_LSK 模型的 mAP50 相较于其他模型分别提升 24.7、33.3、8.0、7.4、0.8 个百分点，模型内存占用量相对最少。相比 YOLO v7－seg、YOLO v8－seg、YOLO 11－seg 模型在检测速度上有一定损失，但帧率达到 36.2 f/s，可以满足本研究中的检测需求。

3.3　计数模型测试结果

通过计算不同品种计数评价指标以及整体计数评价指标来验证改进 YOLO 11s－CP_LSK 模型的性能，其具体数据结果如表 5 所示。

由表 5 可知，YOLO 11s－CP_LSK 与 YOLO 11－seg 表现出显著的性能差异与互补特征。整体而言，YOLO 11s－CP_LSK 模型在全局中展现出系统性优势，其 MAE 较原模型降低 42.9%，RMSE 较原模型降低 15.7%，显示该模型在预测精度、误差控制及数据拟合度方面具有更优的综合性能。YOLO 11s－CP_LSK 模型的 MAE、RMSE 在 7 个品种的测试中都有一定降低，R^2 也有提升。且在误差稳定性方面表现突出，其 MAE 波动范围(0.07～0.47 个)明显小于原模型(0.20～1.60 个)，表明改进模块通过强化特征选择能力提升了模型鲁棒性。后续也可针对 CP_LSK 的模块化特性进行架构优化，尝试融合 YOLO 11－seg 模型在局部特征提取上的优势，并通过跨品种迁移学习进一步提升模型的泛化能力。7 个品种总计 105 个样本的单幅图像分蘖数预测值与真实值的线性拟合结果如图 8 所示，其中，原始预测值经轻微水平抖动(区间为[－0.5，0.5]个)并增加样本数据点透明度以区分重复样本。

表 5　不同水稻品种及整体分蘖计数的评价指标结果

Tab. 5　Results of evaluation indexes for different rice varieties and overall tiller counts

品种	模型	MAE/个	RMSE/个	R^2
1	YOLO 11－seg	1.60	1.27	0.849
	YOLO 11s－CP_LSK	0.47	1.18	0.937
2	YOLO 11－seg	0.33	0.68	0.978
	YOLO 11s－CP_LSK	0.07	0.26	0.998
3	YOLO 11－seg	0.40	0.89	0.975
	YOLO 11s－CP_LSK	0.27	0.82	0.983
4	YOLO 11－seg	0.53	0.89	0.951
	YOLO 11s－CP_LSK	0.33	0.78	0.975
5	YOLO 11－seg	0.20	0.45	0.988
	YOLO 11s－CP_LSK	0.13	0.37	0.993
6	YOLO 11－seg	0.73	1.18	0.947
	YOLO 11s－CP_LSK	0.33	0.68	0.984
7	YOLO 11－seg	0.20	0.45	0.992
	YOLO 11s－CP_LSK	0.07	0.26	0.998
平均	YOLO 11－seg	0.57	0.83	0.954
	YOLO 11s－CP_LSK	0.24	0.62	0.981
全局	YOLO 11－seg	0.42	0.83	0.941
	YOLO 11s－CP_LSK	0.24	0.70	0.950

注：“全局”类型表示将整个测试集作为整体计算其 MAE、RMSE、R^2。

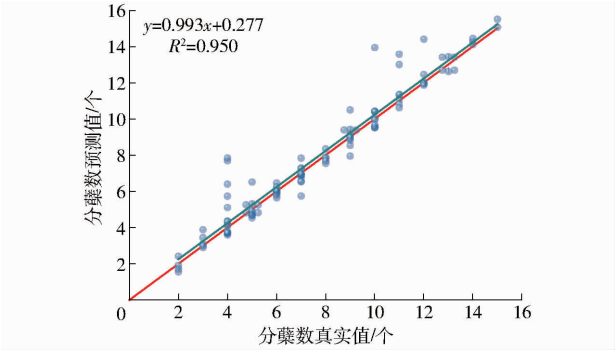


图 8　7 个品种单幅图像分蘖数预测值与真实值的拟合结果

Fig. 8　Fitting results of predicted and true values of tillers in single images of seven varieties

本研究系统对比了 YOLO 11s－CP_LSK 模型与原模型(YOLO 11－seg)在测试集上的统计分布特征。实验结果表明，改进模型的绝对计数率显著提升，较原模型提升 28.9 个百分点。测试集整体计数结果如表 6 所示。

3.4　测试结果可视化展示与讨论分析

3.4.1　改进模型较原模型问题优化的可视化对比

改进 YOLO 11s－CP_LSK 模型在水稻分蘖检

表 6 改进前后模型在测试集的预测计数结果

Tab. 6 Predicted count results of model in test set before and after improvement

模型	准确计数图像		误差小于 2 个图像		误差小于 3 个图像		误差大于 2 个图像	
	数量/个	占比/%	数量/个	占比/%	数量/个	占比/%	数量/个	占比/%
YOLO 11 - seg	69	65.7	97	92.4	102	97.1	3	2.9
YOLO 11s - CP_LSK	89	84.8	99	94.3	103	98.1	2	1.9

测任务中展现出显著的性能提升,特别是在应对目标遮挡和复杂光照干扰等关键难题方面有一定改善,针对目标特征缺失、遮挡、光照不均等问题改善的可视化结果如图 9 所示。

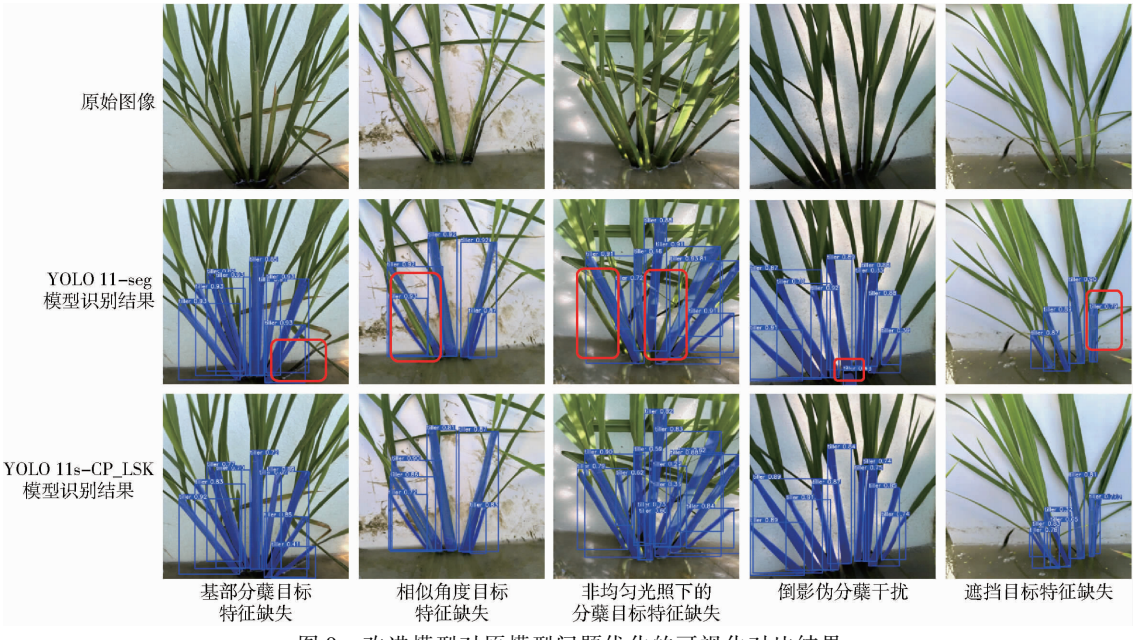


图 9 改进模型对原模型问题优化的可视化对比结果

Fig. 9 Visual comparison results of improved model for optimization of original model problem

由图 9 可以看到,YOLO 11 - seg 模型会出现图中红色框所圈出的因基部分蘖目标特征缺失、相似角度的分蘖目标特征缺失、水面倒影的干扰以及遮挡等情况导致的漏检问题,而 YOLO 11s - CP_LSK 模型通过增强特征融合能力,针对图中呈现的目标特征缺失、光影干扰、目标遮挡等问题,漏检率得以显著下降。其次,改进的空间感知模块提升了模型对部分遮挡分蘖的定位精度,在茎叶交错区域仍能保持稳定的检测性能。相较于原始模型,YOLO 11s - CP_LSK 在保持实时性的同时,实现了对复杂农田环境的高适应性。

3.4.2 YOLO 11s - CP_LSK 模型在不同分蘖数情况下的检测性能分析

在本研究中,根据采集时间的不同,水稻分蘖也处于不同阶段。在首个采集日期,各品种处于分蘖初期,一般有 2 ~ 4 个分蘖,随着时间推移,在适宜生长条件下水稻植株进入快速分蘖阶段,因此在接下来的 4 个采集日期分别对应的分蘖数范围为 4 ~ 7 个、7 ~ 10 个、10 ~ 13 个、13 ~ 17 个。针对不同生长阶段的水稻分蘖,本研究系统对比了原模型(YOLO 11 - seg)与改进模型(YOLO 11s - CP_LSK)的检测准确率,具体结果如表 7 所示。各品种在不同日期的检测可视化结果如图 10 所示,直观呈现不同品种水稻分蘖期生长动态。

表 7 改进前后模型在不同分蘖区间的检测准确率

Tab. 7 Detection accuracy of model before and after improvement in different tillering intervals

采集日期	分蘖数范围/个	YOLO 11 - seg 检测准确率/%	YOLO 11s - CP_LSK 检测准确率/%
7 月 19 日	2 ~ 4	71.4	76.2
7 月 22 日	4 ~ 7	90.5	95.2
7 月 25 日	7 ~ 10	66.7	85.7
7 月 28 日	10 ~ 13	52.4	85.7
7 月 31 日	13 ~ 17	52.4	81.0

由表 7 可以看出,改进模型在各分蘖数区间均展现出优于原模型的检测性能,这种性能差异不仅反映了模型算法的优化效果,更与水稻分蘖生长过程中形态结构的动态变化密切相关。在分蘖初期(2 ~ 4 个),改进模型 YOLO 11s - CP_LSK 的检测计数准确率高于原模型 YOLO 11 - seg,但其整体准确率仍未达理想水平,是由于分蘖初期的茎秆与叶片的形态差异不够显著,增加了模型的检测难度;当分

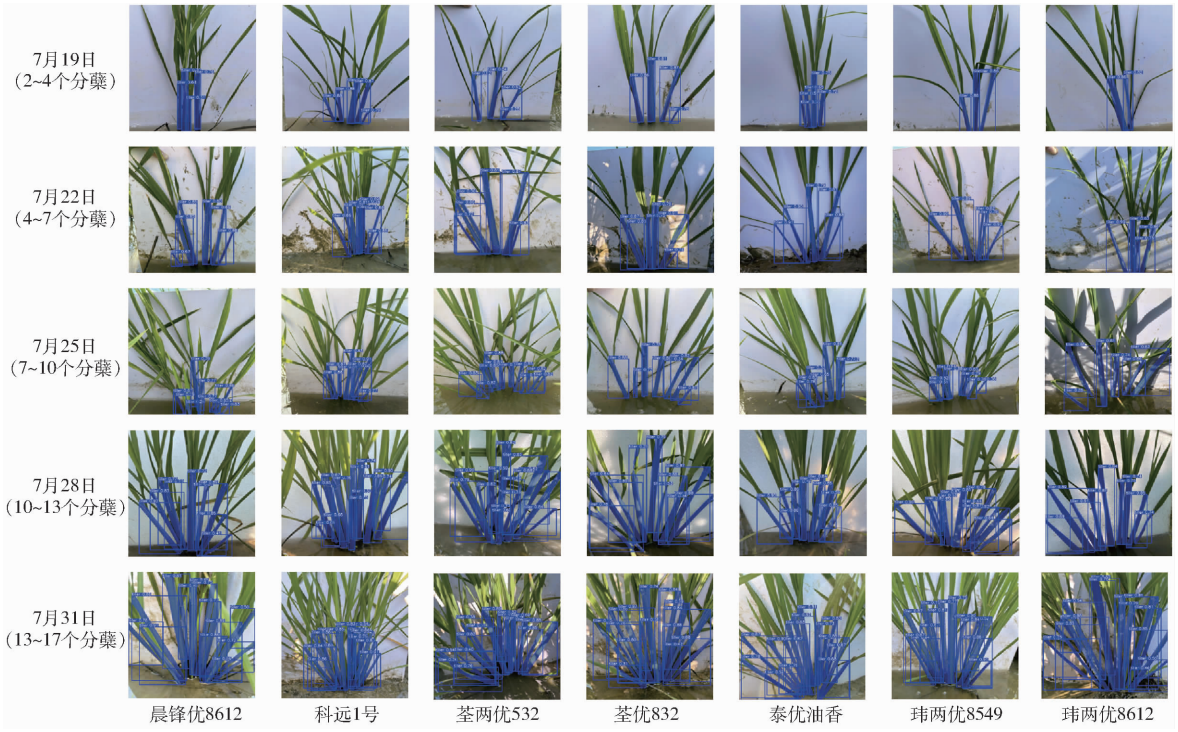


图 10　多品种水稻不同生长阶段检测可视化结果

Fig. 10　Visualization results of detection of different growth stages in multiple varieties of rice

蘖数增至 4 ~ 7 个、7 ~ 10 个及以上的复杂阶段，由表 7 数据对比凸显了改进模型处理重叠、密集分蘖的优势，其通过引入 CP_LSK 结构，在主干网络末端引入 CBAM 注意力机制，增强了复杂场景下的目标检测能力，确保在高复杂度场景下维持较高的检测准确率。

由图 10 可知，该模型对分蘖能力各异的品种基本能实现所有分蘖的准确识别。针对不同条件下的泛化能力分析如下：

(1)不同分蘖时期：对于分蘖初期，植株数量较少且分布稀疏，模型同样能够实现稳定检测；而分蘖开始增多时，面对遮挡问题的挑战，本研究在前期训练过程中，通过数据增强手段模拟了部分复杂场景，并采用多尺度特征融合策略增强模型对复杂形态的适应性。在测试集中包含的盛期数据样本测试中，模型仍能保持可接受的检测性能。

(2)不同品种：选取 7 个水稻品种作为研究对象，涵盖了不同株型与分蘖特性。试验结果表明，模型在各品种关键分蘖期的检测精度差异较小，证明了本方法对不同品种的良好适应性。尽管紧凑型品种在盛期易出现严重遮挡，但在关键分蘖期其形态特征仍与常规品种具有共性，本方法能够有效识别。

(3)不同遮挡程度：在本研究所针对的分蘖关键期阶段，针对不同遮挡程度，模型在轻度至中度遮挡场景下均表现良好，这得益于本研究改进的实例分割算法对目标边界的精准捕捉能力，在测试验证中能达到较高的检测精度。在后续的实际应用中，利用多源数据融合等技术，可进一步缓解遮挡问题对检测效果的影响。

4　结论

(1)提出一种基于改进 YOLO 11 - seg 模型的田间水稻分蘖数原位检测方法，通过大型选择性内核网络(LSKNet)构建 CP_LSK 模块和引入 CBAM 注意力机制，实现了对有效分蘖的准确识别，并改善了遮挡、光照不均等问题的影响。

(2)在水稻分蘖数据集上，改进模型在检测任务中 Box 分支的精确度、召回率、F1 分数、mAP50 和 mAP50 - 95 分别达到 90.3%、85.3%、87.7%、92.7%、61.4%，较原模型分别提升 2.2、3.5、2.9、0.8、2.1 个百分点；Mask 分支的对应指标分别提升 2.5、5.1、3.9、2.3、1.5 个百分点。

(3)分蘖计数性能显著优化：MAE、RMSE 分别为 0.24、0.70 个，决定系数 R^2 为 0.950。测试样本统计显示，98.1% 的样本计数误差在 3 个分蘖以内，其中准确计数的样本比例较原模型提升 28.9 个百分点。改进模型可在复杂田间环境下实现一定准确性与实时性。

参 考 文 献

[1] CAO J, ZHANG Z, TAO F, et al. Integrating multi-source data for rice yield prediction across China using machine learning and deep learning approaches[J]. Agricultural and Forest Meteorology, 2021,297: 108275.

[2] WANG P, ZHANG Z, SONG X, et al. Temperature variations and rice yields in China: historical contributions and future trends[J]. Climatic Change, 2014, 124: 777 - 789.

[3] SINGH D, MORI T, ICHIURA S, et al. Estimation of tiller number in rice using a field robot and deep learning—investigating effects of dataset composition on tiller estimation accuracy—[J]. Engineering in Agriculture, Environment and Food, 2022, 15(2): 47 - 60.

[4] ZHANG Y, XIAO D, LIU Y. Automatic identification algorithm of the rice tiller period based on PCA and SVM[J]. IEEE Access, 2021,9: 86843 - 86854.

[5] REN M, HUANG M, QIU H, et al. Genome-wide association study of the genetic basis of effective tiller number in rice[J]. Rice, 2021,14(1): 56.

[6] YANG W, XU X, DUAN L, et al. High-throughput measurement of rice tillers using a conveyor equipped with X-ray computed tomography[J]. Review of Scientific Instruments, 2011,82(2): 025102.

[7] ZULKARNAIN W M, ISMAIL M R, SAUD H M, et al. Growth and yield response to water availability at different growth stages of rice[J]. Journal of Food, Agriculture & Environment, 2013,11(2): 540 - 544.

[8] HUANG Z, GONG L, LIU C, et al. Measurement of rice tillers based on magnetic resonance imaging[J]. IFAC - PapersOnLine, 2016,49(16): 254 - 258.

[9] HASAN M M, CHOPIN J P, LAGA H, et al. Detection and analysis of wheat spikes using convolutional neural networks[J]. Plant Methods, 2018,14: 1 - 13.

[10] MENG X, LI C, LI J, et al. Yolov7-ma: improved Yolov7-based wheat head detection and counting[J]. Remote Sensing, 2023,15(15): 3770.

[11] WANG X, YANG W, LV Q, et al. Field rice panicle detection and counting based on deep learning[J]. Frontiers in Plant Science, 2022,13: 966495.

[12] 王泰华,郭亚州,张家乐,等. 基于改进 YOLO v5s 的水稻害虫识别研究[J]. 农业机械学报,2024,55(11):39 - 48.
WANG Taihua, GUO Yazhou, ZHANG Jiale, et al. Rice pest identification based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 39 - 48. (in Chinese)

[13] 袁立存,周俊,戈为溪,等. 基于多模态知识图谱的水稻施肥期判别方法[J]. 农业机械学报,2024,55(9):163 - 173.
YUAN Licun, ZHOU Jun, GE Weixi, et al. Rice fertilization period discrimination method based on multi-modal knowledge graph[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 163 - 173. (in Chinese)

[14] DESAI S V, BALASUBRAMANIAN V N, FUKATSU T, et al. Automatic estimation of heading date of paddy rice using deep learning[J]. Plant Methods, 2019,15: 1 - 11.

[15] DENG R, JIANG Y, TAO M, et al. Deep learning-based automatic detection of productive tillers in rice[J]. Computers and Electronics in Agriculture, 2020,177: 105703.

[16] 崔家乐,曾祥峰,任政威,等. 基于轻量化 Ghost - YOLOv8 和智能手机的田间水稻有效分蘖检测方法[J]. 智慧农业(中英文),2024,6(5):98 - 107.
CUI Jiale, ZENG Xiangfeng, REN Zhengwei, et al. Detection method of effective tillering of rice in field based on lightweight Ghost - YOLOv8 and smart phone[J]. Smart Agricultural, 2024, 6(5):98 - 107. (in Chinese)

[17] 张岩琪,周硕,张凝,等. 基于改进实例分割算法的区域养殖生猪计数系统[J]. 智慧农业(中英文),2024,6(4):53 - 63.
ZHANG Yanqi, ZHOU Shuo, ZHANG Ning, et al. A regional farming pig counting system based on improved instance segmentation algorithm[J]. Smart Agricultural, 2024, 6(4):53 - 63. (in Chinese)

[18] 王福顺,王旺,孙小华,等. 基于改进 YOLO v8n - seg 的羊只实例分割方法[J]. 农业机械学报,2024,55(8):322 - 332.
WANG Fushun, WANG Wang, SUN Xiaohua, et al. Sheep instance segmentation method based on improved YOLO v8n - seg [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 322 - 332. (in Chinese)

[19] 李兆东,章艳芳,汪蕴红,等. 基于 YC - YOLO v7 模型的油菜幼苗株数识别方法[J]. 农业机械学报, 2024, 55(12): 322 - 332.
LI Zhaodong, ZHANG Yanfang, WANG Yunhong, et al. Identification of rapeseed seeding number based on YC - YOLO v7 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(12):322 - 332. (in Chinese)

[20] 翟肇裕, 张梓涵, 徐焕良, 等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报, 2024, 55(11): 1 - 20.
ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 1 - 20. (in Chinese)

[21] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 - 19.

(下转第 656 页)

[19] 廖娟,刘凯旋,杨玉青,等. 基于 RDN - YOLO 的自然环境下水稻病害识别模型研究[J]. 农业机械学报,2024,55(8):233 - 242.
LIAO Juan, LIU Kaixuan, YANG Yuqing, et al. Rice disease recognition in natural environment based on RDN - YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(8):233 - 242. (in Chinese)

[20] DU Y, GAO A, SONG Y, et al. Young apple fruits detection method based on improved YOLO v5[J]. INMATEH-Agricultural Engineering, 2024, 73(2). 84 - 93.

[21] 张帆,郭思媛,任方涛,等. 基于改进 YOLO v3 的玉米叶片气孔自动识别与测量方法[J]. 农业机械学报,2023,54(2):216 - 222.
ZHANG Fan, GUO Siyuan, REN Fangtao, et al. Automatic identification and measurement of maize leaves stomata based on YOLO v3[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(2):216 - 222. (in Chinese)

[22] 冀汶莉,刘洲,邢海花. 基于 YOLO v5 的农田杂草识别轻量化方法研究[J]. 农业机械学报,2024,55(1):212 - 222,293.
JI Wenli, LIU Zhou, XING Haihua. Lightweight method for identifying farmland weeds based on YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(1):212 - 222,293. (in Chinese)

[23] 袁杰,谢霖伟,郭旭,等. 基于改进 YOLO v7 的苹果叶片病害检测方法[J]. 农业机械学报,2024,55(11):68 - 74.
YUAN Jie, XIE Linwei, GUO Xu, et al. Apple leaf disease detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(11):68 - 74. (in Chinese)

[24] HUANG Y, HUANG H, QIN F, et al. YOLO - IAPs: a rapid detection method for invasive alien plants in the wild based on improved YOLOv9[J]. Agriculture,2024,14(12):2201.

[25] MAI R, WANG J. UM - YOLOv10: underwater object detection algorithm for marine environment based on YOLO v10 model [J]. Fishes,2025,10(4):173.

[26] HUO Y,ZHANG Y, XU J, et al. A small-sample target detection method for transmission line hill fires based on meta-learning YOLO 11[J]. Energies,2025,18(6):1511.

(上接第 606 页)

[22] WANG Y, LI J. Branching in rice[J]. Current Opinion in Plant Biology, 2011,14(1): 94 - 99.

[23] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008,77: 157 - 173.

[24] KHANAM R, HUSSAIN M. Yolov11: an overview of the key architectural enhancements[J]. arXiv Preprint, arXiv:2410.17725,2024.

[25] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779 - 788.

[26] LI Y, HOU Q, ZHENG Z, et al. Large selective kernel network for remote sensing object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 16794 - 16805.

[27] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818 - 2826.

[28] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for image classification with convolutional neural networks[C]// Proceedings of the the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 558 - 567.

[29] SHUAI L, MU J, JIANG X, et al. An improved YOLOv5-based method for multi-species tea shoot detection and picking point location in complex backgrounds[J]. Biosystems Engineering, 2023,231: 117 - 132.

[30] GAO H, WANG Z, JI S. Channelnets: compact and efficient convolutional neural networks via channel-wise convolutions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(8): 2570 - 2581.