基于改进YOLOv11s的机耕船水田秸秆耕整质量检测系统设计

涂 鸣[1,2] 李 峥[1] 涂海鹏[1] 刘羽航[1] 程志文[3] 张国忠[1,2*]
1.华中农业大学工学院,武汉,430070
2.农业农村部长江中下游农业装备重点实验室,武汉,430070
3.华友天宇科技(武汉)股份有限公司,武汉,430210

摘要:针对水田留茬秸秆泥水背景干扰强、秸秆目标尺度差异大、泥土易遮挡粘黏等问题,提出一种基于改进YOLOv11s的机耕船水田秸秆耕整质量检测系统,通过构建端到端目标检测网络,以耕整后秸秆埋覆状态为评价依据,实现对耕整质量的实时感知。将秸秆状态划分为嵌入、未嵌入和裸露三类目标,建立耕整质量评价指标,引入高效通道注意力(ECA)机制以增强关键特征表达能力,基于深度可分离卷积(DWConv)结构,减少模型冗余并提高推理效率;同时,结合自适应空间特征融合(ASFF)模块以提高不同尺度秸秆目标检测一致性,并引入背景抑制(BS)模块以降低泥水、光照、阴影等复杂背景对系统检测性能的影响。实验结果表明:在模型参数量仅增加0.4%的情况下,改进模型运行帧率达到128帧/s,且在多种水田作业场景下的精确率、mAP@0.5和mAP@0.5:0.95相较YOLOv11s分别提高了5.9%、4.6%和1.3%,并在Orange Pi 5 Plus平台上实现了耕整质量的实时检测与评估。

关键词:水田秸秆耕整;分布检测;YOLOv11模型;机耕船;农机作业调控
中图分类号:S222.3
DOI:10.3969/j.issn.1004-132X.2026.11.004 **开放科学(资源服务)标识码(OSID)**:

Design of a Paddy Field Straw Tillage Quality Detection System for Boat Tractor Based on an Improved YOLOv11s

TU Ming[1,2] LI Zheng[1] TU Haipeng[1] LIU Yuhang[1] CHENG Zhiwen[3] ZHANG Guozhong[1,2*]
1.College of Engineering, Huazhong Agricultural University, Wuhan, 430070
2.Key Laboratory of Agricultural Equipment for the Middle and Lower Reaches of the Yangtze River, Ministry of Agriculture and Rural Affairs, Wuhan, 430070
3.Wuhan Huayou Tianyu Technology Co., Ltd., Wuhan, 430210

Abstract: To address the challenges posed by strong background interference from muddy water in paddy fields, large differences in straw target size, and easy obstruction and adhesion by soil, a quality detection system for boat tractor paddy field straw tillage was proposed based on an improved YOLOv11s. By constructing an end-to-end target detection network, the system used the straw burial state after tillage as the evaluation criterion to achieve real-time perception of tillage quality. First, the straw state was divided into embedded, non-embedded, and exposed. A tillage quality evaluation index was established, and an efficient channel attention(ECA) mechanism was introduced to enhance the expression of key features. Based on a depthwise separable convolution(DWConv) structure, model redundancy was reduced and inference efficiency was improved. At the same time, an adaptive spatial feature fusion(ASFF) module was combined to improve the consistency of straw target detection at different scales, and a background suppression(BS) module was introduced to reduce the impact of complex backgrounds such as mud, water, light, and shadow on the system's detection performance. Experimental results show that with only a 0.4% increase in model parameters, the improved model achieves a frame rate of 128FPS. Furthermore, compared to YOLOv11s, the accuracy, mAP@0.5, and mAP@0.5:0.95 are improved by 5.9%, 4.6%, and 1.3%, respectively, in various paddy field operation scenarios. Real-time detection and evaluation of tillage quality are also achieved on the Orange Pi 5 Plus platform.

Key words: paddy field straw tillage; distribution detection; YOLOv11 model; boat tractor; regulation and control of agricultural machinery operations

收稿日期:2026-03-11
基金项目:国家自然科学基金(32572223);湖北省农机装备补短板核心技术应用攻关项目(HBSNYT202204);中央高校基本科研业务费专项资金(2662024GXPY013)

0 引言

稻田和藕田等水田土壤承载力低、泥脚深厚、

秸秆残茬覆盖复杂，传统轮式与履带式拖拉机耕整时易沉陷，难以有效挂接和操控耕整机具，导致作业质量难以保证。机耕船采用浮式底盘与动力叶轮，在深泥脚田具有良好的通过性与适应性，已成为此类区域重要的耕整作业装备[1]。然而当前机耕船耕整作业仍需依赖机手经验，缺乏对耕整质量的实时感知与客观评价手段，致使秸秆还田效果不稳定、土壤结构改善不均[2]。

通过检测机耕船耕整后的秸秆埋覆分布并及时调整作业参数，能有效减小传统人工目视判断的主观性误差，提升耕整质量。安晓飞等[3]基于K-means算法和彩色空间距离方法实现了秸秆和土壤背景的分类识别，秸秆平均识别准确率达到88%，整体秸秆覆盖率准确度达到98.18%。杨光等[4]先后使用改进的AdaBoost和Bernsen算法，通过彩色空间距离化、图像增强等方式实现了秸秆的特征识别和覆盖率检测。刘媛媛等[5]利用多目标图像分割方法，在大尺度无人机图像中获得了较好的秸秆识别与覆盖率检测效果。阈值分割等传统机器视觉方法对光照环境的敏感度较高，因此需要结合深度学习算法，以增强在复杂环境下秸秆识别的鲁棒性和抗干扰性[6]。YOLO[7]系列算法具有检测速度快、结构精简的特点，在保持较高精度的同时，更易满足装备实时检测帧率要求。罗亮等[8]提出的改进YOLOv8气缸套缺陷检测方法的帧率达到476帧/s，提高了2%的识别精度并降低了0.7浮点运算数。王俊等[9]基于目标识别技术提出了改进YOLOv5s的风电叶片表面缺陷检测方法，推理速度可达138帧/s。袁媛等[10]在YOLOv8原有模块中引入轻量动态采样模块，实现了输送带损伤的有效识别，检测速度达到83帧/s。肖御风等[11]提出了一种融合YOLO v11-Seg与Transformer模型的实时预测方法，引入注意力模块和损失函数用于刀具磨损检测。罗杭等[12]构建的SGV-YOLOv8模型通过引入GSConv模块和VoV-GSCSP结构实现了工业机器人80%的零件抓取成功率。邹俊逸等[13]改进了YOLOv7-tiny模型，使其在检测路面平整度中的检测时间缩短了3.4 ms。

然而，当前YOLO直接应用于机耕船耕整质量检测中仍面临挑战：一方面，作物秸秆目标尺度差异较大、排列密集，且常与泥土、水体背景颜色相近，存在遮挡与粘黏现象，需进一步提高目标的识别能力；另一方面，田间作业光照多变、机具振动频繁，对模型的鲁棒性与泛化能力要求更高。此外，现有研究多集中于旱地或常规水田环境，有关深泥脚、高植被覆盖等环境下秸秆埋覆状态的实时检测研究较少，更缺乏适用于机耕船嵌入式平台的轻量化、高精度检测模型。

本文以水田留茬秸秆为研究对象，提出了一种基于YOLOv11s的嵌入式部署改进检测方法，首先引入高效通道注意力（efficient channel attention，ECA）模块、自适应空间特征融合（adaptively spatial feature fusion，ASFF）模块和背景抑制（background suppression，BS）模块，以增强模型对秸秆特征表达、多尺度特征融合判别及土壤背景的抗干扰能力；同时在跨阶段部分空间注意力（cross stage partial with spatial attention，C2PSA）模块中采用深度可分离卷积（depthwise separable convolution，DWConv）结构降低参数量与计算冗余，提高推理实时性；通过分析留茬秸秆空间分布状态，实时评估机耕船耕整作业质量，为整机关键作业参数的动态调控提供可靠依据。

1　水田土壤留茬秸秆数据集建立

实验用水田土壤与秸秆分别为南方稻区黏壤土和当季收割后的水稻留茬秸秆，于华中农业大学水稻实验田（北纬30°28′，东经114°21′）采集后栽植在长30 m、宽2.5 m的水田土槽中，以保证实验条件与田间基本一致。机耕船触土部件与实验仪器搭载在水田动力测试平台（图1），实验时的行进速度为0.5～1.2 m/s，工业相机型号为海康MV-CS060-10UC-PRO，运行帧率为59.6帧/s，实时拍摄机耕船运行时动力叶轮与耕整部件碾压后的留茬秸秆图像，土槽内水层控制在1～8 cm，符合水稻播种或插秧前农艺要求，可保证后续模型训练和评估数据与实际应用场景的一致性。为提高数据多样性和模型泛化能力，采集过程中选用35 W和50 W两种光源，光源入射角度分别设置为与水平面呈60°和80°，以模拟晴天、阴天及早晚时段的典型光照条件开展拍摄，所采集的图像包含泥水飞溅、秸秆瞬时位移、水面波动等动态作

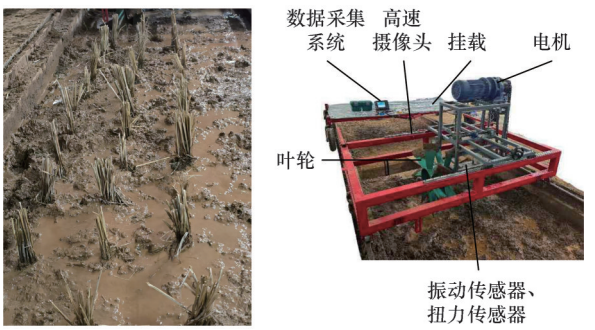

图1　实验土槽及水田动力测试平台

Fig.1　Experimental paddy field trough and paddy field power testing platform

业场景下的典型状态，筛选后整理得到1457张原始图像。

为使检测模型在训练中具有稳定的泛化能力，预处理原始图像数据集，在标注完成后以6∶2∶2的比例划分训练集、验证集和测试集；同时为提高网络检测能力，采用上下旋转、左右镜像及增加高斯噪声3种图像处理技术随机结合的方式对图像实施数据集增强（图2），得到的训练集、验证集和测试集图像分别为2622张、873张和874张。



(a)原图　(b)左右随机



(c)上下随机　(d)高斯噪声

图2　数据集增强

Fig.2　Data set augmentation

采用LabelImg标注原始图像，结合秸秆倒伏认定标准和水田秸秆埋覆特征，将耕整后的秸秆主要分为3个种类（图3）：①秸秆被埋入泥水、仅顶端微露且与地面倾斜夹角大于75°的标注为嵌入（对应标签为qianru）；②秸秆倾斜与地面夹角介于15°～75°之间仍有大部分裸露于泥面或呈倒伏状的标注为未嵌入（对应标签为weiqianru）；③未埋入的独立秸秆或秸秆与地面夹角小于15°的标注为裸露（对应标签为luolu）。

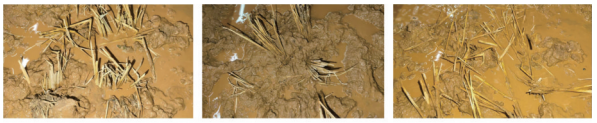

(a)嵌入　(b)未嵌入　(c)裸露

图3　秸秆埋覆特征分类

Fig.3　Classification of residual straw after tillage

在实验过程中，通过检测嵌入、未嵌入与裸露三类秸秆状态，综合评价机耕船在深泥脚、烂泥地等复杂水田环境中的耕整质量。其中，嵌入类秸秆占比越高，表明耕整效果越好；而未嵌入类与裸露类秸秆占比过高，则反映耕整不充分或作业参数有待优化。通过量化分析上述三类秸秆的空间分布与数量比例，为优化耕深、行进速度与叶轮转速等关键作业参数提供依据，可实现耕整质量的动态调控。

2　水田留茬秸秆分布检测模型

2.1　YOLOv11模型

YOLOv11是由Ultralytics于2024年9月发布的模型，结构主要由输入层（Input）、主干网络（Backbone）、颈部网络（Neck）、头部网络（Head）四部分组成，模型引入了C3K2和C2PSA两个全新模块替代YOLOv8中的C2f模块，参数量在减少20%的同时保证了识别精度和检测速度[14]。

YOLOv11依据网络深度和宽度划分为微型（n）、小型（s）、中型（m）、大型（l）、超大型（x）五类，复杂度和计算量依次增强，计算速度逐渐减小。针对机耕船在稻田、藕田等高湿泥泞的复杂水田环境下的实时检测需求，本文选用YOLOv11s作为基础模型，在保持较高识别精度的同时具备更快的推理速度，适合部署于机载嵌入式平台等计算资源与功耗受限的移动装备上，能够有效满足秸秆目标的实时检测与耕整质量在线评估的要求。

2.2　改进YOLOv11s模型

针对水田土壤中留茬秸秆目标存在尺寸差异大、与泥水背景对比度低、分布密集易漏检等检测难点，为提高模型对多状态秸秆（嵌入、未嵌入、裸露）的识别准确率与鲁棒性，本文对YOLOv11s模型进行改进：将主干网络中的C2PSA模块替换为DW-C2PSA模块，在降低参数量与计算复杂度的同时保持特征提取能力，利于在嵌入式设备上实现高效推理；在Neck网络中3个C3K2模块后分别加入ECA模块以强化模型的特征表达，通过增强对秸秆判别性通道的响应，提高模型在复杂泥水背景下的特征选择能力；引入ASFF模块，加权融合不同层级特征，增强模型对多尺度秸秆（如局部裸露的细长秸秆与成簇分布的秸秆团）的检测一致性与泛化能力；最后在C3K2模块中加入BS模块得到BS-C3K2模块，通过抑制泥、水等背景噪声的响应，降低误检率，提高秸秆目标与背景的分离能力，提高秸秆识别准确率。针对秸秆工作（straw work，SW）的改进SW-YOLOv11s模型网络结构如图4所示。

2.2.1　ECA注意力机制

ECA是一种轻量化注意力模块[15]，目的在于通过仅增加少量参数来提高模型对秸秆耕整后倒伏角度等特征的关注度，从而提高特征表达能力。图5所示为ECA模块主要结构及特征图维度变化，其中C为特征图通道维度，H为特征图高

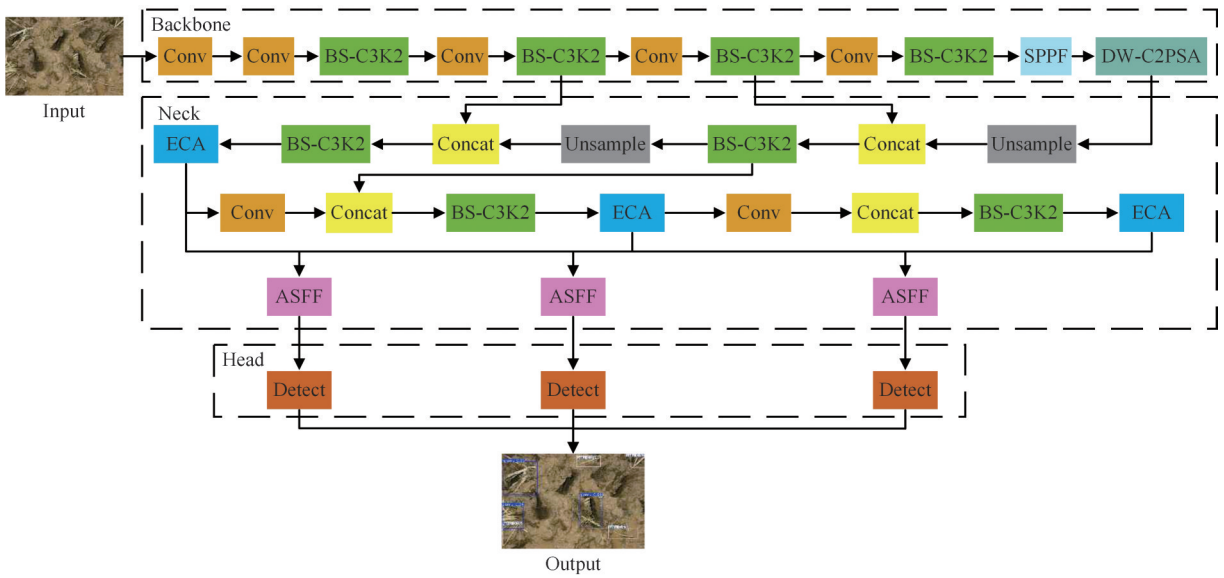

图4　SW-YOLOv11s结构图

Fig.4　Structure diagram of SW-YOLOv11s

度，GAP为间距，W为特征图宽度，卷积核尺寸k由下式确定：

$$k=odd(|\frac{\log_2 C}{\gamma}+\frac{b}{\gamma}|) \tag{1}$$

式中：γ、b为预设的超参数，其中γ设置为2，b为向上取整的最小奇数；$odd(\cdot)$表示函数值向上取最近奇数。

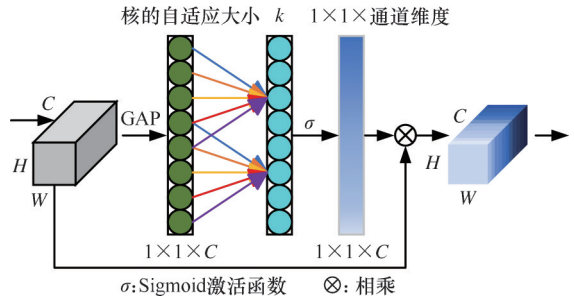

图5　ECA模块结构

Fig.5　ECA module structure

ECA模块首先对输入形状为$C\times H\times W$的特征图进行全局平均池化，在GAP将每个通道信息压缩为$1\times1\times C$的通道描述向量，随后在该向量上施加自适应一维(1D)卷积实现局部跨通道交互，最后通过Sigmoid激活函数转换为介于0～1之间的权重后用于对原始输入特征图的每个通道进行加权，生成$1\times1\times C$的通道注意力权重，以实现对重要通道的增强和对不重要通道的抑制。图像数据在ECA模块中，输入特征图在被压缩成1×1的空间维度后会转换成一维数据进行卷积操作，之后数据再转换回二维与原始输入特征图逐元素相乘，以实现通道特征的增强。

ECA模块使用1D卷积替代了传统全连接层，降低了计算复杂度和参数量，使YOLOv11s在计算复杂度成本较低的情况下提高了对秸秆目标的检测准确率。

2.2.2　改进C2PSA模块

C2PSA模块是在YOLOv8模型基础上新加入Backbone结构中的模块[16]，主要由跨阶段部分连接(cross stage partial，CSP)网络结构和Attention注意力机制组成，能够减少冗余计算、提高网络特征提取效率和增强对空间信息的建模能力。C2PSA模块通过结合CSP结构和极化自注意力(polarized self-attention，PSA)，能有效增强网络对图像关键区域的表征能力并抑制计算效率的减弱，从而提高模型对耕整后秸秆埋伏状态的检测精度。输入至C2PSA模块的特征图会经过CSP结构分段处理，一部分会保留原始特征，另一部分通过PSABlock模块完成特征增强。PSABlock模块集成了自注意力机制和前馈网络，能够捕捉特征图中的长距离依赖关系，在通道维度上拼接处理和未处理的分支，从而完成特征的融合。

虽然C2PSA模块通过CSP结构和PSA机制提高了性能，但其原始设计仍存在不足，特别是cv1(C2PSA模块中第一个卷积层)和cv2(C2PSA模块中最后一个卷积层)采用的常规卷积操作导致模型运算量较大，在对高分辨率田间图像或深层网络前向推理时，这部分计算负担易造成推理延迟与功耗上升，显著增加了设备计算单元、内存及能耗的资源需求，限制了该模块在机耕船搭载的嵌入式设备上的部署可行性。本文对C2PSA模块进行了改进，将原始设计中的常规卷积全部替换为DWConv结构[17]，DWConv结构将常规卷积的操作分解为深度卷积和逐点卷积，减少了参数量和计算复杂度，同时保留了卷积应有的特征

提取能力，改进后的C2PSA模块在不损失检测精度的前提下优化了网络参数量和推理速度，实现了模型的轻量化。此外，DWConv结构的轻量化特性使C2PSA模块能够完成多尺度的特征处理，进一步增强了模型的泛化能力。图6所示为优化后的DW-C2PSA结构，其中包含N个PSABlock模块。通过这种优化，C2PSA模块能够使模型在移动端或嵌入式设备上尽力维持原有的性能和效率。

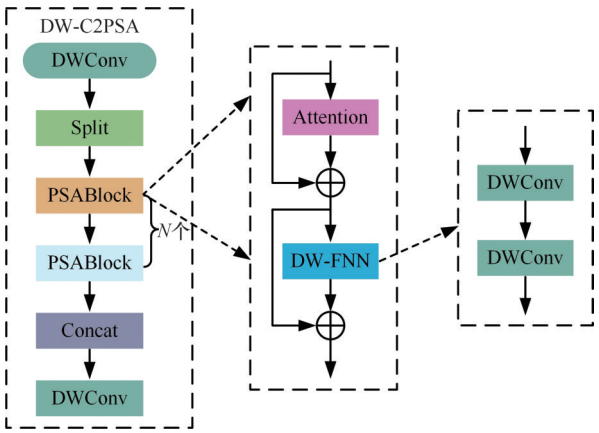

图6 DW-C2PSA结构图

Fig.6 Structure diagram of DW-C2PSA

2.2.3 ASFF模块

传统的特征金字塔网络(feature pyramid network，FPN)在特征融合过程中存在尺度不一致或特征冲突等问题，传统FPN使用固定的加法或拼接等方式融合多尺度特征时，容易忽略不同层特征之间的空间和语义差异，限制了FPN在小目标与大目标并存场景中的表现力。而ASFF模块[18]的主要目标是通过自适应学习权重来融合来自不同尺度的特征图，使网络能够动态筛选出每一层特征图中最有用的信息，从而提高检测的精度。ASFF模块通过引入可学习的权重参数动态调整每一层特征的贡献，优化特征融合过程，进而提高目标检测的精度，其结构如图7所示。

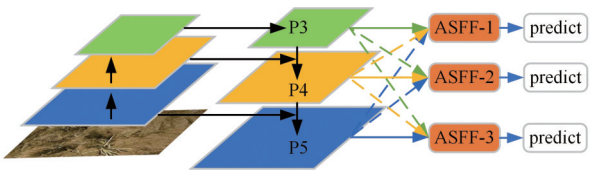

图7 ASFF模块结构

Fig.7 ASFF module structure

由图7可知，ASFF模块接受多个尺度的输入特征，P3(高分辨率用于小目标检测)、P4(中等分辨率)、P5(小分辨率用于大目标检测)是特征金字塔中不同层级的特征。ASFF-1、ASFF-2和ASFF-3分别表示应用了ASFF机制的不同层级特征融合。ASFF模块为每个空间层位置生成一组权重，通过权重动态调整每个尺度特征的贡献程度，根据目标大小和场景特性，自适应地选出最优的特征组合，从而缓解大目标特征与小目标特征之间的冲突。ASFF模块首先通过1×1卷积将不同尺度的输入特征图统一至相同的通道数，以确保后续融合的兼容性，根据目标输出层的分辨率，使用上采样或下采样操作将所有特征图调整到相同的空间尺寸；随后，沿通道维度拼接调整后的特征图，通过一个1×1卷积层生成权重图，权重图的通道数对应输入特征图的数量，并通过Softmax函数归一化处理，确保权重和为1；最后，利用权重对调整后的特征图进行加权求和，生成融合后的特征图。在ASFF-3中生成的用于预测的融合特征Y的计算公式如下：

$$Y=\alpha x^{1\to 3}+\beta x^{2\to 3}+\gamma x^{3\to 3} \tag{2}$$

式中：α、β、γ分别为3个尺度特征图的加权系数；$x^{1\to 3}$、$x^{2\to 3}$、$x^{3\to 3}$分别表示将P3、P4、P5特征调整至与P5(第3尺度)相同尺寸后的特征图，其中$x^{3\to 3}$为P5特征图本身，不作尺度变换。

ASFF模块在仅增加少量计算复杂度的同时，保留了多尺度特征的丰富信息，并通过自适应权重优化了融合效果。由于嵌入、未嵌入和裸露3个种类的秸秆图像中小目标和大目标检测并存，采用ASFF模块融合可增强大、小秸秆特征的区分度，在保留多尺度特征丰富信息的同时，还通过自适应权重优化了融合效果，提高了3个种类秸秆的识别精度。

2.2.4 改进C3K2模块

在目标检测领域，背景干扰是影响模型性能的一个关键因素[19]。在深泥脚、烂泥田等场景中，土壤与水体混合、表面反光和泥浆飞溅等因素会引入显著噪声，同时被分到裸露类的秸秆属于单一细长杆状类目标，在图像中常呈倾斜或局部遮挡状态，检测框中往往包含大量背景区域，易导致误检或漏检，因此，在YOLOv11s模型中的特征融合阶段添加BS模块，以减少背景信息对多尺度特征融合的干扰，增强模型对前景目标的关注度。

在实验中将BS模块引入到C3K2模块的输出后得到改进的BS-C3K2模块，其结构如图8所示，图中特征图在经过BS模块时发生了特征维度的改变。在C3K2模块的输出后添加一个轻量级分支，通过使用一个1×1卷积将通道压缩至1，生成单通道的背景概率图(bg_prob)，同时使用前景权重1-bg_prob与原始特征逐元素相乘，保留前景目标特征，抑制背景区域特征。由于在网络中引入ECA模块，BS-C3K2模块输出的特征图输入至ECA模块后，实现了对重要通道的增强，使秸

秆经耕整后倒伏的角度等特征更为显著。最后将特征图输入至ASFF模块中完成对多尺度特征的融合，实现了裸露类秸秆目标检测精度的提高。

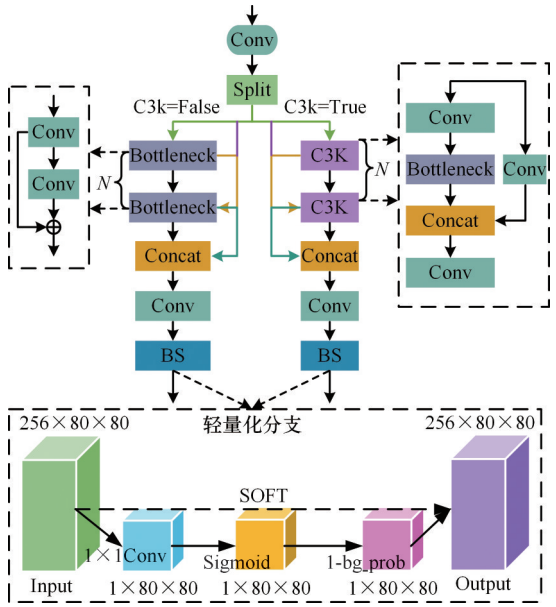

图8　BS-C3K2模块结构

Fig.8　BS-C3K2 module structure

2.3　实验环境与配置

实验所用操作系统为Windows 11，CPU型号为AMD Ryzen 7 5800H with Radeon Graphics@3.20GHz，GPU型号为NVIDIA GeForce RTX 3060 Laptop GPU，运行内存为6.0 GB，开发语言为Python 3.11，使用的深度学习框架为Pytorch 2.2.2，CUDA版本为11.8。具体环境配置参数如表1所示。

表1　实验参数配置表

Tab.1　Experimental parameter configuration table

超参数	设置值	超参数	设置值
批次大小	16	初始学习率	0.01
训练轮数	200	关闭马赛克增强	0
早停耐心值	20	单类别模式	False
输入图像尺寸	640	丢弃率	0.5
优化器	SGD	动量系数	0.937

实验中设置关键参数patience为20，表示在训练过程中若模型的性能在验证集上超过20轮没有明显提升，则触发早停策略。参数的设置是为了防止模型在没有性能提升的同时损失函数达到收敛时仍继续训练导致的过拟合现象发生。实验结果表明，基础模型YOLOv11s在训练过程中的第142轮会触发早停机制，而本文所提改进模型SW-YOLOv11s能够完成200轮训练。

2.4　评价指标

本文采用精确率(Precision)、召回率(Recall)、平均精度均值(mean average precision，mAP)、F1分数(F1 score)、参数量(Parameters)作为评价指标[20]，以评价模型对耕整后水田留茬秸秆的检测性能，精确率P、召回率R、平均精度均值、F1分数S_{F1}的计算表达式分别如下：

$$P=\frac{N_{TP}}{N_{TP}+N_{FP}} \qquad R=\frac{N_{TP}}{N_{TP}+N_{FN}}$$

$$V_{mAP}=\frac{1}{n}\sum_{i=1}^{n}\int_{0}^{1}P(R)\mathrm{d}R \qquad S_{F1}=2\frac{PR}{P+R}$$

式中：N_{TP}为模型预测中的正确数量(true positive，TP)；N_{FP}为预测中的错误数量(false positive，FP)；N_{FN}为实际检测中模型未检测到的数量(false negative，FN)；n为目标样本的数量；V_{mAP}为所有类别的平均精度的均值，常用mAP@0.5和mAP@0.5:0.95两个指标来衡量，前者表示交叉比(intersection over union，IoU)阈值取0.5时的平均精度均值，后者表示对IoU阈值从0.5～0.95、步长为0.05的10组mAP求均值的结果。

3　结果与分析

3.1　改进YOLOv11s模型的实验结果

表2所示为改进模型SW-YOLOv11s在不同类别秸秆上的检测效果。由表2可知，模型对未嵌入、嵌入和裸露三类秸秆目标检测的mAP@0.5分别为92.6%、89.5%和87.3%；不同秸秆目标检测的P、R和mAP@0.5均值分别为89.2%、85.7%和89.8%。尽管大量不同类别的秸秆相互交错、互相重叠，但改进模型仍能较好地将其区分识别，验证了模型的鲁棒性和有效性，能够满足复杂秸秆环境下对不同种类秸秆进行检测的要求。

表2　SW-YOLOv11s模型检测结果

Tab.2　Detection results of SW-YOLOv11s model

种类	检测数量/张	指标			
		P/%	R/%	mAP@0.5/%	F1分数/%
未嵌入	301	90.6	86.6	92.6	88.6
嵌入	277	89.7	85.9	89.5	87.8
裸露	296	87.3	84.7	87.3	86.0
平均值		89.2	85.7	89.8	87.4

3.2　消融实验

为验证改进模型的性能，对测试集设置6组消融实验，实验1为YOLOv11s基础模型，实验6为改进的SW-YOLOv11s，实验2～实验5分别引入轻量化C2PSA、ECA、ASFF和BS模块。实验结果如表3所示，对比实验2和实验1可知，模型经轻量化C2PSA改进后P、mAP@0.5和mAP@0.5:0.95分别提高了2.6%、1.4%和0.9%，表明该模块在降低参数量与计算复杂度的同时可强化对秸秆目标的特征学习能力，进而提高检测精度；实验3较实验1单独引入ECA模块后，P、R和mAP等指标均有提升，表明通过可选择的自适应卷积

核调整网络的感受野大小并生成自适应权重，实现了对秸秆重要特征通道的加强和不重要特征通道的抑制，从而提高了模型的识别精准率；实验4和实验5分别较实验1单独引入ASFF模块和BS模块进行多尺度特征融合后，实验结果均有提升，表明ASFF模块和BS模块能够实现多尺度上的特征融合，同时抑制大小目标特征的冲突并保留目标的重要特征，从而提高对大小秸秆目标的检测精度；将实验5和实验1对比，单独使用BS模块后P提高了3.3%，能有效提高检测的准确率；将实验6和实验1对比，发现改进SW-YOLOv11s模型的P达到最高，比基础模型高出5.9%，且R、mAP@0.5和mAP@0.5:0.95分别提高了3.2%、4.6%和1.3%，有效提高了模型对水田留茬秸秆的识别能力，为后续分布耕整质量检测与耕整参数优化提供基础。

表3 消融实验结果

Tab.3 Results of ablation experiments %

序号	C2PSA	ECA	ASFF	BS	P	R	F1分数	mAP@0.5	mAP@0.5:0.95
1	×	×	×	×	83.3	82.5	82.9	85.2	57.9
2	√	×	×	×	85.9	81.4	83.6	86.6	58.8
3	×	√	×	×	87.9	87.0	87.5	87.2	58.2
4	×	×	√	×	87.3	87.1	87.2	87.4	58.9
5	×	×	×	√	86.6	86.3	86.5	86.9	57.8
6	√	√	√	√	89.2	85.7	87.4	89.8	59.2

注："√"表示基础模型引用了此模块，"×"表示基础模型并未引用此模块。

3.3 YOLO各版本检测模型对比实验

为了进一步验证本文所提模型的性能，选取YOLOv5s、YOLOv6s、YOLOv8s、YOLOv9s和YOLOv10s等其他版本模型进行对比[21]，结果如表4所示。本文提出的SW-YOLOv11s模型在P、R和mAP等指标上均优于其他模型的对应指标，参数量较YOLOv11s基础模型仅增加了0.4%，运行帧率达到128帧/s，较YOLOv11s基础模型的帧率提高了9.4%，在保证满足实时检测要求的同时提高了模型各项性能指标，适合于部署在资源有限的嵌入式硬件设备上。为更直观地展现出各模型在训练过程中的差异，将各模型的mAP@0.5曲线绘制于图9，可知改进后模型的识别效果优于其他模型。

表4 不同模型在测试集中的实验结果

Tab.4 Experimental results of different models in the test set

模型	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	帧率/(帧·s^{-1})	参数量/M
YOLOv5s	77.6	80.2	81.3	55.5	124	9.11
YOLOv6s	85.9	84.0	86.7	57.8	113	16.30
YOLOv8s	82.7	82.0	84.1	56.6	128	11.13
YOLOv9s	80.3	80.5	81.7	55.6	122	7.17
YOLOv10s	78.9	78.2	80.1	54.9	119	8.04
YOLOv11s	83.3	82.5	85.2	57.9	117	9.41
SW-YOLOv11s	89.2	85.7	89.8	59.2	128	9.45

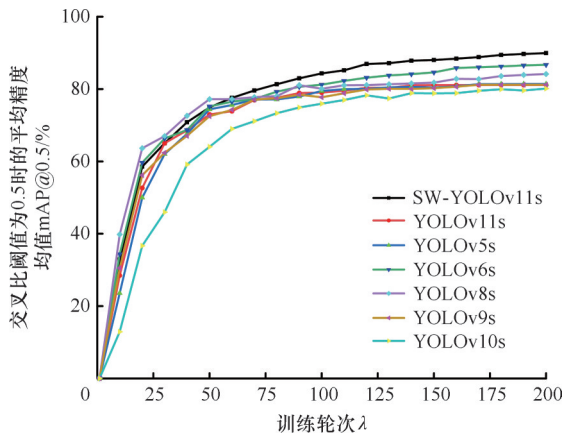

图9 各模型mAP@0.5变化曲线

Fig.9 Variation curves of mAP@0.5 for each model

3.4 改进前后可视化分析

为对比改进前后模型的检测能力，将基础模型YOLOv11s与改进后模型SW-YOLOv11s在测试集上进行结果比较。同时为模拟实际作业中的动态环境，数据集中包含机耕船作业过程中叶轮扰动泥水、秸秆位移等动态场景图像，选取强光、泥水、弱光和背景阴影杂乱等多种情况下的模型检测情况，对比改进前后的漏检、误检与置信度情况来判断模型性能。如图10所示，强光和泥水条件下基础模型YOLOv11s存在漏检(红色矩形框标注)，产生的原因可能是模型对小目标特征提取不足，改进后模型的检测置信度分别为0.93和

0.95，较基础模型提高了0.06和0.33，且无漏检现象；弱光和背景阴影杂乱条件下，基础模型由于受到背景干扰存在误检（黄色圆框标注），改进后模型的检测置信度分别为0.93和0.95，较基础模型提高了0.07和0.16，且无误检现象。

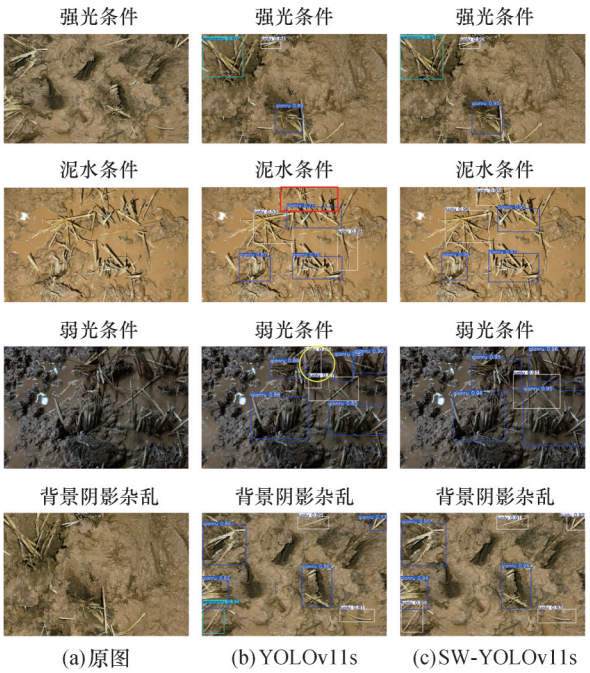

图10　模型检测结果对比

Fig.10　Comparison of model detection results

3.5　BS模块对模型在测试集上表现的影响

测试过程中发现，部分在验证集上表现良好的模型，在测试集上mAP@0.5和mAP@0.5:0.95可能会出现1%～2%的降低。同时在实验中发现，当模型引入BS模块后降低的效果会得到削弱，表5所示为YOLOv11s和SW-YOLOv11s模型在引入BS模块前后，验证集和测试集的表现效果差异。从表5中数据可以看出，YOLOv11s模型未引入BS模块时，测试集相对于验证集的mAP@0.5和mAP@0.5:0.95两个指标分别下降了0.7%和0.6%，引入BS模块后两个指标的降幅分别为0.4%和0.3%；SW-YOLOv11s模型未引入BS模块时，测试集相对于验证集的mAP@0.5和mAP@0.5:0.95两个指标分别下降了1.2%和0.9%，引入BS模块后两个指标的降幅分别为0.6%和0.4%，表明SW-YOLOv11s模型引入BS模块后，可将验证集至测试集的指标衰减抑制约50%，有效提高了模型的泛化能力，同时可以提高对秸秆的检测精度，满足检测要求。

表5　BS模块对测试集的影响实验结果

Tab.5　Experimental results of BS module influence on the test set

模型	指标	有BS模块		无BS模块	
		验证集	测试集	验证集	测试集
YOLOv11s	mAP@0.5/%	85.3	84.9	84.1	83.4
	mAP@0.5:0.95/%	56.5	56.2	55.5	54.9
SW-YOLOv11s	mAP@0.5/%	89.0	88.4	88.9	87.7
	mAP@0.5:0.95/%	59.6	59.2	58.6	57.7

3.6　秸秆分布指标制定

为客观评价秸秆分布对机耕船在深泥脚、烂泥地等环境中耕整质量的影响，制定基于视觉的秸秆分布量化指标，目前有关秸秆的分布指标主要包括密度、人均占有量、草谷比以及收集系数等，这些指标的主要作用是评估全国各地的资源潜力[22]。结合深泥脚水田耕整特点，本文以秸秆埋覆状态为耕整质量的间接评价依据，将每一个图像帧分为左、中、右三块区域，中间区域为叶轮工作区域，如图11所示，其中NWA代表非工作区域，WA代表工作区域。定义作业质量评价指标如下：分析每一个图像帧上的秸秆检测结果，当工作区域内未嵌入以及裸露的秸秆数量小于或等于当前图像所有秸秆目标的15%时，判断此时水田动力装置测试平台对土壤的耕整质量为良好以“Good”表示，当该比例为15%～50%之间时判断耕整质量为一般以“Mediocre”表示，当该比例在50%以上时，判断耕整质量为较差以“Bad”表示。

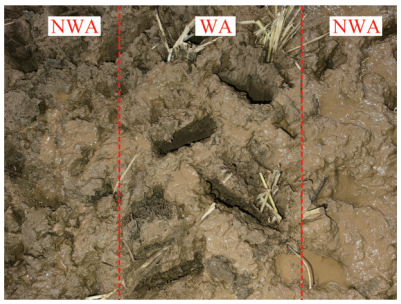

图11　工作区域划分方法

Fig.11　Dividing method of work area

3.7　部署分布测试结果

为衡量YOLOv11s与SW-YOLOv11s模型部署在Orange Pi 5 plus平台上的性能差异以及实时秸秆分布检测性能，选取测试集的图片进行推理检测。将训练完成的模型pt文件依次转换为onnx文件及rknn文件后部署在Orange Pi 5 plus平台，再将该平台安装在机耕船上开展实时运行检测。测试时，机耕船以约0.8 m/s的速度行进，摄像头以30帧/s的帧率采集图像，模型逐帧推理，Orange Pi 5 plus平台上的部署测试情况如图12所示，运行实时检测帧率为27帧/s，处理单帧图像的平均耗时为37 ms，系统整体输出延迟小于50 ms，检测频率满足水和秸秆的动态变化要求，能够实现对耕整质量的连续、稳定感知。在

连续30 min的测试中，帧率波动小于±2帧/s，改进模型未出现泥水飞溅、光照突变等动态干扰导致的长时间漏检或误检问题。

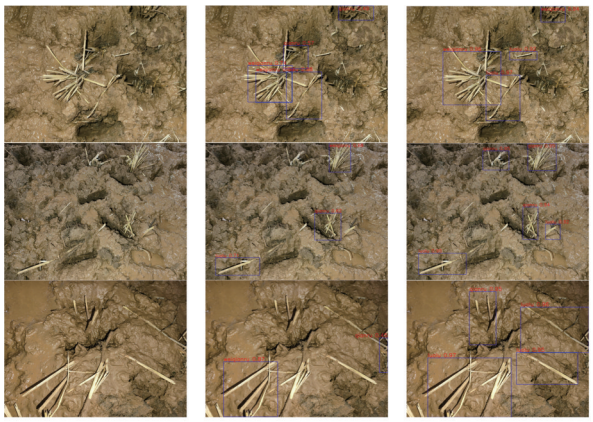

(a)原图 (b)YOLOv11s (c)SW-YOLOv11s

图12 Orange Pi 5 plus部署两模型的检测结果

Fig.12 Detection results of two models deployed by Orange Pi 5 plus

基于14组有效测试样本进行统计，经计算得到改进模型检测值与人工统计真值的平均绝对误差为0.9%，其表达式如下：

$$\bar{E}_a=\frac{1}{M}\sum_{i=1}^{M}|R_{det,i}-R_{gt,i}|$$

式中：$\bar{E}_a$为平均绝对误差；$R_{det,i}$、$R_{gt,i}$分别为第i组样本下SW-YOLOv11s模型和人工计数获取的未嵌入及裸露秸秆数量占工作区域的比例；M为有效测试样本总数量，本实验取M=14。

表6展示了4组典型样本下两模型秸秆分布检测得到的耕整工作区域及人工计数工作区域的比例值。研究结果表明，改进后的SW-YOLOv11s模型能够在嵌入式平台上实现准确、高效的秸秆分布检测，满足在水田深泥脚环境中耕整质量的实时感知需求。

表6 秸秆分布检测结果对比

Tab.6 Comparison of straw distribution detection results

测试数据	YOLOv11s		SW-YOLOv11s		人工计数	
	比例/%	判断	比例/%	判断	比例/%	判断
测试1	11.11	Good	16.67	Mediocre	15.79	Mediocre
测试2	22.22	Mediocre	25.12	Mediocre	25.89	Mediocre
测试3	28.57	Mediocre	24.33	Mediocre	25.24	Mediocre
测试4	10.21	Good	12.11	Good	12.50	Good

为更加直观地显示改进前后模型的检测过程，将识别的图片生成检测热力图，利用高斯核计算秸秆目标的分布密度，用来分析改进模型和基础模型在不同区域内的关注度。图13为测试集得到的网格图及热力图，热力图中红色越深代表关注度越高，黄色代表关注度次之，蓝色代表对图像识别的影响较小。由图13可以看出，本文提出的SW-YOLOv11s模型的检测网格图与热力图更加贴近真实秸秆分布的区域，可以在复杂环境下有效提取秸秆分布特征，从而提高秸秆判别准确性。

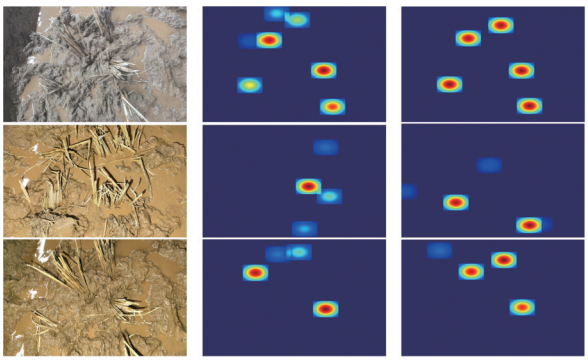

(a)原图 (b)YOLOv11s (c)SW-YOLOv11s

图13 Orange Pi 5 plus部署两模型的热力图

Fig.13 Heatmap of two models deployed by Orange Pi 5 plus

3.8 水深对检测性能的影响分析

水田秸秆耕整时，水层深度会影响泥水背景光学特性及秸秆可见度，实验时将水层划分为3个不同的深度：小于3 cm为浅水层；3～6 cm为中水层；6～8 cm为深水层。图14和表7所示分别为改进模型对3种水深秸秆检测的识别效果和检测结果，相较于浅水层，中水层和深水层时模型的P、R和mAP@0.5等指标均有降低，分析原因是水深导致的泥水散射增强，部分嵌入状态的秸秆边缘被泥水浸没，模型检测精度略有下降，但精确率P值仍保持在88%以上，表明泥水对光线的吸收与散射作用有限，秸秆与背景间的对比度较高，改进模型能够稳定地提取秸秆形态与埋覆特征，验证了在水深波动情况下仍具有一定的鲁棒性。

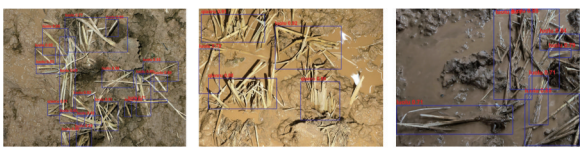

(a)浅水层 (b)中水层 (c)深水层

图14 不同水深识别效果

Fig.14 Recognition performance at different water depths

表7 SW-YOLOv11s模型对不同水深条件检测结果

Tab.7 Detection results of the SW-YOLOv11s model under different water depth conditions

水深	检测数/张	P/%	R/%	mAP@0.5/%	F1分数/%
浅水层	255	91.2	87.2	92.1	89.2
中水层	217	90.7	86.8	91.8	88.7
深水层	241	88.2	84.3	89.4	86.2

4　结论

1)提出SW-YOLOv11s模型用于机耕船在深泥脚水田秸秆耕整质量检测。针对秸秆目标尺度差异大、背景干扰强、部署平台资源有限等问题，在YOLOv11s骨干网络中采用轻量化DW-C2PSA模块，以深度可分离卷积降低参数量；在Neck部分嵌入ECA模块，增强对秸秆判别性特征的提取能力；引入ASFF模块，提高模型对多尺度秸秆目标的检测一致性；在C3K2模块中集成背景抑制算法，有效抑制泥水背景干扰。通过上述改进，模型在保持较高推理速度的同时显著提高了在复杂水田环境下对秸秆状态的识别精度。

2)实验结果表明，改进模型SW-YOLOv11s的mAP@0.5和运行帧率分别为89.8%和128帧/s，较YOLOv11s基础模型分别提高4.6%和9.4%；精确率提高5.9%，参数量仅增加0.4%。在同系列模型对比中，所提改进模型在精度-速度平衡方面表现最优，能够有效识别嵌入、未嵌入、裸露三类秸秆，满足复杂秸秆分布下的检测要求。

3)将所提SW-YOLOv11s模型部署于Orange Pi5 Plus嵌入式平台，能够实现耕整秸秆的实时检测与作业质量在线评价。通过分析秸秆分布比例，可为耕深、叶轮转速等作业参数提供实时调控依据，形成“检测-评估-调控”的智能作业闭环，有效解决了复杂水田环境下耕整质量评估难、参数调节滞后的问题。

未来的工作可进一步融合多传感器信息，构建机耕船自适应作业系统，推动田间管理向智能化、精准化方向发展。

参考文献：

[1] 陈行政，周浩，谢守勇，等. 双螺旋驱动式丘陵山区深泥脚水田插秧机设计与试验[J]. 农业机械学报，2025，56(3)：247-255.
CHEN Xingzheng，ZHOU Hao，XIE Shouyong，et al. Rice Transplanter with Double Helix Drive for Deep Muddy Paddy Fields of Hilly Regions[J]. Transactions of the Chinese Society for Agricultural Machinery，2025，56(3)：247-255.

[2] 张文茜，李文娟，余强毅，等. 农田玉米秸秆覆盖类型的光学和微波遥感识别潜力分析[J]. 农业工程学报，2025，41(18)：140-150.
ZHANG Wenqian，LI Wenjuan，YU Qiangyi，et al. Potential Analysis of Optical and Microwave Remote Sensing for Identifying Maize Straw Mulching Types in Farmland[J]. Transactions of the Chinese Society of Agricultural Engineering，2025，41(18)：140-150.

[3] 安晓飞，代均益，路振田，等. 基于彩色空间距离优化的秸秆覆盖率检测算法研究[J]. 农业机械学报，2023，54(增刊2)：229-234.
AN Xiaofei，DAI Junyi，LU Zhentian，et al. Development of Rapid Detection Algorithm of Straw Coverage Rate Based on Color Spatial Distance Gray and K-means Method[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(S2)：229-234.

[4] 杨光，张洪熙，方涛，等. 基于改进AdaBoost算法的秸秆识别与覆盖率检测技术[J]. 农业机械学报，2021，52(7)：177-183.
YANG Guang，ZHANG Hongxi，FANG Tao，et al. Straw Recognition and Coverage Rate Detection Technology Based on Improved AdaBoost Algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery，2021，52(7)：177-183.

[5] 刘媛媛，孙嘉慧，张书杰，等. 用多阈值多目标无人机图像分割优化算法检测秸秆覆盖率[J]. 农业工程学报，2020，36(20)：134-143.
LIU Yuanyuan，SUN Jiahui，ZHANG Shujie，et al. Detection of Straw Coverage Based on Multi-threshold and Multi-target UAV Image Segmentation Optimization Algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering，2020，36(20)：134-143.

[6] 钱志源，李念洹，李俊烨，等. 基于视觉检测技术和仿形设计的导电滑环轴向接触位置测试方法[J]. 中国机械工程，2025，36(11)：2641-2651.
QIAN Zhiyuan，LI Nianhuan，LI Junye，et al. Axial Contact Position Testing Method of Conductive Slip Rings Based on Visual Inspection Technology and Profilometric Design[J]. China Mechanical Engineering，2025，36(11)：2641-2651.

[7] Ultralytics. Ultralytics：Revolutionizing the World of Computer Vision[EB/OL]. [2025-11-09]. https://www.ultralytics.com.

[8] 罗亮，郎霄，祖国庆，等. 一种基于改进YOLOv8n的气缸套缺陷检测方法[J]. 中国机械工程，2025，36(5)：1054-1064.
LUO Liang，LANG Xiao，ZU Guoqing，et al. A Cylinder Liner Defect Detection Method Based on Improved YOLOv8n[J]. China Mechanical Engineering，2025，36(5)：1054-1064.

[9] 王俊，高贵兵. 基于改进YOLOv5s的风电叶片表面缺陷检测方法[J]. 中国机械工程，2025，36(9)：2108-2117.
WANG Jun，GAO Guibing. A Method for Detecting Surface Defects on Wind Turbine Blades Based on Improved YOLOv5s[J]. China Mechanical Engineering，2025，36(9)：2108-2117.

[10] 袁媛，白一超，周利东，等. 改进YOLOv8的输送带损伤检测方法[J]. 中国机械工程，2025，36(12)：2829-2836.
YUAN Yuan，BAI Yichao，ZHOU Lidong，et al. Conveyor Belt Damages Detection Based on Improved YOLOv8 Algorithm[J]. China Mechanical Engineering，2025，36(12)：2829-2836.

[11] 肖御风，张超勇，赛希亚拉图，等. 基于YOLOv11-Seg与Transformer模型的刀具磨损多步向前实时预测方法[J]. 中国机械工程，2025，36(12)：2944-2951.
XIAO Yufeng，ZHANG Chaoyong，Saixiyalatu，et al. Multi-step Ahead Real-time Prediction of Tool Wear Based on YOLOv11-seg and Transformer Model[J]. China Mechanical Engineering，2025，36(12)：2944-2951.

[12] 罗杭，杨晔，陈本永. 基于SGV-YOLOv8模型的机械零件智能识别与抓取方法[J]. 中国机械工程，2026，37(2)：442-451.
LUO Hang，YANG Ye，CHEN Benyong. Intelligent Part Identification and Grabbing Method Based on SGV-YOLOv8 Model[J]. China Mechanical Engineering，2026，37(2)：442-451.

[13] 邹俊逸，刘畅，郭文彬，等. 面向智能车辆的路面凹凸障碍物识别方法研究[J]. 中国机械工程，2024，35(6)：951-961.
ZOU Junyi，LIU Chang，GUO Wenbin，et al. Research on Road Uneven Obstacle Recognition Method for Intelligent Vehicles[J]. China Mechanical Engineering，2024，35(6)：951-961.
[14] CHEN Ruolan，ZHOU Huibo，XIE Hui，et al. YOLO-CE：an Underwater Low-visibility Environment Target Detection Algorithm Based on YOLO11[J]. The Journal of Supercomputing，2025，81(5)：723.
[15] WANG Qilong，WU Banggu，ZHU Pengfei，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，2020：11531-11539.
[16] ZHANG Runqing，DONG Wenhui，HOU Pengzhi，et al. YOLOv11-BSD：Blueberry Maturity Detection under Simulated Nighttime Conditions Evaluated with Causal Analysis[J]. Smart Agricultural Technology，2025，12：101314.
[17] ZHANG Na，DENG Guanghong，JING Wenlong，et al. A Deep Network Incorporating Depthwise Separable Convolutions for Pathological Diagnosis of Chest X-ray Images：a Model Development and Validation Study[J]. Health Science Reports，2026，9：e71647.
[18] DONG Qin，WANG Fei，TANG Mingping，et al. RSA-YOLO：an Improved YOLOv8-based Model for Tomato Leaf Disease Detection[J]. Signal，Image and Video Processing，2026，20(2)：77.
[19] 卜德森，苏绍璟，王迎龙，等. 复杂背景干扰下基于时空关联的低慢小红外目标检测方法[J]. 仪器仪表学报，2025，46(5)：183-194.
BU Desen，SU Shaojing，WANG Yinglong，et al. Low-slow Small Infrared Target Detection Method Based on Spatio-temporal Correlation under Complex Background Interference[J]. Chinese Journal of Scientific Instrument，2025，46(5)：183-194.
[20] 潘鹤立，肖松，杨晓霞，等. 基于改进YOLO v8m的柑橘花期与花量识别方法[J]. 农业机械学报，2026，57(5)：186-196.
PAN Heli，XIAO Song，YANG Xiaoxia，et al. Dense Distribution Citrus Flowering Detection Method Based on YOLO v8m[J]. Transactions of the Chinese Society for Agricultural Machinery，2026，57(5)：186-196.
[21] LI Yuanbo，ZHANG Wenwu，LYU Songtao，et al. YOLOv11-CAFM Model in Ground Penetrating Radar Image for Pavement Distress Detection and Optimization Study[J]. Construction and Building Materials，2025，485：141907.
[22] 杨传文，邢帆，朱建春，等. 中国秸秆资源的时空分布、利用现状与碳减排潜力[J]. 环境科学，2023，44(2)：1149-1162.
YANG Chuanwen，XING Fan，ZHU Jianchun，et al. Temporal and Spatial Distribution，Utilization Status，and Carbon Emission Reduction Potential of Straw Resources in China[J]. Environmental Science，2023，44(2)：1149-1162.

（编辑 胡佳慧）

作者简介：涂 鸣，男，1985年生，副教授。研究方向为水稻机械化生产技术与装备。E-mail：mingtu@mail.hzau.edu.cn。
张国忠*（通信作者），男，1971年生，教授、博士研究生导师。研究方向为水稻与水生蔬菜生产技术与装备。E-mail：zhanggz@mail.hzau.edu.cn。

本文引用格式：
涂鸣，李峥，涂海鹏，等. 基于改进YOLOv11s的机耕船水田秸秆耕整质量检测系统设计[J]. 中国机械工程，2026，37(11)：2714-2724.
TU Ming，LI Zheng，TU Haipeng，et al. Design of a Paddy Field Straw Tillage Quality Detection System for Boat Tractor Based on an Improved YOLOv11s[J]. China Mechanical Engineering，2026，37(11)：2714-2724.

（上接第2713页）

LIU Changhai，FEI Junkai，ZHAO Zhixue，et al. Simulation Study on the Performance of Hydraulic Power Take-off System of Wave Energy Conversion Based on the Volumetric Regulation and Energy-storage Principle[J]. Journal of Mechanical Engineering，2024，60(20)：327-338.
[17] 郭煜杰，陈俊翔，艾超，等. 基于模型标定与泵阀动态匹配的液压挖掘机启动压力冲击改善[J]. 中国机械工程，2026，37(7)：1784-1793.
GUO Yujie，CHEN Junxiang，AI Chao，et al. Improvement of Starting Pressure Impact on Hydraulic Excavator Based on Model Calibration and Dynamic Matching of Pump Valve[J]. China Mechanical Engineering，2026，37(7)：1784-1793.
[18] CHENG Z，YANG J，HU Z，et al. Frequency/Time Domain Modeling of a Direct Drive Point Absorber Wave Energy Converter[J]. Science China Physics，Mechanics and Astronomy，2014，57(2)：311-320.

（编辑 胡佳慧）

作者简介：刘常海*（通信作者），男，1988年生，副教授。研究方向为波浪能开发与利用、流体传动与控制。E-mail：liuchanghai@hfut.edu.cn。

本文引用格式：
刘常海，高瑞恒，彭立志，等. 液压泵控式波浪能转换器的半物理试验系统仿真研究[J]. 中国机械工程，2026，37(11)：2706-2713.
LIU Changhai，GAO Ruiheng，PENG Lizhi，et al. Simulation Study on Semi-physical Test System of Wave Energy Converters for Hydraulic Pump-controlled System[J]. China Mechanical Engineering，2026，37(11)：2706-2713.