doi:10.6041/j.issn.1000-1298.2025.11.036

基于数字表面模型和改进 PIDNet 的玉米倒伏无人机遥感监测研究

李嘉豪[1,2]　刘开东[1,2]　柴子凯[1,2]　宁纪峰[3,4]　杨蜀秦[1,2]

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100;
3. 西北农林科技大学信息工程学院, 陕西杨凌 712100; 4. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100)

摘要: 倒伏严重影响玉米的生长发育和产量形成,及时有效地监测玉米田间倒伏位置并确定倒伏区域,对生产补救、良种选育和受灾评估等工作具有重要意义。本文基于改进语义分割模型 PIDNet 融合数字表面模型蕴含的作物高度信息,提出一种基于无人机遥感的多生育期玉米倒伏监测方法。首先,基于吐丝期、乳熟期和腊熟期玉米的无人机遥感影像,将可见光图像与数字表面模型 DSM 图像进行融合并作为 PIDNet 模型的输入层,增强玉米倒伏区域的特征;其次,在 PIDNet 的积分分支中添加高效多尺度注意力(EMA)模块以提升网络聚合上下文信息、细节解析和边界监测的能力,增强模型对玉米不同生育期倒伏区域的识别能力,从而得到改进的 PIDNet 玉米倒伏监测模型。试验结果表明,本研究提出的融合 DSM 的 EMA - PIDNet 模型的平均像素精度(Mean pixel accuracy, mPA)和平均交并比(Mean intersection over union, mIoU),在吐丝期分别为 91.83% 和 83.94%,在乳熟期分别为 91.66% 和 82.77%,在腊熟期分别为 90.84% 和 82.64%。与代表性的模型 U - Net、PSPNet、DeepLabv3 + 、UHRNet 相比,提出的 EMA - PIDNet 模型在 3 个生育期的玉米倒伏区域监测表现均为最优。通过消融实验证明了 PIDNet 模型融合 DSM 高度信息和添加 EMA 模块的有效性。研究表明,通过融合 DSM 高度信息的方法能够更精准地监测玉米倒伏区域,EMA 模块对于玉米多生育期倒伏的监测能力也有提升作用,为利用无人机遥感技术监测玉米倒伏提供了一种有效的方法。

关键词: 玉米倒伏; 数字表面模型; 无人机遥感; 生育期; 语义分割; PIDNet

中图分类号: TP753　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0378-09　　**OSID**:

Maize Lodging Detection in UAV Remote Sensing Images Based on DSM and Improved PIDNet

LI Jiahao[1,2]　LIU Kaidong[1,2]　CHAI Zikai[1,2]　NING Jifeng[3,4]　YANG Shuqin[1,2]

(1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Internet of Things*, *Ministry of Agriculture and Rural Affairs*, *Yangling*, *Shaanxi* 712100, *China*
3. *College of Information Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
4. *Shaanxi Key Laboratory of Agricultural Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Lodging significantly affects the growth, development, and yield of maize. Timely and effective detection of lodging locations and identification of lodging areas in cornfields is crucial for production remediation, breeding of improved varieties, and disaster assessment. A multi-growth stage maize lodging detection method was proposed based on UAV remote sensing by integrating the improved semantic segmentation model PIDNet with DSM containing maize height information. Firstly, UAV remote sensing images of maize at the silking, milk, and dough stages were fused with visible light images and DSM images to serve as the input layer for the PIDNet model, enhancing the features of lodging areas. Secondly, an efficient multi-scale attention (EMA) module was added to the integrative branch of PIDNet to improve the network's ability to aggregate contextual information, detail parsing, and boundary detection, thereby enhancing the model's generalization capability, which resulted in the EMA - PIDNet

收稿日期: 2024 - 07 - 20　修回日期: 2024 - 09 - 05

基金项目: 陕西省自然科学基础研究计划项目(2022JM - 128)

作者简介: 李嘉豪(2000—),男,硕士生,主要从事计算机视觉在农业信息领域中的应用研究,E-mail: lijiahao@nwafu.edu.cn

通信作者: 杨蜀秦(1978—),女,副教授,博士,主要从事计算机视觉在农业信息领域中的应用研究,E-mail: yangshuqin1978@163.com

maize lodging detection model. Experimental results showed that the proposed EMA – PIDNet model integrating DSM achieved mean pixel accuracy (mPA) and mean intersection over union (mIoU) of 91.83% and 83.94% at the silking stage, 91.66% and 82.77% at the milk stage, and 90.84% and 82.64% at the dough stage, respectively. Compared with representative models such as U – Net, PSPNet, DeepLabv3 +, and UHRNet, the proposed EMA – PIDNet model demonstrated superior performance in detecting maize lodging areas across all three growth stages. Ablation experiments confirmed the effectiveness of integrating DSM height information and adding the EMA module to the PIDNet model. The research result indicated that the method of integrating DSM height information can more accurately detect maize lodging areas, and the EMA module enhanced the detection capability of maize lodging across multiple growth stages, providing effective support for using UAV remote sensing technology to detect maize lodging.

Key words: maize lodging; digital surface model; UAV remote sensing; growth stages; semantic segmentation; PIDNet

0　引言

玉米一般生长在高温多雨的季节,具有生长快、产量大的特点。通常认为,叶片夹角小、叶片间距大的高茎玉米生长期间能够更好地进行光合作用。然而,玉米叶片致密,株形高大,茎韧性低,再加上品种和管理等原因,使得在夏季强风和暴雨多发的气象条件下,玉米农田容易发生成片倒伏现象[1-2]。倒伏压力使得玉米叶片堆积,并破坏植物的根和茎,阻碍植株光合作用和养分运输,甚至导致玉米死亡[3-4],成为影响玉米产量的重要原因之一。因此,快速准确地获取玉米倒伏区域位置、面积等信息,监测玉米田间倒伏的程度和范围,有助于采取措施,减少损失,并为未来的农业管理提供参考[5-7]。

近年来,利用深度学习在计算机视觉领域的优异性能,研究者将其广泛应用于农作物农情的监测分析中,并取得了较好的效果,能够为各种农业问题提供高效、准确、实时的解决方案[8]。无人机遥感作为一种高效化、现代化、智能化的技术,已被广泛用于农作物长势监测[9]、产量估算[10]和倒伏面积提取[11]等领域,无人机搭载的高分辨率摄像设备能够全面、全方位地观测到农田的情况,同时充分利用图像的高程等信息提高监测精度[12-15]。YANG 等[16]将无人机图像、纹理特征和数字表面模型进行了不同组合,并计算了不同组合特征中各类作物形态分类精度。朱厚文等[17]利用 Planet 和 Sentinel-2 影像分别结合面向对象与基于像元方法提取研究区玉米倒伏,同时评估了不同影像特征与不同分类方法对玉米倒伏提取精度的影响。毛智慧等[18]通过无人机倾斜测量的方式获取倒伏作物的数字表面模型,并结合无人机图像的色彩特征,进行了玉米倒伏信息提取。申华磊等[19]为及时准确地提取小麦倒伏面积,提出一种融合多尺度特征的倒伏面积分割模型 Attention_U2 – Net,为无人机遥感监测小麦受灾面积及损失评估提供了参考。

玉米具有叶片致密、株形高大的特点,因此倒伏的玉米植株可能会互相遮挡,导致部分倒伏的植株难以监测,不同生育期的玉米倒伏形态也各不相同,使得一般的倒伏监测方法难以准确适用,需要根据玉米倒伏的复杂情况,对深度学习检测模型进行一定的改进,并结合遥感技术和数据处理方法,以提高玉米倒伏监测的准确性和可靠性。因此,本文建立玉米无人机遥感影像数据集,将数字表面模型(Digital surface model, DSM)高度信息与可见光图像融合作为 PIDNet 的输入层,使模型同时学习视觉和高度特征,并在 PIDNet 模型中添加 EMA 模块增强特征处理和表示的能力,提升网络聚合上下文信息、细节解析和边界监测的能力,将其应用于多生育期玉米倒伏监测,以期为无人机遥感技术监测玉米倒伏提供有效的技术支撑。

1　研究区域与数据

1.1　研究区域概况

数据采集区域位于陕西省关中平原中部的杨凌区陕西大唐种业股份有限公司实验田,中心坐标(34°20′7.73″N,108°42′55.51″E),属于温带半干旱或半湿润气候,春暖多风、夏热多雨、秋凉阴雨、冬寒干燥的大陆性季风气候特征明显。年平均气温11 ~ 13℃,年降水量 500 ~ 700 mm。如图 1 所示,出现倒伏情况玉米种植区域分为 4 块,其中,1 号地面积约

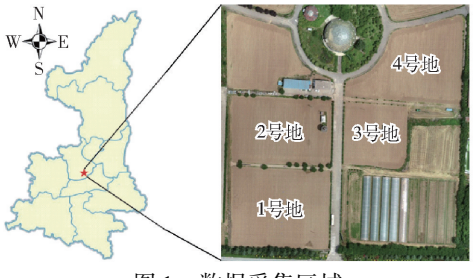


图 1　数据采集区域

Fig. 1　Data collection area

为 9 500 m^2,2 号地面积约为 4 050 m^2,3 号地面积约为 8 645 m^2,4 号地面积约为 10 330 m^2。

1.2 数据采集及分析

采用大疆精灵 4 RTK 型无人机获取研究区域的遥感影像。大疆精灵 4 RTK 型无人机最大飞行时间约为 30 min,搭载了 DJI FC6310R 型可见光相机,成像分辨率为 4 864 像素 ×3 648 像素,负责采集高分辨率可见光影像。在 8 月 12 日、9 月 4 日和 9 月 25 日进行拍摄,这 3 d 对应的生育期分别为玉米吐丝期、乳熟期和腊熟期,数据获取于拍摄当日的 10:00—12:00,天气均为晴或多云,飞行高度为 30 m,飞行速度为 1.6 m/s,航向重叠度为 85%,旁向重叠度为 75%。

通过航拍数据处理软件 Pix4D mapper 将无人机拍摄的影像进行拼接,获得研究所需的正射影像和数字表面模型。为了更好地掌握数据分布特点和构建玉米倒伏数据集,统计 3 个生育期的各块实验田遥感影像并对倒伏区域的分布和特点进行分析。如图 2 所示,遥感影像中玉米在吐丝期、乳熟期和腊熟期的颜色、纹理等特征均存在差异,同时发生倒伏的玉米在倒伏角度和冠层颜色上也存在差异,吐丝期的倒伏玉米偏浅绿且倒伏区域边界较为整齐;乳熟期的倒伏玉米倒伏角度偏大,同时未倒伏玉米的叶片会对倒伏区域产生遮挡;而腊熟期的倒伏玉米基本贴近地面,存在部分颜色偏浅黄色的叶片。

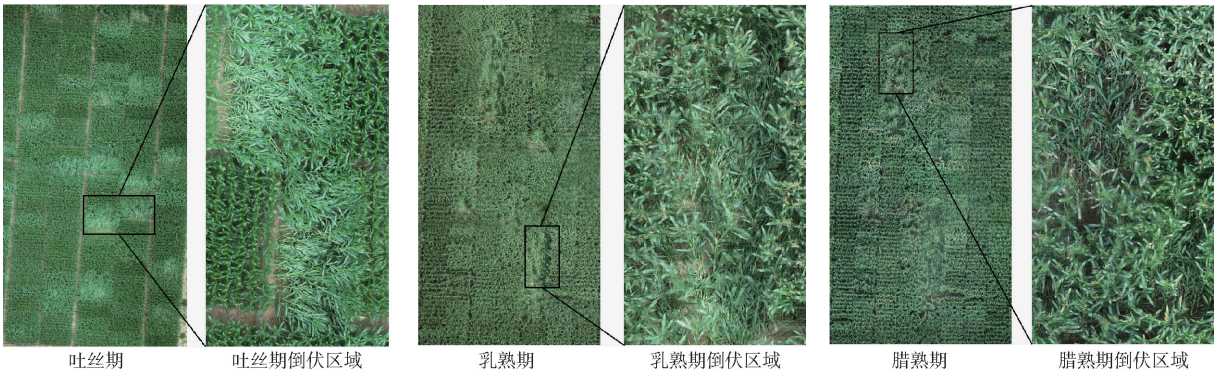


图 2 玉米无人机遥感影像

Fig. 2 Maize UAV remote sensing images

1.3 数据集构建及分析

采用 labelme 软件对玉米的整体遥感正射影像的倒伏区域进行标注,根据标签图像中倒伏区域的像素点占比估算倒伏玉米面积,对吐丝期、乳熟期和腊熟期的各个种植区域倒伏玉米面积进行统计,结果如图 3 所示。可以看出,育种区域之间玉米倒伏情况存在差异,不同生育时期的玉米倒伏情况也不相同,育种区域的倒伏程度随着时间逐步加重。结合图 2 可知,玉米倒伏区域分布不规律,其中一部分区域零散分布,另一部分则集中成片倒伏。在构建数据集时,应充分考虑这种不规律性,通过增加多样化的训练数据,提升模型对各种倒伏模式的泛化能力,以获得最优的模型性能。

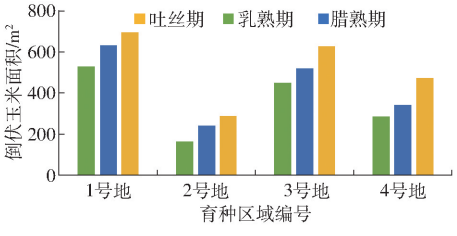


图 3 玉米倒伏情况统计分析

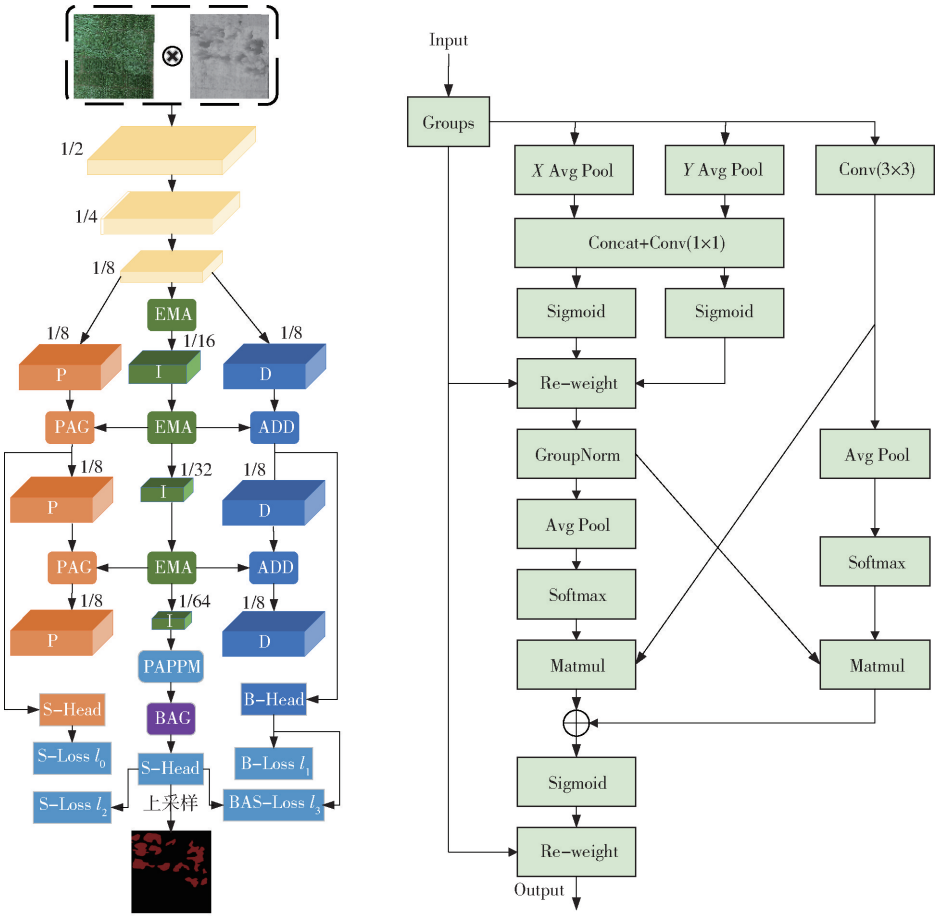
Fig. 3 Statistical analysis of maize lodging

为了验证模型的泛化性能,按育种区域将玉米遥感影像划分为训练集、验证集和测试集,1 号地和 2 号地为训练集,3 号地和 4 号地分别为验证集和测试集。为了方便后续深度学习模型对数据集进行训练,将遥感影像裁剪为 512 像素 ×512 像素的小图像。由于深度学习需要大量的数据进行训练,因此本研究采用加噪、对称变换、旋转、改变亮度等数据增强方法对训练集进行扩充,每个生育期分别获得 9 513 幅训练集图像。每个生育期获得的验证集和测试集图像数量分别为 1 073 幅和 960 幅。

2 研究方法

2.1 PIDNet 模型

玉米倒伏区域监测任务要求网络模型具有较高的边界监测精度,同时也需要有较强的细节信息分析能力。深度语义分割模型 PIDNet 具有 3 个互相补充的分支,比例分支 P 负责解析和保留高分辨率特征图中的详细信息;积分分支 I 负责聚合局部和全局的上下文信息以捕获远距离依赖关系;微分分支 D 负责提取高频特征以预测边界区域。整个网络按如图 4 所示结构进行开发,采用级联残差作为主干,以实现硬件友好的架构[20]。PIDNet 的分支 I



(a) 改进的PIDNet结构图　　(b) EMA模块结构图

图 4　基于 EMA 模块的改进 PIDNet 模型总体结构

Fig. 4　Overall structure of improved PIDNet model based on EMA module

提供丰富而准确的语义信息对于分支 P 和 D 的细节解析和边界检测至关重要，因此将分支 I 视为其他 2 个分支的备份，向它们提供所需的信息。PIDNet 引入了像素注意力引导（Pixel attention guided fusion，PAG）模块，使分支 P 有选择地从分支 I 学习有用的语义特征。同时引入边界注意力引导（Boundary-attention-guided fusion，BAG）模块，利用边界特征来指导分支 P 和分支 I 的融合，以实现更好的语义分割效果。

2.2　融合 DSM 和 EMA 的改进 PIDNet 模型

由于标准的 PIDNet 深度语义分割模型仅处理可见光图像，不能直接用于处理融合 DSM 高度信息的多通道图像，需要对网络模型的输入层进行修改。同时，在多生育期玉米倒伏监测中，不同生育期的玉米倒伏区域在颜色、纹理和角度等具有较大的差异性，PIDNet 的三分支结构虽然可以同时处理不同尺度的信息，但其对不同生育期玉米特征变化的泛化能力较弱，无法有效适应不同生育期的数据特征，导致其对倒伏情况的准确性和稳定性有所限制，因此需要对网络模型进行改进，提升网络模型的性能。

2.2.1　RGB 图像与 DSM 高度信息融合

DSM 具有丰富的高程信息，而玉米倒伏主要表现为植株高度的降低，因此通过融合 DSM 高度信息，能够直接量化玉米植株的高度变化，从而更准确地识别倒伏区域，对于玉米倒伏监测具有独特的优势和作用。同时 DSM 高度信息与 RGB 图像信息相结合，可以形成更丰富的多维度数据。RGB 图像提供颜色和纹理信息，DSM 提供高度和形态信息，且 DSM 不受光照变化影响，可以作为一个稳定的辅助信息源，使得监测系统不再过度依赖视觉特征，两者的融合使得监测系统能够从多个维度进行综合分析，提高对玉米倒伏的监测精度。

标准的 PIDNet 深度语义分割模型仅处理可见光图像，所以需修改输入层以适应四通道图像的输入，且 RGB 图像融合 DSM 高度信息前需要经过一系列的预处理。预处理包括：

（1）图像配准：DSM 的每个像素表示传感器与物体之间的实际距离，因此，为了在 RGB 图像中正确地表示物体的真实距离，需要确保像素点之间具有一对一的对应关系。本文将高度图像的坐标系转换到 RGB 图像的坐标系下，从而对 RGB 图像和

DSM 进行精确配准。

(2) 数据预处理:采集 DSM 的数值范围大致为 0 ~ 500,而 RGB 图像的单通道数值范围为 0 ~ 255,这导致了两者之间的数据差异较大。通过均值化和归一化,将数据调整到相同的分布范围内,从而消除因数值差异带来的误差。这不仅可以加快梯度下降的求解速度,还能提高模型的精度。

在对模型通道进行改进和对数据进行预处理后,最终将 RGB 图像和 DSM 高度信息拼接,从而实现了作物高度信息的融合。

2.2.2 基于高效多尺度注意力的改进 PIDNet 模型

高效多尺度注意力(Efficient multi-scale attention, EMA)模块的主要原理是通过重塑部分通道到批次维度,并将通道维度分组为多个子特征,以保留每个通道的信息并减少计算开销[21]。EMA 模块结构如图 4b 所示。EMA 模块通过编码全局信息来重新校准每个并行分支中的通道权重,并通过跨维度交互来捕获像素级别的关系。此外,EMA 模块通过重新组织通道维度和批次维度,提高了模型处理特征的能力,利用跨维度的交互来捕捉像素级别的关系,增强了特征表示能力。EMA 模块还在并行分支中编码全局信息,并用于通道权重的重新校准,进一步提升了模型性能。

由于 EMA 模块具有提高特征处理和表示的能力,将模块加入 PIDNet 网络的分支 I,增强网络聚合局部和全局的上下文信息的能力,改进后的 PIDNet 网络模型结构图如图 4a 所示。同时在分支 I 与分支 P 和 D 的连接处前添加 EMA 模块,将输出分别和分支 P、分支 D 融合,加强分支 P 和 D 的细节解析和边界监测能力,提高监测结果的准确性,减少漏检和误检。同时,EMA 模块通过对模型参数进行加权平均,使得模型对各种倒伏特征的参数变化更加敏感和适应,从而提升了模型在不同生育期下的泛化能力,使得监测结果更加准确和鲁棒。

综上所述,将玉米可见光无人机遥感图像与 DSM 高程信息进行融合作为模型的输入层,同时将 EMA 模块(图 4b)分别添加到分支 I 的 3 处位置,从而得到面向玉米倒伏监测的改进 PIDNet 模型。

2.3 模型训练

2.3.1 训练参数设置

运行硬件环境为 Lenovo SystemX 3650 M5 服务器,搭载 2 块 NVIDIA GeForce RTX 3090 显卡。操作系统为 Ubuntu 16. 04,采用 PyTorch 深度学习框架构建网络。在实验中,模型采用 SGD 优化器。初始学习率设置为 0.001,权重衰减率为 5×10^{-6},动量值为 0.9。批量大小(batch_size)设为 16,训练模型的迭代次数设为 100。

2.3.2 评价指标

采用平均像素精度(Mean pixel accuracy, mPA)和平均交并比(Mean intersection over union, mIoU)评价指标对网络模型进行定量评估,指标越大表示模型分割效果越好。平均像素精度表示所有类型正确分类像素的平均值。平均交并比表示所有类别的预测像素与真实值相似程度的平均值。

3 实验结果与讨论

3.1 实验结果

选择 U - Net[22]、PSPNet[23]、DeepLabv3 +[24]和 UHRNet[25]网络模型,与 PIDNet[20]以及改进的 PIDNet 模型在融合 DSM 信息的玉米倒伏数据集上进行测试结果比较,验证 PIDNet 网络模型的优势,以及验证本研究提出的改进方法对玉米倒伏监测精度的提升。

由表 1 可知,U - Net、PSPNet 和 DeepLabv3 + 的倒伏监测结果较差,在 3 个生育期的数据集上,mPA 均未超过 80%,mIoU 均未超过 75%,证明了三者在处理玉米倒伏的复杂特征上有较大的局限性,UHRNet 和 PIDNet 模型相较于前者有较大的提升,但 UHRNet 在乳熟期和腊熟期的玉米倒伏监测任务上有明显的缺陷,mPA 和 mIoU 相较于吐丝期下降幅度较大,证明了该网络的泛化能力存在不足之处。与 UHRNet 相比,PIDNet 模型的表现更优,其吐丝期和乳熟期的 mPA 均超过 86%,但在腊熟期的倒伏监测上仍有缺陷,需要进一步提升其泛化能力。而添加了 EMA 模块的 PIDNet 在吐丝期、乳熟期和腊熟期的 mPA 均超过 90%,mIoU 均超过 82%,3 个生育期的 2 项指标之间也仅有 1 个百分点左右的差距。综上所述,通过添加 EMA 模块到 PIDNet 网络中,可以有效提升模型在多生育期玉米倒伏监测任务中的稳定性、泛化能力和监测准确性,为玉米倒伏监测提供更加可靠和准确的结果。

表 1 无人机遥感影像玉米倒伏监测结果

Tab. 1 UAV remote sensing image maize lodging detection results %

模型	mPA			mIoU		
	吐丝期	乳熟期	腊熟期	吐丝期	乳熟期	腊熟期
U - Net	75.58	73.99	74.03	72.15	70.56	70.26
PSPNet	79.51	78.80	78.01	74.64	73.81	73.92
DeepLab v3 +	79.89	77.97	77.66	72.74	72.18	71.56
UHRNet	84.64	80.08	81.96	75.96	72.56	73.14
PIDNet	87.79	86.57	84.59	79.61	78.70	76.87
改进的 PIDNet	91.83	91.66	90.84	83.94	82.77	82.64

3.2　结果分析

3.2.1　不同语义分割模型对比分析

为了直观展示改进的 PIDNet 模型对玉米倒伏区域的监测能力，利用不同模型分割测试集中的样本图像，评价改进的 PIDNet 模型的分割性能。由于 U－Net、PSPNet 和 DeepLabv3＋的评价指标较低，倒伏监测效果较差，不能准确监测玉米倒伏的区域，因此不对其监测效果图进行对比分析。不同模型的预测结果如图 5 所示，PIDNet 和 UHRNet 在玉米倒伏监测方面表现尚可，能够大致监测出玉米倒伏的区域，但仍然存在少量漏检和误检问题，尤其是在乳熟期和腊熟期这样环境复杂的情况下，存在着部分边缘细节效果不佳的情况。而本研究中融合 EMA 模块的 PIDNet 相较于原本模型较大程度上保留了玉米倒伏特征信息的完整性及边缘细节信息的精准性，在边缘细节的提取效果以及特征识别方面表现更好，保证了在 3 个生育期上的监测准确度，是处理玉米倒伏图像的最佳选择。

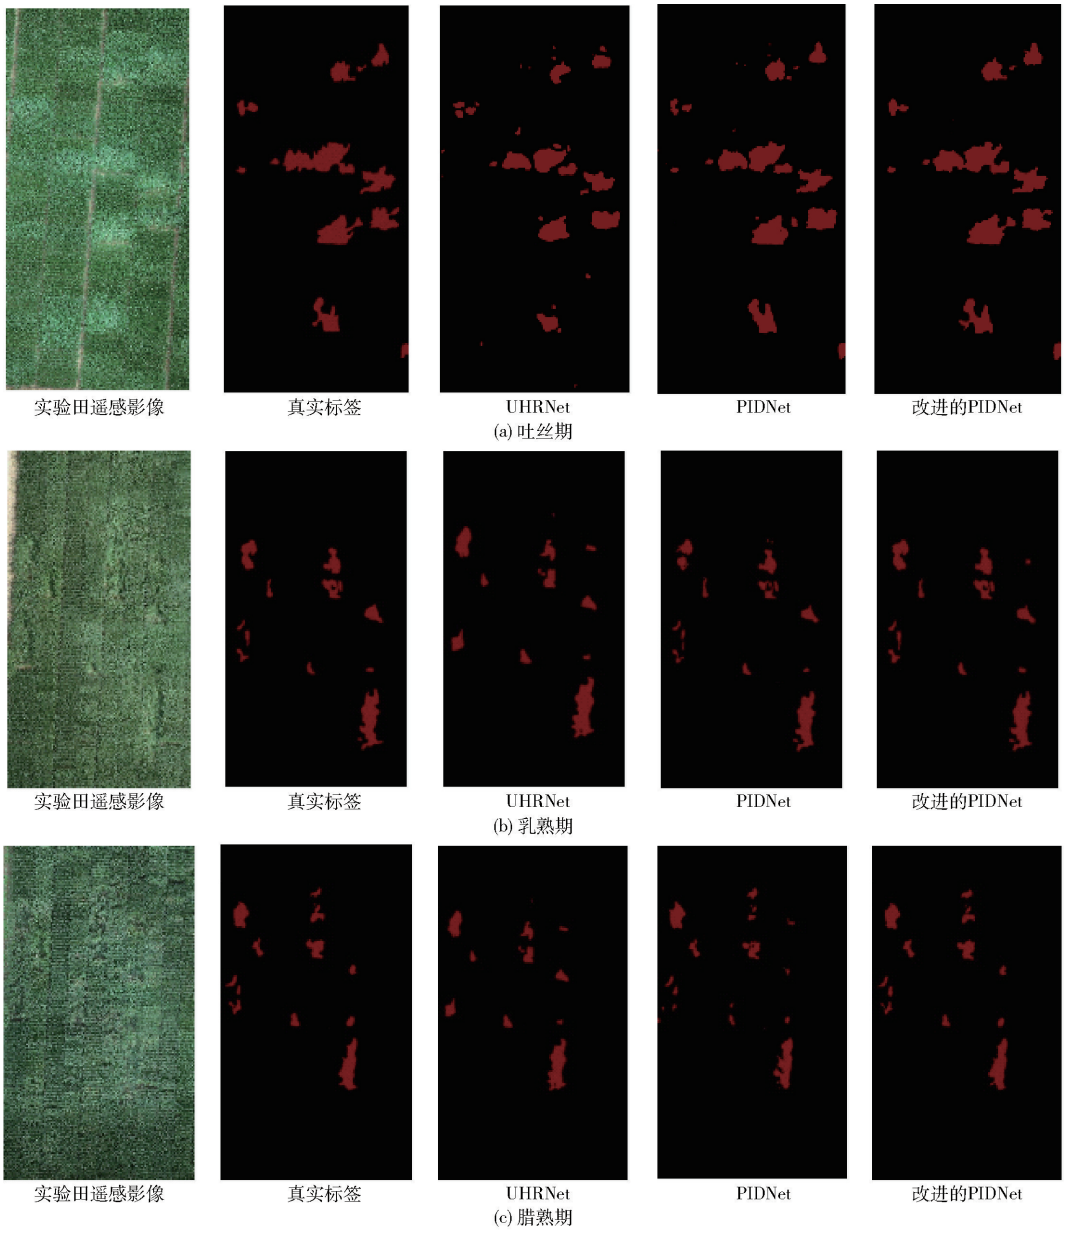


图 5　不同语义分割模型对玉米倒伏监测效果比较

Fig. 5　Comparison of different semantic segmentation models for maize lodging detection

3.2.2　消融实验

通过原始的 PIDNet 模型在融合 DSM 高度信息的数据集上进行测试，实验结果如表 2 所示，mPA 和 mIoU 在吐丝期分别为 87.79%、79.61%，在乳熟期分别为 86.57%、78.70%，在腊熟期分别为 84.59%、76.87%。同时与未融合 DSM 高度信息的 RGB 数据集相比，mPA 和 mIoU 在吐丝期分别提高 5.33、5.52 个百分点，在乳熟期分别提高 5.59、5.86 个百分点，在腊熟期分别提高了 3.96、4.26 个百分点。证明了原始的 PIDNet 模型在融合 DSM 高度信

表 2 融合 DSM 玉米倒伏监测结果对比

Tab. 2 Comparison of maize lodging detection results integrating DSM %

DSM	mPA			mIoU		
	吐丝期	乳熟期	腊熟期	吐丝期	乳熟期	腊熟期
未融合	82.46	80.98	80.63	74.09	72.84	72.61
融合	87.79	86.57	84.59	79.61	78.70	76.87

息的数据集上训练效果最优。结果表明,在网络模型相同的情况下,通过融合 DSM 高度信息的方式可以提升监测结果的 mPA 和 mIoU,增强网络模型的倒伏监测准确度。

通过进行消融实验以验证在分支 I 添加的 3 个 EMA 模块对玉米倒伏监测性能提升的效果,表 3 为消融实验结果。在融合了 DSM 高度信息的情况下 PIDNet 网络结构(图4a),仅在分支 I 添加一个 EMA 模块,或在分支 I 与分支 P、D 两处融合处添加 EMA 模块,对 PIDNet 模型的准确性和泛化能力的提升并不明显,腊熟期的性能指标与吐丝期和乳熟期仍有一定的差距,而添加 3 个 EMA 模块的 PIDNet 模型不仅大幅提高了网络对倒伏监测的精准度,还增强了网络模型的泛化能力,针对不同生育时期的倒伏监测任务均能达到较好的监测结果。

表 3 消融实验结果

Tab. 3 Ablation experiment results %

EMA-1	EMA-2	EMA-3	mPA			mIoU		
			吐丝期	乳熟期	腊熟期	吐丝期	乳熟期	腊熟期
×	×	×	87.79	86.57	84.59	79.61	78.70	76.87
√	×	×	87.73	86.42	84.43	78.30	78.55	75.68
×	√	√	87.69	86.04	84.92	79.58	79.08	76.59
√	√	√	91.83	91.66	90.84	83.94	82.77	82.64

注:“√”表示使用此模块,“×”表示不使用此模块。

由图 6 可知,原始的 PIDNet 模型使用 RGB 影像训练后的监测效果较差,倒伏区域的边界监测结果不准确,在各个生育期内均有漏检和误检的情况,其中误检问题在腊熟期出现的尤为明显。相比之下,融合了 DSM 高度信息的数据集监测效果有着明显提升,倒伏区域大致监测准确,区域边界的监测精度也较高,使用改进后的 PIDNet 模型与融合 DSM 高度信息的倒伏监测效果进一步提升,并且极大地减少了漏检和误检。综上所述,本研究提出的融合 DSM 高度信息和添加 EMA 模块改进 PIDNet 模型的方法提高了监测的准确性和对倒伏程度的区分能力。

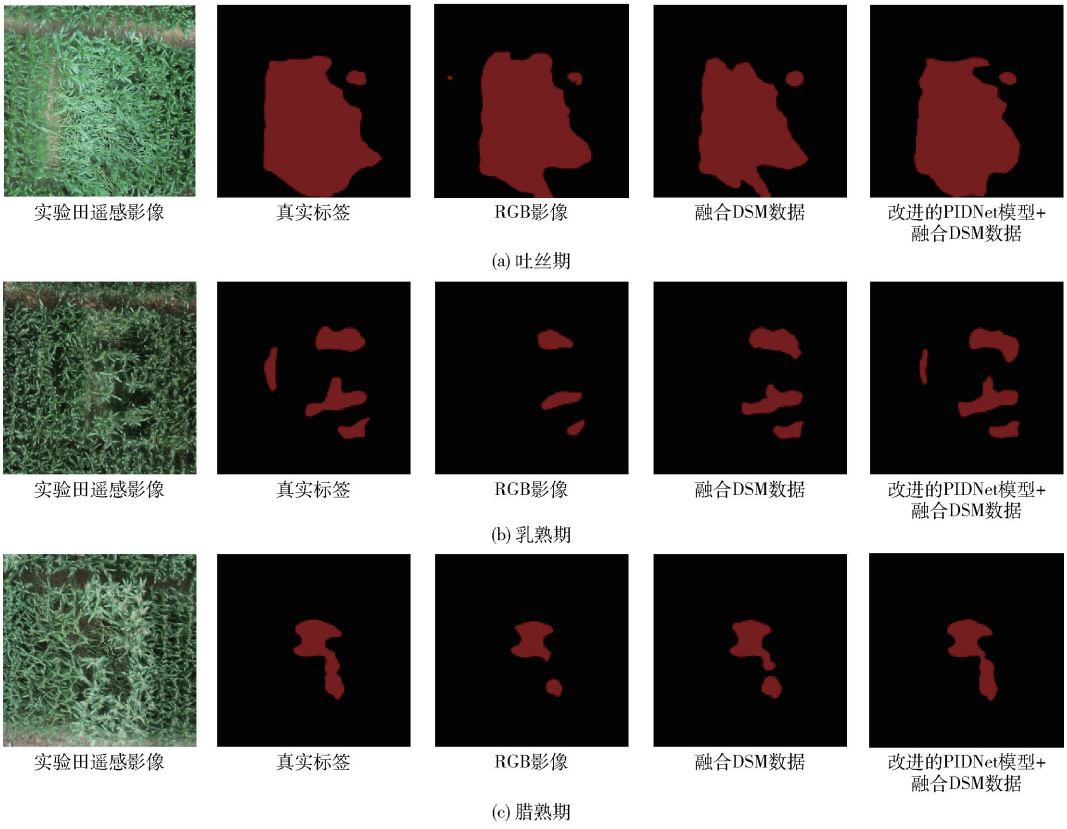


图 6 不同改进方法对玉米倒伏监测效果比较

Fig. 6 Comparison of different improved methods for maize lodging detection

综上所述,本文提出的改进方案不仅提高了模型对倒伏监测的准确性,还增强了不同生育期下模型的泛化能力。通过消融实验证明了融合 DSM 数据和在分支 I 适当位置添加 EMA 模块是提升玉米

倒伏监测性能的最有效方法。

4　结论

(1)为有效监测玉米田间倒伏位置并确定倒伏区域,通过将可见光 RGB 影像与 DSM 高度信息进行融合,在三分支深度语义分割模型 PIDNet 的积分分支中添加 EMA 自注意力模块,提高网络特征处理能力和不同生育期的泛化能力,实现了吐丝期、乳熟期和腊熟期的玉米倒伏区域准确监测。

(2)基于融合 DSM 高度信息的遥感影像相较于仅用可见光遥感影像能够较好地实现玉米倒伏区域的识别,RGB 影像融合 DSM 作物高度信息能达到两者优势互补的目的,可显著提高玉米倒伏区域的监测精度,减少漏检与误检。

(3)基于添加 EMA 模块的 PIDNet 模型的玉米倒伏监测精度优于 U - Net、PSPNet 和 DeepLabv3 + 、UHRNet 和标准 PIDNet 模型,消融实验验证了融合 DSM 高度信息和添加 EMA 模块对倒伏区域监测能力的提升。并通过对吐丝期、乳熟期和腊熟期的倒伏监测结果对比分析,证明了改进模型拥有较强的泛化性和鲁棒性。

参　考　文　献

[1] LI Q, GAO L, LIU D, et al. Novel insights of maize structural feature in China[J]. Euphytica, 2021, 217(1):S10681 - 020 - 02742 - 3.

[2] ROBERTSON J D, JULIAS M, GARDUNIA W B, et al. Corn stalk lodging: a forensic engineering approach provides insights into failure patterns and mechanisms[J]. Crop Science, 2015, 55(6):2833 - 2841.

[3] XUE J, GAO S, FAN Y, et al. Traits of plant morphology, stalk mechanical strength, and biomass accumulation in the selection of lodging-resistant maize cultivars[J]. European Journal of Agronomy, 2020, 117:2020.126073.

[4] GUO Y, CHEN S, LI X, et al. Machine learning-based approaches for predicting SPAD values of maize using multi-spectral images[J]. Remote Sensing, 2022, 14(6):1337.

[5] 赵静,闫春雨,杨东建,等. 基于无人机多光谱遥感的台风灾后玉米倒伏信息提取[J]. 农业工程学报, 2021, 37(24):56 - 64.
ZHAO Jing, YAN Chunyu, YANG Dongjian, et al. Extraction of maize lodging information after typhoon based on UAV multispectral remote sensing[J]. Transactions of the CSAE, 2021, 37(24): 56 - 64. (in Chinese)

[6] QU X, ZHOU J, GU X, et al. Monitoring maize lodging severity based on multi-temporal Sentinel - 1 images using Time-weighted Dynamic time Warping[J]. Computers and Electronics in Agriculture, 2023, 215:108365.

[7] XUE J, GOU L, ZHAO Y, et al. Effects of light intensity within the canopy on maize lodging[J]. Field Crop Res, 2016,188: 133 - 141.

[8] BOCK C, POOLE G, PARKER P, et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging[J]. Crit. Rev. Plant Sci, 2010, 29(2): 59 - 107.

[9] 牛鲁燕,蒋风伟,张俊丽,等. 基于无人机多光谱遥感的小麦长势监测研究[J]. 山东农业科学, 2021, 53(3):139 - 145.
NIU Luyan, JIANG Fengwei, ZHANG Junli, et al. Study on wheat growth monitoring based on UAV multi-spectrum[J]. Shandong Agricultural Sciences, 2021, 53(3):139 - 145. (in Chinese)

[10] 申洋洋,陈志超,胡昊,等. 基于无人机多时相遥感影像的冬小麦产量估算[J]. 麦类作物学报, 2021, 41(10):1298 - 1306.
SHEN Yangyang, CHEN Zhichao, HU Hao, et al. Estimation of winter wheat yield based on UAV multi-temporal remote sensing image[J]. Journal of Triticeae Crops, 2021, 41(10):1298 - 1306. (in Chinese)

[11] 杨蜀秦,王鹏飞,王帅,等. 基于 MHSA + DeepLab v3 + 的无人机遥感影像小麦倒伏监测[J]. 农业机械学报, 2022, 53(8):213 - 219,239.
YANG Shuqin, WANG Pengfei, WANG Shuai, et al. Detection of wheat lodging in UAV remote sensing images based on multi-head self-attention DeepLab v3 + [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 213 - 219,239. (in Chinese)

[12] 赵春江. 农业遥感研究与应用进展[J]. 农业机械学报, 2014, 45(12):277 - 293.
ZHAO Chunjiang. Advances of research and application in remote sensing for agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12):277 - 293. (in Chinese)

[13] 赵龙才,李粉玲,常庆瑞. 农作物遥感识别与单产估算研究综述[J]. 农业机械学报, 2023, 54(2):1 - 19.
ZHAO Longcai, LI Fenling, CHANG Oingrui. Review on crop type identification and yield forecasting using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2):1 - 19. (in Chinese)

[14] 韩文霆,彭星硕,张立元,等. 基于多时相无人机遥感植被指数的夏玉米产量估算[J]. 农业机械学报,2020,51(1): 148 - 155.
HAN Wenting, PENG Xingshuo, ZHANG Liyuan, et al. Summer maize yield estimation based on vegetation index derived from multi-temporal UAV remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 148 - 155. (in Chinese)

[15] MEIYAN S, KAI B, LEI M, et al. Assessing maize lodging severity using multitemporal UAV-based digital images[J]. European Journal of Agronomy, 2023,144:2023.126754.

[16] YANG Ming-Der, HUANG Kai-Siang, KUO Yi-Hsuan, et al. Spatial and spectral hybrid Image classification for rice lodging assessment through UAV imagery[J]. Remote Sensing,2017, 9(6): 583.

[17] 朱厚文, 罗冲, 官海翔, 等. 基于面向对象的多源卫星遥感影像玉米倒伏面积提取[J]. 遥感技术与应用. 2022, 37(3):599 - 607.
ZHU Houwen, LUO Chong, GUAN Haixiang, et al. Object-oriented extraction of maize fallen area based on multi-source satellite remote sensing images[J]. Remote Sensing Technology and Application, 2022, 37(3):599 - 607. (in Chinese)

[18] 毛智慧, 邓磊, 赵晓明, 等. 利用无人机遥感提取育种小区玉米倒伏信息[J]. 中国农学通报,2019, 35(3): 68 - 74
MAO Zhihui, DENG Lei, ZHAO Xiaoming, et al. Extraction of maize lodging in breeding plot based on UAV remote sensing [J]. Chinese Agricultural Science Bulletin, 2019, 35(3): 68 - 74. (in Chinese)

[19] 申华磊, 苏歆琪, 赵巧丽, 等. 基于深度学习的无人机遥感小麦倒伏面积提取方法[J]. 农业机械学报,2022, 53(9): 252 - 260,341.
SHEN Hualei, SU Xinqi, ZHAO Qiaoli, et al. Extraction of lodging area of wheat varieties by unmanned aerial vehicle remote sensing based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9):252 - 260, 341. (in Chinese)

[20] XU Jiacong, XIONG Zixiang, BHATTACHARYYA S P. PIDNet: a real-time semantic segmentation network inspired by PID controllers[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 19529 - 19539.

[21] OUYANG Dailiang, HE Su, ZHANG Guozhong, et al. Efficient multi-scale attention module with cross-spatial learning[C]// IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Rhodes Island, 2023: 1 - 5.

[22] RONNEBERGER O, FISCHERF P, BROX T. U - Net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, Munich, Proceedings, Part Ⅲ 18. Springer International Publishing, 2015:234 - 241.

[23] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]// Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR2017). Hawaii:IEEE, 2017: 6230 - 6239.

[24] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018:833 - 851.

[25] WANG J, LONG X, CHEN G, et al. U - HRNet: delving into improving semantic representation of high reolution network for dense prediction[J]. arXiv, 2022, 1:13.