doi:10.6041/j.issn.1000-1298.2022.08.022

基于MHSA + DeepLab v3 + 的无人机遥感影像小麦倒伏检测

杨蜀秦[1,2]　王鹏飞[1,2]　王　帅[1,2]　唐云松[1,2]　宁纪锋[3,4]　奚亚军[5]

(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. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100; 4. 西北农林科技大学信息工程学院, 陕西杨凌 712100;
5. 西北农林科技大学农学院, 陕西杨凌 712100)

摘要: 倒伏是影响小麦产量和质量的重要因素之一,及时准确获取倒伏信息有利于小麦良种选育中的倒伏损失鉴定。本文以小麦灌浆期和成熟期两个生长阶段的可见光无人机遥感影像为依据,构建多生长阶段小麦倒伏数据集,通过在 DeepLab v3 + 模型中添加不同的注意力模块进行比较分析,提出一种基于多头自注意力(MHSA)的 DeepLab v3 + 小麦倒伏检测模型。试验结果表明,提出的 MHSA + DeepLab v3 + 模型的平均像素精度(Mean pixel accuracy, mPA)和均交并比(Mean intersection over union, mIoU),灌浆期分别为 93.09% 和 87.54%,成熟期分别为 93.36% 和 87.49%。与代表性的 SegNet、PSPNet 和 DeepLab v3 + 模型相比,在灌浆期 mPA 提高了 25.45、7.54、1.82 个百分点和 mIoU 提高了 36.15、11.37、2.49 个百分点,在成熟期 mPA 提高了 15.05、6.32、0.74 个百分点,mIoU 提高了 23.36、9.82、0.95 个百分点。其次,相比于 CBAM 和 SimAM 两种注意力模块,在灌浆期及成熟期基于多头自注意力的 DeepLab v3 + 表现均为最优,在灌浆期其 mPA 和 mIoU 分别提高了 1.6、2.07 个百分点和 1.7、2.45 个百分点,成熟期提高了 0.27、0.11 个百分点和 0.26、0.15 个百分点。研究表明提出的改进的 DeepLab v3 + 模型能够有效地捕获灌浆期和成熟期的无人机小麦遥感图像中的倒伏特征,准确识别不同生育期的倒伏区域,具有良好的适用性,为利用无人机遥感技术鉴定小麦倒伏灾害等级和良种选育等提供了参考。

关键词: 小麦; 倒伏; 深度语义分割; 无人机遥感; 注意力机制; DeepLab v3 +

中图分类号: TP753　　**文献标识码**: A　　**文章编号**: 1000-1298(2022)08-0213-07　　**OSID**:

Detection of Wheat Lodging in UAV Remote Sensing Images Based on Multi-head Self-attention DeepLab v3 +

YANG Shuqin[1,2]　WANG Pengfei[1,2]　WANG Shuai[1,2]　TANG Yunsong[1,2]　NING Jifeng[3,4]　XI Yajun[5]

(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. *Shaanxi Key Laboratory of Agricultural Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*
4. *College of Information Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
5. *College of Agronomy*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Lodging is one of the main factors, which affect the yield and quality of wheat. Timely and accurate acquisition of wheat lodging information is beneficial to cultivating fine varieties and identifying lodging losses in agricultural insurance. A multi-growth stage wheat lodging dataset was constructed based on the visible light UAV remote sensing images of the two growth stages of wheat: grain filling stage and mature stage. By adding different attention modules to the DeepLab v3 + model for comparative analysis, a DeepLab v3 + wheat lodging detection model based on multi-head self-attention was proposed to accurately detect the lodging areas during wheat growth. The experimental results showed that the mPA and mIoU of the proposed multi-head self-attention DeepLab v3 + model were 93.09%, 87.54% (the grain filling stage) and 93.36%, 87.49% (the mature stage), which were improved by 25.45, 7.54, 1.82 (mPA) and 36.15, 11.37, 2.49 (mIoU) percentage points at the grain-filling stage and outperformed by 15.05, 6.32, 0.74 (mPA) and 23.36, 9.82, 0.95 (mIoU) percentage points at the mature stage, compared with the representative SegNet, PSPNet and DeepLab v3 + models,

收稿日期: 2022-05-01　修回日期: 2022-05-31

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: 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

respectively. Secondly, compared with the two attention modules of CBAM and SimAM, DeepLab v3 + based on multi-head self-attention performed the best in both the grain filling stage and the mature stage, and its mPA and mIoU were increased by 1.6, 2.07 and 1.7, 2.45 percentage points at the grain-filling stage and increased by 0.27, 0.11 and 0.26, 0.15 percentage points at the mature stage. The results showed that the improved DeepLab v3 + model captured the lodging features in the UAV remote sensing images of wheat at the grain filling and mature stages effectively and identified the lodging areas in different growth stages precisely, and it had good applicability. It provided a reference for the identification of wheat lodging disaster grades and breeding of improved varieties by using UAV remote sensing technology.

Key words: wheat; lodging; deep semantic segmentation; UAV remote sensing; attention mechanism; DeepLab v3 +

0 引言

小麦作为世界三大主要粮食作物之一,是淀粉、蛋白质、维生素、膳食纤维等植物化学物质的重要来源[1]。受气候、品种性状或栽培管理不当等因素影响,在小麦生育中后期,容易发生倒伏现象。灌浆期的小麦植株受倒伏影响容易发生病虫害,会降低小麦产量和品质。成熟期倒伏小麦匍匐在地,将增大小麦收割难度,导致收获小麦的经济和时间成本增加[2]。因此,选育具有抗倒伏能力的小麦品种对于育种非常重要。另外,准确鉴定小麦倒伏程度也是保险公司勘定农业损失并估算灾害理赔金额的重要依据。

小麦倒伏从形式上可分为根倒伏和茎倒伏,根倒伏源自小麦发育不良造成的扎根浅,一经风吹雨打就会匍匐于地或土沉根歪;茎倒伏主要是小麦茎秆中糖分积累变少和茎壁变薄,减弱了抗倒能力,茎基部节间(多数是基部三节)弯曲倾斜或折断后平铺于地[3]。一些学者利用正常小麦和倒伏小麦在颜色和空间结构上的不同,基于卫星和无人机两种遥感技术,利用经典机器学习和深度学习方法开展小麦倒伏识别研究。高空卫星遥感探测面积大、周期短,适用于大尺度范围下小麦农田的农情信息获取[4-5]。基于 Radarsat - 2 全极化影像数据,杨浩等[6]提出了一种利用雷达极化指数检测小麦倒伏的方法,实现了对小麦抽穗灌浆期的倒伏检测;胡宗杰等[7]通过人工模拟小麦灌浆期的倒伏现象,采用光谱仪测量倒伏小麦的光谱反射率,研究表明小麦在灌浆期倒伏后,其光谱变化明显,且与倒伏角度有关,为高分辨率遥感影像检测小麦倒伏提供了理论基础。无人机遥感技术在获取田块级小麦生长信息方面具有机动灵活、时效性强和分辨率高等特点[8-12]。LIU 等[13]基于无人机获得的图像中的光谱和纹理特征来确定小麦倒伏区域;CHAUHAN 等[14]对无人机多光谱影像,利用多分辨率分割和最近邻分类算法根据倒伏的程度将小麦倒伏区域划分为正常、中度、重度和极重度;李广等[15]提取小麦无人机可见光影像中倒伏区域的两个单特征,构建倒伏信息的综合特征,结合 k 均值算法,提出了一种多时相倒伏面积提取方法;赵静等[16]采用无人机遥感平台获取小麦倒伏后的冠层可见光图像,利用最大似然法和随机森林法对数字表面模型和可见光融合图像以及数字表面模型和过绿特征指数融合图像进行监督分类提取小麦倒伏面积。CAO 等[17]提出了一种基于分水岭和自适应阈值分割的小麦倒伏提取方法,将两种算法结合减少噪声对提取小麦倒伏信息的影响。以上研究主要对于单个生长阶段使用经典的机器学习方法识别小麦倒伏,其特征选择依赖于传统方法,模型泛化性能较弱,难以应用于多生长阶段的小麦倒伏监测。ZHANG 等[18]提出一种结合迁移学习和 DeepLab v3 + 的方法提取试验条件下通过人工干预得到不同生长阶段的小麦倒伏信息,然而其在多生育期大田小麦自然倒伏的监测还需进一步验证。为提升多生育期农田环境下无人机可见光遥感影像对倒伏小麦的解译能力,本文采用多头自注意力模块优化 DeepLab v3 + 的骨干网络,提出一种基于多头自注意力的深度语义分割模型获取小麦倒伏信息。并与 SegNet[19]、PSPNet[20]和 DeepLab v3 +[21]模型以及添加不同注意力模块的 DeepLab v3 + 模型进行比较,以期为利用无人机遥感技术鉴定小麦倒伏灾害和良种选育等提供参考。

1 研究区域与数据

1.1 研究区域概况

研究区域位于陕西省关中平原西部杨凌农业高新技术产业示范区曹新庄试验农场(图 1),介于东经 107°59′ ~ 108°08′,北纬 34°14′ ~ 34°20′之间,平均海拔 530 m,属东亚暖温带半湿润半干旱气候区,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。年均气温 12.9℃、无霜期 211 d、

日照时数 2 163.8 h、总太阳辐射量 114.86 kcal/cm^2 和降水量 635.1 mm，具备小麦适宜生长的自然条件。

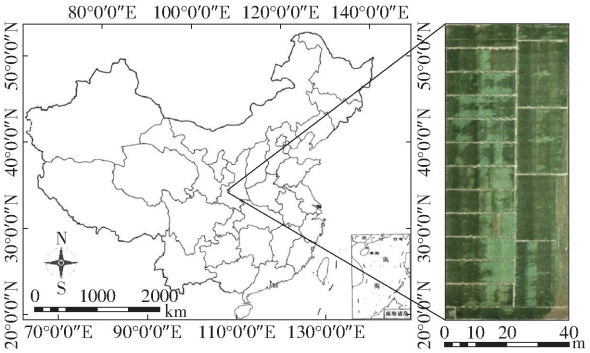

图 1　研究区位置

Fig. 1　Location of study area

1.2　数据采集及标注

2021 年 5 月中旬杨凌出现大风、暴雨等恶劣天气，导致试验田小麦发生严重倒伏，实地调查部分小麦倒伏情况如图 2 所示。本研究于 2020 年 5 月 18 日和 6 月 2 日分别采集试验田小麦灌浆期和成熟期的无人机可见光遥感影像。无人机型号为大疆精灵 4 RTK，最大飞行时间约 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。数据获取于当日 10:00—12:00。5 月 18 日气温 14 ~ 28℃，多云，东风 2 级；6 月 2 日气温 18 ~ 33℃，多云，东南风 2 级。无人机飞行高度 25 m，飞行速度 1.5 m/s，航向重叠率 85%，旁向重叠率 75%，共规划 14 条航线，获得原始图像 506 幅。采用大疆智图软件拼接无人机遥感原始图像，获得试验田数字正射影像。



图 2　小麦倒伏情况示例

Fig. 2　Examples of wheat lodging

试验区域包含 17 个育种小区，如图 3 所示，其中小面积育种小区 13 个（1 ~ 12 号、17 号），大面积育种小区 4 个（13 ~ 16 号），其余未框选区域为隔离带。遥感影像中小麦在灌浆期和成熟期发生倒伏时冠层的颜色、纹理等特征均存在明显差异，灌浆期的倒伏小麦偏浅绿且倒伏角度较小，而成熟期的倒伏小麦偏浅黄色且倒伏角度较大基本贴近地面。利用 Labelme 软件进行小麦倒伏标注，目视解译结合人工实地调查对倒伏区域的标注结果如图 4 所示。

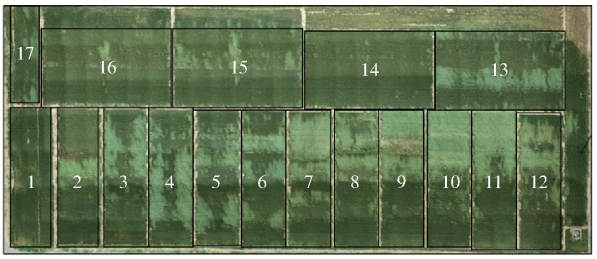

图 3　试验田育种小区布局图

Fig. 3　Layout of experimental field breeding plot

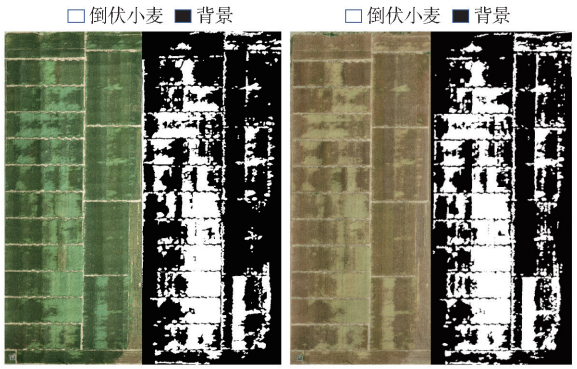

(a) 灌浆期　　(b) 成熟期

图 4　小麦 2 个生长阶段的可见光图像和相应的标签图像

Fig. 4　RGB images of two growth stages of wheat and corresponding lodging area labels

1.3　数据集构建及分析

以育种小区为基本单元对拼接标注后试验田正射影像进行裁剪。统计试验区域各育种小区灌浆期和成熟期倒伏小麦面积占比如图 5 所示。可以看出，试验区域小麦倒伏情况存在着较大差异。灌浆期的 11 个育种小区中，倒伏小麦面积占比达到 40% 以上。而成熟期时，这些育种小区倒伏进一步加重，如 17 号小区的倒伏占比从 30% 增至 45%。由图 4 可知，小麦倒伏区域分布不规律，小部分小麦倒伏区域分布十分零散，大部分小麦倒伏区域分布集中表现为成片倒伏。在构建数据集时应充分考虑以上问题，增加训练集数据多样性，以得到泛化性能

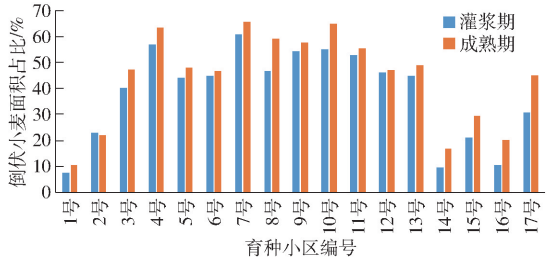

图 5　小麦倒伏情况统计分析

Fig. 5　Statistical analysis of wheat lodging

最优的模型。

按照 3∶1 比例将育种小区划分为训练验证集和测试集,6 号、12 号、13 号和 17 号 4 个育种小区为测试集,而其余 13 个育种小区作为训练验证集。其中,训练集用于训练调整网络模型权重,验证集用于评估最优的模型超参,测试集用于评估最终模型的性能[22]。考虑到深度学习网络性能对于数据集容量的依赖性,本文通过扩充训练集,获得大量图像数据,增强网络的泛化性能。另外,为加快训练速度,将训练集和验证集样本设置为 256 像素 × 256 像素。具体过程为:从训练集和验证集中随机裁取若干 256 像素 × 256 像素的图像,并对裁剪后的训练集图像做加噪、镜像、旋转和模糊等图像增强处理,最后获得的训练集图像数量为 9 032 幅,验证集图像数量为 1 004 幅。

2 研究方法

2.1 DeepLab v3 + 深度语义分割模型

语义分割结合了图像分类、目标检测和图像分割。首先将图像划分为具有一定语义含义的区域块,并识别出每个区域块的语义类别,实现从底层到高层的语义推理过程,最终得到一幅具有逐像素语义标注的分割图像。与传统的语义分割方法相比,基于卷积神经网络的语义分割方法自动学习图像的特征,实现端到端的分类学习,能够极大提升语义分割的精确度。

DeepLab v3 + 网络是通过对 DeepLab v3[23] 增加了编-解码模块和 Xception 主干网络改进而来。其中编解码模块主要用于恢复原始像素信息,更好地保留分割细节和同时编码丰富的上下文信息;而 Xception 主干网络采用深度卷积进一步提高算法的精度和速度。在 Xception 结构中,先对输入进行 1 × 1 的卷积,之后将通道分组,分别使用不同的 3 × 3 卷积提取特征,最后将各组结果串联在一起作为输出。

Deeplab v3 + 采用空洞卷积,使其在级联模块(采用 50 层或 101 层的 ResNet 网络)和空洞空间金字塔池化(Atrous spatial pyramid pooling, ASPP)的框架下,能够获得更多尺度的信息。DeepLab v3 + 解码部分借鉴了 FCN 的跳步连接方式,用中间一层低维特征图扩充输出图信息,以便更好地恢复边界细节。在提高网络尺寸适应性方面,DeepLab v3 + 为带孔空间金字塔池化模块增加了不同尺度范围内语义信息的区分和提取,利用多种比例和有效接受野的不同分辨率特征来挖掘多尺度的上下文内容信息,以实现对不同尺寸目标的识别。

2.2 基于多头自注意力的 DeepLab v3 + 小麦倒伏识别模型

2.2.1 DeepLab v3 + 识别小麦倒伏的局限性

在 DeepLab v3 + 模型中,虽然丰富的语义信息被编码,但骨干网络的多次下采样,使得倒伏小麦的边缘信息丢失,从而导致边缘模糊;使用空洞卷积可以缓解由于下采样过多使得倒伏小麦边缘信息丢失的问题,但空洞卷积会造成局部信息丢失以及远距离获取的信息关联减弱。此外 DeepLab v3 + 网络中 ASPP 结构使用不同扩张率(6、12、18)来并行处理输入特征以提取多尺度信息,但过大的扩张率会影响图像边缘特征的提取以及局部特征之间的关联,从而产生大尺度目标语义分割空洞现象[24],这将对农田无人机遥感影像中的大面积小麦倒伏的检测精度造成较大影响。

2.2.2 多头自注意力模型

Transformer[25] 中的多头自注意力(Multi-head self-attention, MHSA)模块因其可以捕获数据的全局依赖性,能够表示数据之间更丰富的联系,而受到广泛关注。在 MHSA 模块中对 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$($\boldsymbol{V}$ 为值向量,$\boldsymbol{Q}$ 为查询向量、$\boldsymbol{K}$ 为键向量)进行自注意力变换,这个过程独立重复 h 次(h 为 MHSA 模块中的头数),最后将 h 次比例点积注意力的结果进行拼接,再进行一次线性变换得到 MHSA 模块的最终输出。其本质就是多个独立的注意力计算然后再集成,每一个注意力机制函数只负责最终输出序列中一个子空间。

2.2.3 改进的 DeepLab v3 + 模型

鉴于 MHSA 复杂度较高,本文在低分辨率的高层语义特征上增加 MHSA。首先,将 DeepLab v3 + 中 ResNet[24] 骨干网络的 C5 层用多头自注意力模块代替,减轻骨干网络运算负担。其次,在高层特征上使用全局自注意力建立小麦倒伏特征的全局依赖关系,有效克服空洞卷积造成的远距离获取信息相关性弱和 ASPP 结构中过大扩张率对局部特征间关联性的影响。图 6 为提出的农田无人机遥感影像小麦倒伏识别深度语义分割模型结构。

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 NVIDIA TITAN V 显卡。操作系统为 Ubuntu 16.04,采用 Tensorflow 深度学习框架构建网络。为了验证本文提出改进的 DeepLab v3 + 网络的有效性,将其与 SegNet、PSPNet 和 DeepLab v3 + 等深度语义分割模型进行比较。训练深度语义分割模型时,基于在公共数据集上得到的预训练模型,在小

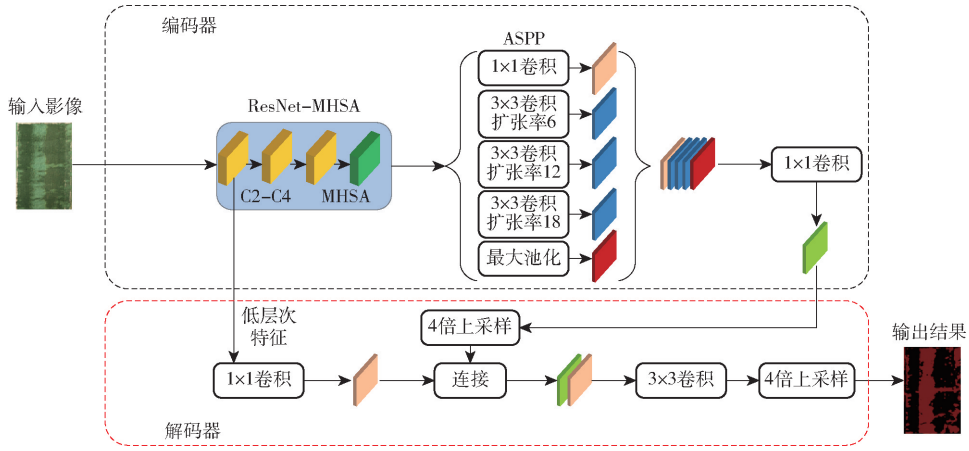

图 6　改进的 DeepLab v3 + 小麦倒伏检测网络结构图

Fig. 6　Network structure diagram of improved DeepLab v3 + for wheat lodging detection

麦倒伏数据集上进行迁移学习以训练小麦倒伏识别模型。最终，将训练好的模型在测试集上进行测试，计算模型准确度。所有模型均采用多项式衰减学习率调整策略，训练 100 个周期。其中 PSPNet 的初始学习率为 0.000 1，批处理尺寸为 32，矩为 0.9，权值退化率为 0.000 01；SegNet、DeepLab v3 + 以及改进的 DeepLab v3 + 初始学习率为 0.01，批处理尺寸为 32，矩为 0.9，权值退化率为 0.000 1。

2.3.2　评价指标

采用平均像素精度和均交并比作为分类结果评价指标，定量分析模型的分类性能。设有 $k+1$ 个类，令 n_{ij} 表示第 i 类被预测为第 j 类的像素数量。即 n_{ii} 表示预测准确的像素数量，而 n_{ij} 和 n_{ji} 分别表示假正和假负预测的数量。

像素精度（Pixel accuracy，PA）为正确分类像素数量与总像素数量之比，表示正确分类像素占总像素的比值。

平均像素精度（Mean pixel accuracy，mPA）为首先计算标签中每一类目标被正确分类的像素数量与标签中该类像素数量的比值，最后对所有类求平均值。

均交并比（Mean intersection over union，mIoU）为语义分割的标准度量。首先以标签中每一类目标被正确分类的像素数量除以标签和预测图像中该类像素数量并集，最后对所有类求平均值。均交并比表示每个类上预测值与真实值两个集合的交集和并集之比。

为了指导小麦倒伏灾害鉴定评价，定义倒伏比例（Lodging ratio，LR）评估育种小区小麦倒伏程度，计算式为

$$R=\frac{N}{M}\times 100\%$$

式中　M——育种小区图像总像素数量

N——倒伏小麦的像素数量

3　试验结果与分析

3.1　试验结果

4 种深度语义分割方法的试验结果如表 1 所示。图 7 以 13 号育种小区为例，显示了 4 种深度语义分割方法在多生长阶段小麦倒伏测试集上的检测效果。由图表可见，DeepLab v3 + 相较于 SegNet 和 PSPNet 表现出更好的性能，而改进的 DeepLab v3 + 模型则对应着最高的 mPA 和 mIoU，其检测效果最优。

表 1　无人机遥感影像小麦倒伏检测结果

Tab. 1　Comparison of wheat lodging detection results from UAV remote sensing images

方法	周期	mPA/%		mIoU/%	
		灌浆期	成熟期	灌浆期	成熟期
SegNet	100	67.64	78.31	51.39	64.13
PSPNet	100	85.55	87.04	76.17	77.67
DeepLab v3 +	100	91.27	92.62	85.05	86.54
改进的 DeepLab v3 +	100	93.09	93.36	87.54	87.49

3.2　试验结果分析

3.2.1　不同深度语义分割模型

由表 1 和图 7 可知，SegNet 灌浆期和成熟期的 mPA 仅有 67.64% 和 78.31%，并且存在严重的误检问题，不适用于小麦倒伏检测任务。PSPNet 在灌浆期和成熟期的 mPA 分别为 85.55% 和 87.04%，精度也不高，且结果存在严重的空洞，这一问题在小麦灌浆期尤为突出。相比之下 DeepLab v3 + 检测结果较为精细，对于小麦倒伏边缘及零散倒伏区域等细节方面表现出更好的性能，mPA 在灌浆期和成熟期分别比 PSPNet 高 5.72、5.58 个百分点，但空洞问题也不容忽视。而改进的 DeepLab v3 + 网络表现出更高的检测精度和更好的检测效果，在两个生长阶段

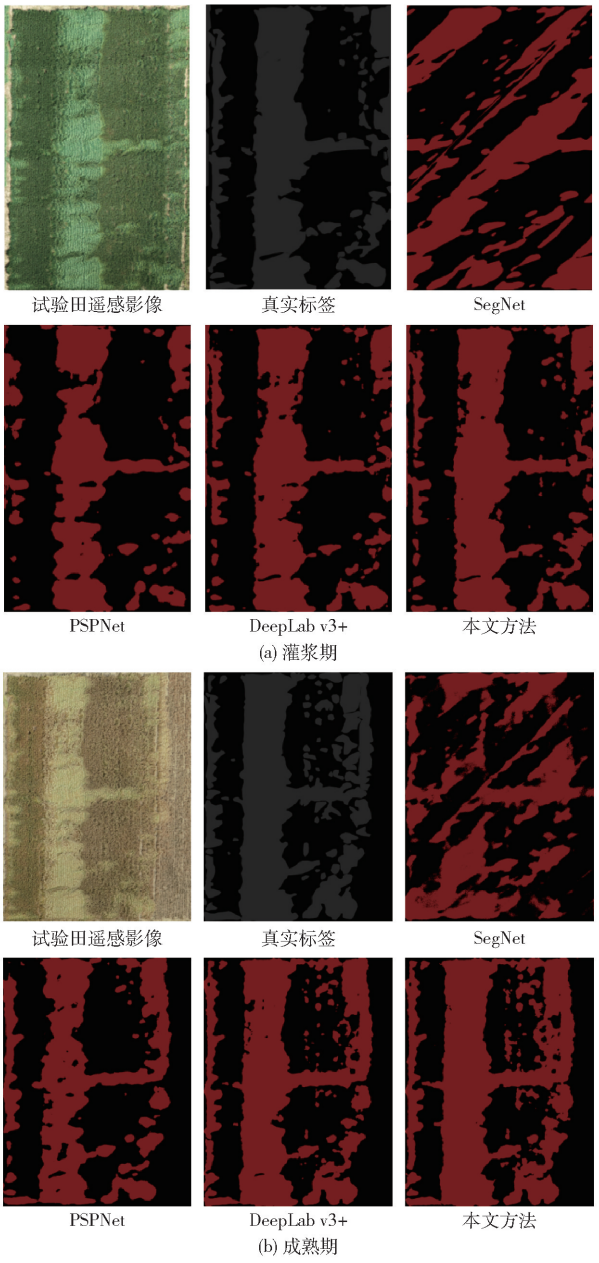

图 7 4 种深度语义分割模型对 13 号育种小区小麦倒伏的检测效果比较

Fig. 7 Comparison of detection effects of four deep semantic segmentation models on wheat lodging in No. 13 breeding plot

mPA 和 mIoU 指标均为最高,灌浆期 mPA 和 mIoU 分别为 93.09% 和 87.54%,成熟期 mPA 和 mIoU 分别为 93.36% 和 87.49%,误识别区域以及空洞问题较少。表明提出的基于多头自注意力的 DeepLab v3 + 对小麦倒伏有更好的特征提取能力,并具有较好的泛化性能,在灌浆期和成熟期效果均最佳。

3.2.2 不同注意力模块的 DeepLab v3 + 模型

为了验证提出的基于多头自注意力 DeepLab v3 + 捕获小麦倒伏特征的能力,表 2 为在 DeepLab v3 + 模型中添加不同注意力机制的试验结果比较。其中,CBAM[26]是一种用于前馈卷积神经网络的简单而有效的注意力模块,SimAM[27]是一种无需额外参数为特征图推导出 3D 注意力权值的简单有效的注意力模块。可以看出,在 DeepLab v3 + 模型中添加各种注意力机制后,mPA 和 mIoU 均有提升,但使用多头自注意力模块相较于原 DeepLab v3 + 模型灌浆期和成熟期的 mPA 分别提升了 1.82、0.74 个百分点,mIoU 分别提升了 2.49、0.95 个百分点,提升效果最为明显。

3.2.3 灌浆期和成熟期小麦倒伏识别结果分析

由表 1 可知,成熟期小麦倒伏识别的 mPA 均优于灌浆期小麦倒伏识别的 mPA,本文提出的方法在成熟期对小麦倒伏的识别精度达到 93.36%,比灌浆期高了 0.27 个百分点。由图 7 可见,不同生长阶段倒伏小麦与正常小麦的纹理特征对比明显,而就颜色特征而言,灌浆期倒伏小麦中心部分呈浅绿色,与正常小麦对比明显,但边缘部分颜色与正常小麦接近,成熟期倒伏小麦中心部分呈黄绿色,边缘部分呈白黄色,与正常小麦均对比明显。因此,算法更容易提取成熟期倒伏小麦零散区域以及边缘区域的特征,从而达到比灌浆期更好的识别精度。总体上,本文方法在灌浆期和成熟期预测结果较为接近,显示了其良好的泛化性能。

表 3 为测试集 4 个育种小区倒伏比例的预测结果。可以看出,在灌浆期小麦倒伏预测结果大都比真实结果偏低,识别的平均误差为 1.94%,在成熟期小麦倒伏预测结果大都比真实结果偏高,识别的平均误差为 2.27%, 总体预测误差均较小,验证了本文方法预测小麦倒伏比例的可靠性。

表 2 不同注意力机制的小麦倒伏检测结果

Tab. 2 Comparison of wheat lodging detection results with different attention mechanisms %

评价指标	DeepLab v3 +		CBAM – DeepLab v3 +		SimAM – DeepLab v3 +		改进的 DeepLab v3 +	
	灌浆期	成熟期	灌浆期	成熟期	灌浆期	成熟期	灌浆期	成熟期
mPA	91.27	92.62	91.49	93.09	91.39	93.10	93.09	93.36
mIoU	85.05	86.54	85.47	87.38	85.09	87.34	87.54	87.49

4 结论

(1)基于多头自注意力的 DeepLab v3 + 模型的

表 3　测试集育种小区倒伏识别结果

Tab. 3　Analysis of lodging identification results of breeding plots in test set　%

育种小区编号	灌浆期倒伏比例		灌浆期误差	成熟期倒伏比例		成熟期误差
	预测值	真实值		预测值	真实值	
6 号	42.23	44.73	2.50	47.86	46.56	1.30
12 号	44.60	46.18	1.58	49.11	47.17	1.94
13 号	42.27	44.81	2.54	49.92	48.92	1.00
17 号	31.71	30.59	1.12	40.29	45.13	4.84
平均误差			1.94			2.27

识别精度优于 SegNet、PSPNet 和 DeepLab v3 + 模型，与基于 CBAM 和 SimAM 注意力的 DeepLab v3 + 相比，提出方法也取得更好的识别结果，验证了其在解译农田小麦倒伏遥感影像方面的有效性。

(2)改进的 DeepLab v3 + 模型在灌浆期和成熟期两个生长阶段的倒伏小麦识别精度为 93.09% 和 93.36%，表明提出的方法能够从不同生育期的小麦遥感影像中精准地识别倒伏区域。

参　考　文　献

[1] SHEWRY P R, HEY S J. The contribution of wheat to human diet and health[J]. Food Energy Secur, 2015, 4(3): 178 - 202.

[2] 杨扬, 杨建宇, 李绍明, 等. 玉米倒伏胁迫影响因子的空间回归分析[J]. 农业工程学报, 2011, 27(6): 244 - 249.
YANG Yang, YANG Jianyu, LI Shaoming, et al. Spatial regression analysis on influence factors of maize lodging stress[J]. Transactions of the CSAE, 2011, 27(6): 244 - 249. (in Chinese)

[3] WU W, MA B L. A new method for assessing plant lodging and the impact of management options on lodging in canola crop production[J]. Sci. Rep., 2016, 6: 31890.

[4] HASITUY A, CHEN Z X, WANG L M, et al. Selecting appropriate spatial scale for mapping plastic-mulched farmland with satellite remote sensing imagery[J]. Remote Sensing, 2017, 9(3): 265.

[5] 张宏鸣, 张国良, 朱珊娜, 等. 基于 U - Net 的葡萄种植区遥感识别方法[J]. 农业机械学报, 2022, 53(4): 173 - 182.
ZHANG Hongming, ZHANG Guoliang, ZHU Shanna, et al. Remote sensing recognition method of grape planting regions based on U - Net[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 173 - 182. (in Chinese)

[6] 杨浩, 杨贵军, 顾晓鹤, 等. 小麦倒伏的雷达极化特征及其遥感监测[J]. 农业工程学报, 2014, 30(7): 1 - 8.
YANG Hao, YANG Guijun, GU Xiaohe, et al. Radar polarimetric response features and remote sensing monitoring of wheat lodging[J]. Transactions of the CSAE, 2014, 30(7): 1 - 8. (in Chinese)

[7] 胡宗杰, 张杰, 王召海. 灌浆期小麦倒伏后光谱变化特征[J]. 安徽农业科学, 2011, 39(6): 3190 - 3192.
HU Zongjie, ZHANG Jie, WANG Zhaohai. Spectral variation characteristics of wheat lodging in the filling eriod[J]. Journal of Anhui Agricultural Sciences, 2011, 39(6): 3190 - 3192. (in Chinese)

[8] 纪景纯, 赵原, 邹晓娟,等. 无人机遥感在农田信息监测中的应用进展[J]. 土壤学报, 2019, 56(4): 773 - 784.
JI Jingchun, ZHAO Yuan, ZOU Xiaojuan, et al. Adcancement in application of UAV remote sensing to monitoring of farmlands [J]. Acta Pedologica Sinica, 2019, 56(4): 773 - 784. (in Chinese)

[9] 李德仁, 李明. 无人机遥感系统的研究进展与应用前景[J]. 武汉大学学报(信息科学版), 2014, 39(5): 505 - 513.
LI Deren, LI Ming. Research advance and application prospect of unmanned aerial vehicle remote sensing system [J]. Geomatics and Information Science of Wuhan University, 2014, 39(5): 505 - 513. (in Chinese)

[10] 韩文霆, 郭聪聪, 张立元,等. 基于无人机遥感的灌区土地利用与覆被分类方法[J]. 农业机械学报, 2016, 47(11): 270 - 277.
HAN Wenting, GUO Congcong, ZHANG Liyuan, et al. Classification method of land cover and irrigated farm land use based on UAV remote sensing in irrigation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(11): 270 - 277. (in Chinese)

[11] 戴建国, 张国顺, 郭鹏, 等. 基于无人机遥感可见光影像的北疆主要农作物分类方法[J]. 农业工程学报, 2018, 34(18): 122 - 129.
DAI Jianguo, ZHANG Guoshun, GUO Peng, et al. Classification method of main crops in northern Xinjiang based on UAV visible waveband images[J]. Transactions of the CSAE, 2018, 34(18): 122 - 129. (in Chinese)

[12] WU M, YANG C, SONG X, et al. Evaluation of orthomosics and digital surface models derived from aerial imagery for crop type mapping[J]. Remote Sensing, 2017, 9(3): 239.

[13] LIU H Y, YANG G J, ZHU H C. The extraction of wheat lodging area in UAV's image used spectral and texture features[J]. Applied Mechanics and Materials, 2014, 651 - 653: 2390 - 2393.

[14] CHAUHAN S, DARVISHZADEH R, LU Y, et al. Wheat lodging assessment using multispectral UAV data[C]// The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2019, XLII - 2/W13: 235 - 240.

[15] 李广, 张立元, 宋朝阳,等. 小麦倒伏信息无人机多时相遥感提取方法[J]. 农业机械学报, 2019, 50(14): 211 - 220.
LI Guang, ZHANG Liyuan, SONG Chaoyang, et al. Extraction method of wheat lodging information based on multi-temporal UAV remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(4): 211 - 220. (in Chinese)

[16] 赵静, 潘方江, 兰玉彬,等. 无人机可见光遥感和特征融合的小麦倒伏面积提取[J]. 农业工程学报, 2021, 37(3): 73 - 80.
ZHAO Jing, PAN Fangjiang, LAN Yubin, et al. Wheat lodging area extraction using UAV visible light remote sensing and feature fusion[J]. Transactions of the CSAE, 2021, 37(3): 73 - 80. (in Chinese)

(下转第 239 页)