

# 基于无人机遥感影像的多生育期冬小麦种植行检测方法

杨蜀秦<sup>1,2</sup> 林丰山<sup>1,2</sup> 徐鹏辉<sup>3,4</sup> 王鹏飞<sup>1,2</sup> 王 帅<sup>1,2</sup> 宁纪锋<sup>3,4</sup>

(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:** 大田环境下小麦种植行的识别与定位对农机田间喷药和除草等任务的导航作业具有重要意义。以分蘖期和拔节期的冬小麦无人机可见光遥感影像为研究数据, 结合深度语义分割和霍夫变换直线检测, 提出了一种多生育期小麦种植行检测方法。采用 SegNet 深度语义分割提取小麦种植区域, 克服传统检测方法对光照敏感的同时提高检测精度。基于霍夫变换的小麦种植行预检测结果, 提出采用二分 k 均值聚类进一步提炼检测结果, 以识别出小麦种植行区域的中心线。实验结果表明, 对于分蘖期和拔节期的冬小麦图像, 种植行直线平均位置偏差的绝对值分别为 0.55、0.11 cm; 平均角度偏差的绝对值分别为 0.0011、0.00037 rad, 检测精度与直线漏检率等指标都显著优于传统方法。研究结果为智能农机导航作业中的作物种植行检测提供了方法支持。

**关键词:** 冬小麦; 农机导航; 无人机遥感; 种植行提取; 深度语义分割

中图分类号: TP753 文献标识码: A 文章编号: 1000-1298(2023)02-0181-08

OSID:



## Planting Row Detection of Multi-growth Winter Wheat Field Based on UAV Remote Sensing Image

YANG Shuqin<sup>1,2</sup> LIN Fengshan<sup>1,2</sup> XU Penghui<sup>3,4</sup> WANG Pengfei<sup>1,2</sup> WANG Shuai<sup>1,2</sup> NING Jifeng<sup>3,4</sup>

(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 Agricultural 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:** The identification and location of wheat planting rows in the field environment is of great significance to the navigation operation of agricultural machinery such as pesticide spraying and weeding in the field. A method for detecting wheat planting row at multiple growth stages was proposed based on visible light remote sensing images of winter wheat at tillering stage and jointing stage obtained by unmanned aerial vehicle, combining with deep semantic segmentation and Hough transform linear detection. Firstly, wheat planting regions were extracted by SegNet deep semantic segmentation to overcome the sensitivity of traditional detection methods to light and improve detection accuracy. Secondly, based on the pre-detection results of wheat planting rows by Hough transform, dichotomy k-means clustering was proposed to further refine the detection results to identify the center line of wheat planting rows. Respectively, for winter wheat images at tillering stage and jointing stage, the mean absolute values of straight position deviation of planting row were 0.55 cm and 0.11 cm, and the mean absolute values of angle deviation were 0.0011 rad and 0.00037 rad. It was superior to the traditional method in detecting accuracy and line missing rate. The research results can provide a method for detecting the direction of crop planting in the navigation operation of intelligent agricultural machinery.

**Key words:** winter wheat; navigation of agricultural machinery; UAV remote sensing; planting row detection; deep semantic segmentation

## 0 引言

大田环境下小麦采用成行种植以增加光暴露、提供换气通道,方便进行除草和施肥作业<sup>[1-2]</sup>。种植行方向的识别和准确定位不仅是农机视觉导航的基础<sup>[3-4]</sup>,而且对于作物种植情况分析、精准施药、中耕除草和优化农田管理等工作都有重要意义<sup>[5-11]</sup>。

无人机遥感具备灵活机动、时效性强和分辨率高等优势,已被广泛用于小麦长势监测<sup>[12]</sup>、产量估算<sup>[13]</sup>和倒伏面积提取<sup>[14]</sup>等农情信息分析。许多研究者基于无人机遥感影像采用超绿特征和霍夫变换等传统图像处理方法开展了种植行提取研究,并已在小麦种植行和玉米垄估计中取得了较好的效果。如王晓杰<sup>[15]</sup>采用超绿特征、基于移动窗的特征点提取以及霍夫变换、聚类等方法提取小麦、大豆等作物种植行;苏伟等<sup>[16]</sup>应用霍夫变换提取育种玉米垄数,精度可达90%以上;RAMESH等<sup>[17]</sup>采用k均值算法、数学形态学和几何运算的空间方法检测番茄行;BASSO等<sup>[18]</sup>采用超绿特征提取、阈值分割和霍夫变换等检测玉米种植行。但是这些方法仅适用于作物行完整的田间条件下,当面临种植行稀疏、杂草干扰和封垄等情况时,传统的种植区域提取和种植行检测方法效果较差。

近年来,利用深度学习有效的特征表示和端到端的学习能力<sup>[19]</sup>,将其应用于作物种植行检测的工作逐渐增多。PANG等<sup>[20]</sup>基于Masking Scoring R-CNN模型检测玉米种植行区域,在不考虑地形条件时,准确度较高;BAH等<sup>[21]</sup>提出一种基于CNN的霍夫变换组成的CRoWNet方法,检测甜菜地种植行。然而,文献[20]提出的方法仅提取种植行区域,并未考虑种植行中心线的检测。而且,文献[20-21]均未考虑在作物拔节期时趋于封垄的种植行提取。

本文结合深度学习和传统方法,分别利用其小麦种植行区域检测精度高和种植行中心线检测计算复杂度低的优势,研究多生育生长条件下的小麦种植行中心线提取问题。根据种植行整体性先验信息,构建SegNet<sup>[22]</sup>深度语义分割模型,提取小麦种植行区域;基于霍夫变换对种植行中心线预检测的结果,提出采用二分k均值聚类方法去除伪直线,优化种植行中心线检测效果,以期实现复杂环境下小麦种植行提取。

## 1 数据采集与处理

### 1.1 实验区域和设备

实验地点位于陕西省关中平原中部的杨凌农业

高新技术产业示范区曹新庄小麦育种试验田,中心坐标(34°18'23.23"N, 108°05'57.54"E),属于温带半干旱或半湿润气候,年平均气温11~13℃,年降水量500~700 mm。如图1a所示,小麦种植区域长约175 m,宽约98 m,面积约17 150 m<sup>2</sup>。该区域所种植冬小麦于2020年10月中旬播种,2021年6月中旬收获。

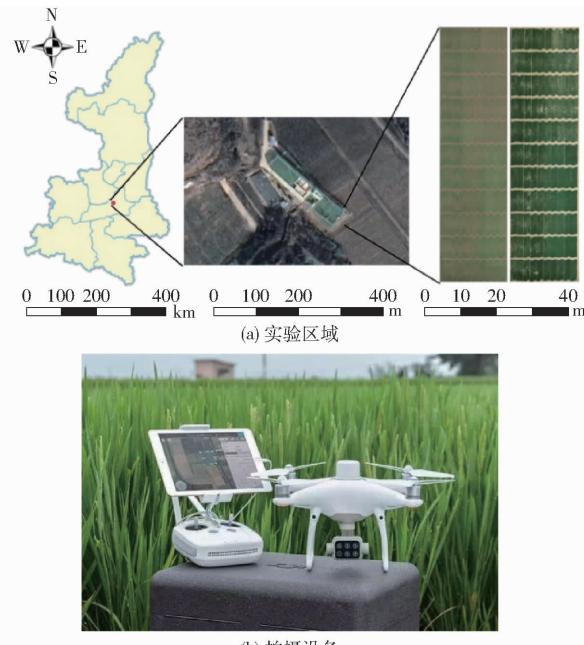


图1 实验区域和拍摄设备

Fig. 1 Experimental areas and imaging equipment

图像采集设备为大疆精灵4型多光谱版无人机,如图1b所示。该设备搭载1个可见光相机及5个多光谱相机。由于可见光传感器具有更高的分辨率,因此本研究采用可见光图像进行小麦种植行提取。

### 1.2 数据采集和分析

采用无人机采集分蘖期和拔节期2个阶段的冬小麦农田遥感影像,飞行具体参数如表1所示。每幅遥感图像分辨率约为4 000像素×15 000像素,通过Pix4Dmapper软件拼接。为方便处理,将拼接后的全景图像分割成分辨率256像素×256像素的若干子图,在子图上检测小麦种植行,并进行评价。

表1 小麦农田无人机影像参数

Tab. 1 Wheat field UAV image parameters

生育期	拍摄时间	飞行	地面采样	云台	航向	旁向
		高度/ m	距离/ (cm·像素 <sup>-1</sup> )	拍摄	重叠 率/%	重叠 率/%
分蘖期	2020年11月28日	30	1.59	垂直		85
拔节期	2021年3月13日	25	1.32	地面		75

图2列出了冬小麦分蘖期和拔节期不同情况下的种植行区域。其中,图2a、2d包括了清晰完整的

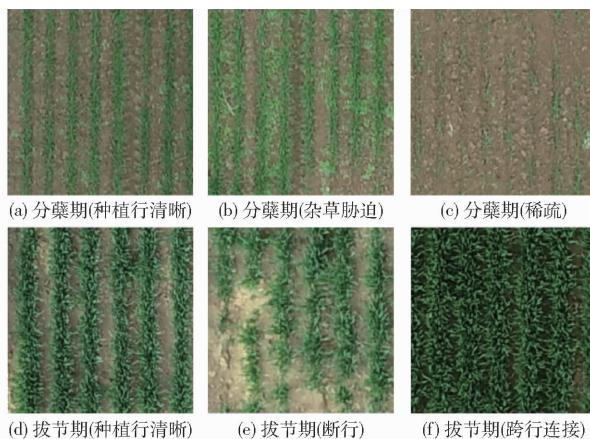


图 2 分蘖期和拔节期小麦无人机遥感图像

Fig. 2 UAV remote sensing images of wheat at tillering and jointing stages

小麦种植行, 图 2b 中存在杂草胁迫情况, 图 2c、2e 为种植行稀疏或不完整, 而图 2f 中种植行趋于封垄。可以看出, 这些复杂因素对小麦种植行中心线的提取造成了一定的困难。

### 1.3 数据集制作

采用开源软件 LabelMe 对拼接后的无人机遥感影像进行手工标注, 标注时将作物种植条形区域中有“仅存绿色作物”、“仅存裸土”和“种植行存在断行”这 3 种情况, 同归为“种植行”类, 并将标注后的图像裁剪为 256 像素  $\times$  256 像素的子图作为网络输入, 如图 3 所示。

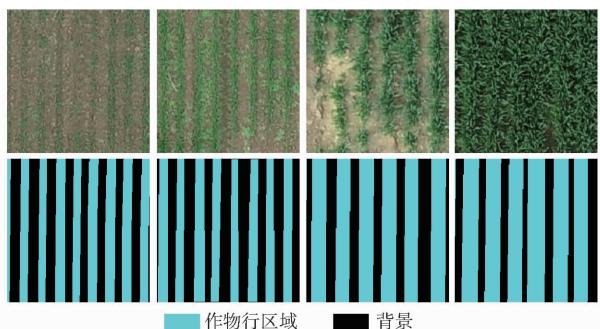


图 3 冬小麦无人机遥感图像的数据标注

Fig. 3 Data annotation of UAV remote sensing images of winter wheat

2 个时期小麦遥感影像中均包含 11 块相互独立的小麦种植区域, 从分蘖期和拔节期的图像中各选取 1 块区域作为测试集, 然后按照比例 9:1 划分 18 块区域作为训练集, 2 块区域作为验证集, 将训练集、验证集和测试集按照分辨率 256 像素  $\times$  256 像素进行分割, 得到共 2 165 幅训练集图像以及 241 幅验证集图像, 测试集包含 75 幅分蘖期图像和 147 幅拔节期图像。最后通过添加噪声、旋转以及亮度和饱和度变化等数据增强方式将最终的训练集扩充至 10 000 幅图像, 以提高模型鲁棒性。

## 2 检测方法

本文从种植行区域提取和行中心线确定两方面考虑小麦种植行检测, 其中, 小麦种植行区域的鲁棒提取是行中心线确定的关键。由图 2 可以看出, 小麦种植行具有明显的纹理特征, 这一特征可借助深度语义分割模型进行识别和优化; 其次, 对具有一定宽度的小麦种植行, 直接采用霍夫变换难以得到准确的中心线, 因此提出采用二分 k 均值聚类优化霍夫变换的直线检测结果。

### 2.1 基于深度语义分割的小麦种植行区域提取

像素级分类是语义分割领域里一个研究热点。其中, SegNet 作为一种代表性的语义分割方法, 主要由编码器、解码器和逐像素分类器组成, 具有对称简洁的 Encoder – Decoder 结构。如图 4 所示, SegNet 网络结构的左半部分是编码网络, 由经过预训练的 VGG16 的前 13 层作为特征提取层, 并通过丢弃全连接层在保留高分辨率特征映射的同时, 有效减少参数量。解码器与编码器对应, 同样具有 13 层, 将低分辨率的特征图映射为与输入相同的分辨率, 并送入分类器为每个像素独立地产生类别概率。

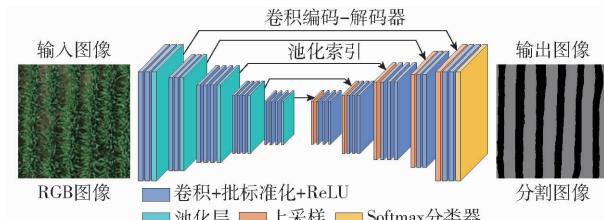


图 4 基于 SegNet 的小麦种植行区域提取网络模型

Fig. 4 Wheat planting row region extraction network model based on SegNet

编码器由 5 个 block 组成, 每个 block 进行卷积、批标准化和 ReLU 激活操作, 并通过最大池化的方法实现下采样。针对下采样会降低特征图分辨率, 从而损失边界信息这一不利于语义分割的问题, SegNet 在解码器部分使用相应编码器的最大池化步骤中计算的池化索引进行非线性上采样, 逐步恢复特征信息, 改善边界描述。因此 SegNet 核心在于解码器, 通过释放编码器中存储的位置信息得到较为完整的边缘, 在语义分割领域中得以广泛使用。

### 2.2 基于二分 k 均值聚类的小麦种植行中心直线检测

基于深度语义分割模型提取小麦种植行区域后, 需进一步确定小麦种植行的中心直线。针对每个小麦种植行区域, 采用霍夫变换直线检测, 从参数空间中可得到多组候选点, 从中确定最优的可表示种植行区域主方向的点。在农作物种植行

提取任务中多采用 k 均值聚类确定数据点的质心,从而得到最接近种植行区域中心的直线。然而,该方法容易陷入局部最优解而造成错检和漏检。为此,本文提出采用二分 k 均值聚类检测小麦种植行中心的方法。

二分 k 均值聚类算法改进自 k 均值聚类,它将整个数据集看成一个整体,求其平均值作为初始质心。首先,对数量仅为 1 个的初始质心进行二均值聚类并产生 2 个新的质心,接着对每个质心所代表的类计算其误差平方和,选择使得总误差平方和最大的类再次进行二均值聚类。依此类推,直到产生的质心数等于给定的聚类质心个数,即图像中包含的种植行条数。该方法能够避免算法陷入局部最优解,鲁棒性强,因此本文将霍夫变换算法中每组表示直线的极坐标参数作为聚类算法的样本数据,应用二分 k 均值聚类,得出代表每条种植行的聚类质心,从而消除种植行中存在的冗余直线。

在提取种植行区域后,对语义分割预测图像的像素进行垂直方向的投影,种植行区域所在列即为峰值,峰值点的个数即为每幅子图中所包含的种植行条数,并将其作为后续进行聚类过程所需提取的聚类质心的个数,因此本文所用方法可自适应地获取聚类质心个数  $k$ 。但这同时导致了后续处理依赖于种植行区域提取的效果,前一步处理若能够达到较精确程度,那么后续经过聚类后的结果即可避免出现直线错漏的情况。

## 2.3 实验方案

首先比较 DeepLabv3 +<sup>[23]</sup>、Segformer<sup>[24]</sup> 和 SegNet 3 种深度学习模型与传统特征提取方法在小麦种植区域提取的结果,选取最优模型进行小麦图像预处理。其次,基于提取的小麦种植行区域,采用霍夫直线检测以及提出的二分 k 均值聚类方法检测种植行中心线,验证所提出方法的有效性。

### 2.3.1 深度学习小麦种植行区域提取模型构建和精度评价

SegNet、Segformer 与 DeepLabv3 + 模型采用经过裁剪和数据增强后的 256 像素  $\times$  256 像素图像作为输入,预测时采用相同尺寸的图像进行种植行区域提取。

实验用的显卡为 GeForce RTX 2080Ti,显存为 10 GB,操作系统为 Ubuntu 16.04。特别地,SegNet 模型深度学习框架采用 Pytorch 1.2.0,编程语言及版本为 Python 3.6.10,迭代次数为 30 000 次,批尺寸为 6,学习率为  $1 \times 10^{-4}$ ,动量参数为 0.9。Segformer 模型深度学习框架采用 Pytorch 1.7.1,编程语言及版本为 Python 3.7.0,迭代次数为 160 000

次,批大小为 6,采用 Poly 策略动态调整学习率。DeepLabv3 + 模型深度学习框架采用 Tensorflow 1.14,编程语言及版本为 Python 3.6.5。迭代次数为 30 000 次,批大小为 6,初始学习率为 0.05,结束学习率为  $6 \times 10^{-6}$ ,权重衰减以及动量参数分别为 0.0008 和 0.9。

采用平均像素精度 (Mean pixel accuracy, MPA)<sup>[25]</sup> 衡量语义分割算法精度,通过分别计算每个类被正确分类像素数的比例,最后累加求平均的方式获得。

### 2.3.2 小麦种植行中心线精度评价

在种植行直线检测阶段,采用提出的作物行检测算法分别处理小麦分蘖期和拔节期的遥感图像,检测所得的作物行中心直线为预测直线,标注结果中作物行区域的中心直线作为真实直线,测量预测直线与真实直线相对水平方向角,定义 2 条直线的最大夹角为作物行的角度偏差,当预测直线角度相对真实直线角度为顺时针方向偏移时,偏差角为正值,反之则为负值。当预测直线相对真实直线发生水平方向平移时,定义平移距离为作物行的位置偏差,向右偏移时位置偏差为正值,反之则为负值,最后计算位置、角度偏差的标准差。角度偏差和位置偏差计算式为

$$\theta_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n \theta_i \quad (1)$$

$$\rho_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n \rho_i \quad (2)$$

式中  $\theta_{\text{mean}}$  —— 平均角度偏差  
 $n$  —— 图像中种植行数量  
 $\theta_i$  —— 第  $i$  条种植行对应的种植直线角度偏差  
 $\rho_{\text{mean}}$  —— 平均位置偏差  
 $\rho_i$  —— 第  $i$  条种植行对应的种植直线位置偏差

## 3 结果与讨论

### 3.1 实验结果

#### 3.1.1 基于超绿特征方法和深度语义分割的小麦种植行区域提取比较

基于超绿特征的传统方法和 2 种深度语义分割模型对小麦种植区域提取的结果如表 2 所示。可以看出,在分蘖期和拔节期,基于超绿特征的传统方法在检测速度上有优势,但在小麦种植区域提取精度上却远低于深度语义分割方法,显然这一指标在检测问题中更为看重,其中,SegNet 提取的小麦种植区域精度最高。在分蘖期和拔节期,SegNet 比

DeepLabv3+ 分别提高 3.8、0.5 个百分点, 检测速度快 28 f/s; 在种植行区域提取任务上, Segformer-B0 相较于 SegNet 精度相近, 然而检测速度慢 15 f/s。因此, 综合考虑精度和推理速度, 本实验采用 SegNet 方法提取小麦种植区域。

表 2 不同方法的小麦种植区域提取结果比较

Tab. 2 Comparison of extraction results of wheat planting regions by different methods

模型	时期	平均像素精度/%	检测速度/(f·s <sup>-1</sup> )
超绿特征方法	分蘖期	73.8	334
	拔节期	77.2	334
DeepLabv3 +	分蘖期	85.1	10
	拔节期	86.3	10
Segformer-B0	分蘖期	87.9	23
	拔节期	86.9	23
SegNet	分蘖期	88.9	38
	拔节期	86.8	38

图 5 为采用传统方法和 SegNet 语义分割模型进行小麦种植行区域提取的结果对比。在图 5a 中, 分蘖期小麦种植行稀疏, 传统方法的检测结果如图 5b 所示, 由于是基于超绿特征检测, 仅能分割出绿色作物, 因此小麦种植行区域出现严重缺失, 而在图 5c 中, 深度语义分割方法得到完整的种植行, 提取效果较传统方法具有明显的优势; 在图 5d 中, 拔节期小麦种植行出现封垄, 由于跨行连接处亮度较暗, 因此造成传统提取方法在连接处分割效果较差(图 5e), 而图 5f 则显示基于 SegNet 的方法仍能保持较好的分割效果, 体现了深度语义分割的鲁棒性。

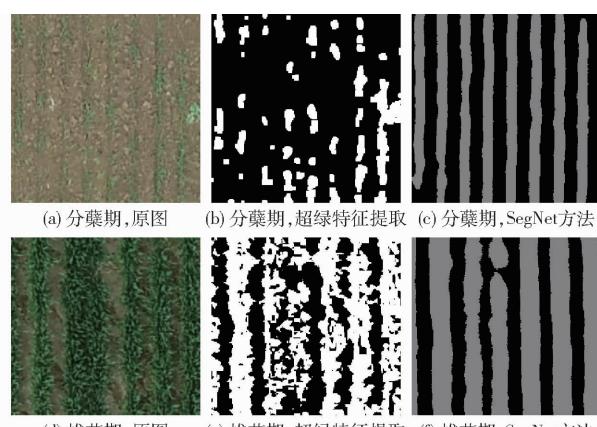


图 5 基于超绿特征的方法与深度语义分割方法提取小麦种植区域比较

Fig. 5 Comparison between method based on ultra-green feature and deep semantic segmentation method to extract wheat planting regions

### 3.1.2 基于二分 k 均值聚类的小麦种植行中心直线确定结果

表 3 对比了本文提出的二分 k 均值聚类和 k 均

值聚类确定种植区域中心线的结果, 表中  $S_l$  和  $S_d$  分别表示位置偏差和角度偏差的标准差。可以看出, 2 种方法对基于 SegNet 语义分割提取的小麦种植区域均能较好地检测行中心线。与 k 均值聚类中心线检测相比, 二分 k 均值聚类方法直线检测的漏、误检条数最低, 说明后者具有鲁棒性强、不易陷入局部最优解的优点。综上所述, 采用本文方法进行小麦种植行直线的检测, 分蘖期和拔节期小麦种植行直线平均位置偏差的绝对值分别为 0.55、0.11 cm; 平均角度偏差的绝对值分别为 0.0011、0.00037 rad, 标准差低, 检测精度高。

表 3 小麦分蘖期和拔节期种植区域中心线检测结果比较

Tab. 3 Comparison of center line detection results between tillering stage and jointing stage of wheat planting area

方法	生长期	直线条数	漏、误检条数	位置偏差/cm		角度偏差/rad	
				$\rho_{\text{mean}}$	$S_l$	$\theta_{\text{mean}}$	$S_d$
二分 k 均值聚类	分蘖期	589	5	-0.55	2.04	0.00110	0.035
聚类	拔节期	923	3	0.11	2.69	0.00037	0.014
k 均值聚类	分蘖期	589	98	0.12	8.69	0.00110	0.012
	拔节期	923	124	0.18	7.42	-0.00200	0.019

图 6 为杂草胁迫下 2 种中心线检测方法的结果比较。图 6a 和图 6c 中的数据点显示了检测到的直线参数, 其中横坐标为位置  $\rho$ , 纵坐标为角度  $\theta$ , 相同颜色的点属于同一种植行, “+”号表示算法直线检测的结果。可以看出, 在图 6a 中, k 均值聚类方法检测结果出现了偏差, “+”表示的聚类质心陷入了局部最优解, 不能准确反映每类数据点的中心, 其结果如图 6b 所示, 出现了明显的漏检和误检。本文所采用的二分 k 均值聚类对中心线的检测结果如图 6c 所示, “+”表示的聚类质心基本处于每一类数据点的中心, 从图 6d 可以看出, 每个作物行均得到了准确的检测结果。

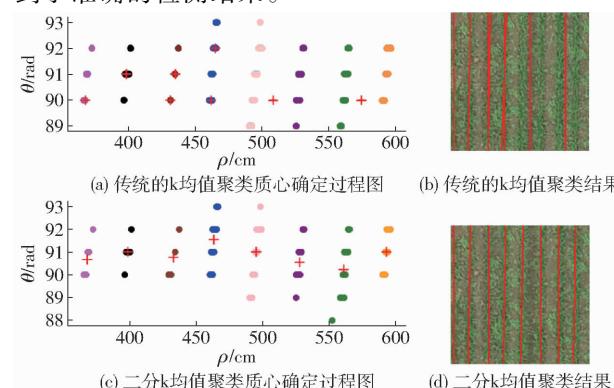


图 6 二分 k 均值和传统的 k 均值聚类小麦种植行中心线检测比较

Fig. 6 Comparison between binary k-means and traditional k-means clustering wheat planting row center line detection

### 3.1.3 多生育期冬小麦遥感图像种植行检测结果

采用本文所述冬小麦大田种植行检测算法对测试集中 75 幅分蘖期图像及 147 幅拔节期图像进行连续处理,并组合回原图尺寸。处理结果如图 7 所示,中心线在大图中基本能够保持连续,然而拼接处的部分中心线仍存在 1~3 像素的错位,对应实际地面尺寸则存在 1~5 cm 的误差。

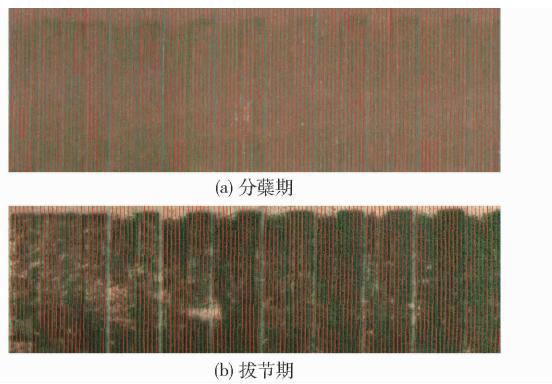


图 7 冬小麦大田种植行检测结果

Fig. 7 Test results of planting lines of winter wheat field

## 3.2 讨论

### 3.2.1 基于深度语义分割的多种小麦种植行表型提取分析

表 4 为 SegNet 网络模型在几种复杂小麦种植行表型条件下的分割精度,其中,“稀疏”和“杂草胁迫”多出现于分蘖期,而“断行”与“封垄”多出现于拔节期。实验表明,在稀疏、杂草胁迫和封垄条件下,SegNet 的 MPA 可达 93% 以上,而对断行现象的处理略差,但 MPA 也达到 87.1%。

表 4 复杂情况下深度语义分割模型提取的小麦种植区域 MPA

Tab. 4 Extraction MPA from wheat planting regions by deep semantic segmentation model under complex conditions

种植行表型	图像数量	MPA/%
稀疏	10	93.6
杂草胁迫	15	93.6
断行	13	87.1
封垄(跨行连接)	12	93.3

### 3.2.2 复杂条件下小麦种植行中心线确定分析

图 8 为拔节期作物行出现断行时,SegNet 和超绿特征检测的种植区域对后续种植行中心线确定的影响。如图 8a 方法流程预处理图像所示,基于超绿特征的种植区域难以提取完整的种植行,因此霍夫变换出现了漏检的情况。而由于 SegNet 模型强大的特征学习能力,即使出现断行,也仍被认为是与其他种植行相同的类,最终能够完整分割并得到正确的行中心线检测结果,如图 8b 方法流程中的聚类结

果所示。

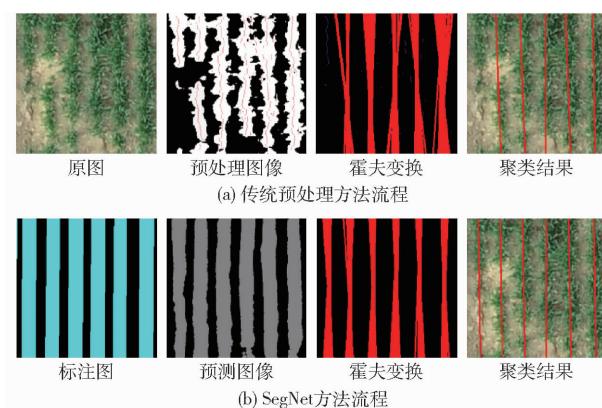


图 8 拔节期作物行断行条件下两种方法处理结果对比

Fig. 8 Comparison of treatment results of two methods under condition of crop line breaking at jointing stage

针对分蘖期中小麦行出现过于稀疏的现象,图 9 对比了传统图像处理方法及本文所提出的方法处理过程及结果。可见,与断行类似,稀疏条件下小麦特征点分布零散,导致直线检测算法无法成功检测中心直线,造成漏检;而 SegNet 模型预测图对每条稀疏作物行区域较为敏感,在稀疏条件下作物行仍保持分割完整。

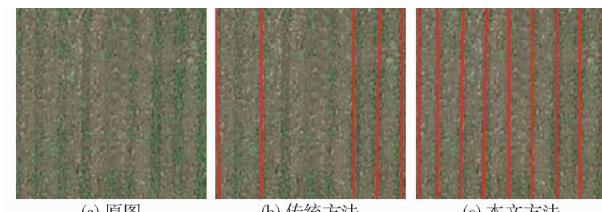


图 9 分蘖期小麦图像稀疏条件下两种方法处理结果对比

Fig. 9 Comparison of processing results of two methods under sparse conditions of wheat images at tillering stage

图 10 表示在麦田趋于封垄时,作物行间小麦特征点分布密集,超绿特征的分割结果对直线检测算法造成较大干扰,从此产生误检并出现很大偏差(图 10b),而语义分割仍能保持较强的鲁棒性,作物行独立并仍能完好地分割(图 10c)。

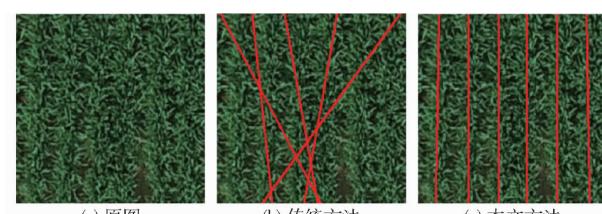


图 10 拔节期小麦图像封垄条件下两种方法处理结果对比

Fig. 10 Comparison of processing results of two methods under image weed stress in wheat at tillering stage

图 11 为传统图像处理方法和本文所提算法在一定杂草胁迫下分蘖期小麦图像的种植行检测提取过程,显然,传统图像处理方法以及本文所提方法都

能一定程度上避免杂草噪声的影响,最终处理结果趋于一致。

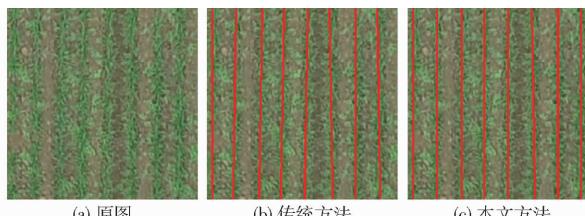


图 11 分蘖期小麦图像杂草胁迫条件下两种方法处理结果对比

Fig. 11 Comparison of processing results of two methods under image weed stress in wheat at tillering stage

综上所述,种植行直线检测效果取决于预处理结果。在传统图像处理方法中,对于小麦图像预处理不可避免地需要根据图像特征和研究者的个人经验应用多种阈值参数以达到去除杂草、避免光照或阴影等自然因素的影响,而在本文提出的方法中,引入深度学习方法替代预处理过程,仅需训练出合适的模型即可对麦田图像进行批量分割处理,并能对作物行区域达到很好的分割效果,后续即可应用多种直线检测算法提取农田作物种植行,大大提高了检测过程的鲁棒性。

植行,大大提高了检测过程的鲁棒性。

## 4 结论

(1) 针对多时相小麦图像种植行中心线检测,提出基于深度语义分割和霍夫变换的小麦种植行检测方法。在小麦种植区域提取中,深度学习方法具有像素级分类和可克服光照影响的优点,检测性能显著优于基于超绿特征的传统方法;在小麦种植区域中心线检测方面,针对基于霍夫变换的 k 均值聚类方法容易陷入局部最优解而造成错检和漏检,提出采用二分 k 均值聚类方法对检测结果进行改进,显著提升检测精度。

(2) 小麦种植区域的准确提取是中心线检测的关键。实验结果表明,SegNet 语义分割方法对于稀疏、杂草胁迫、断行和封垄等复杂条件下的种植区域分割 MPA 达 93% 以上,断行条件下仍达到 87.1%。结合提出的二分 k 均值聚类方法,对分蘖期和拔节期小麦种植行直线平均位置偏差的绝对值分别为 0.55、0.11 cm, 平均角度偏差的绝对值分别为 0.0011、0.00037 rad, 标准差低, 检测精度高。

## 参 考 文 献

- [1] 蒋赟,张丽丽,薛平,等. 我国小麦产业发展情况及国际经验借鉴[J]. 中国农业科技导报, 2021, 23(7): 1–10.  
JIANG Yun, ZHANG Lili, XUE Ping, et al. Development status of wheat industry in China and international experience for reference[J]. Journal of Agricultural Science and Technology, 2021, 23(7): 1–10. (in Chinese)
- [2] 陈鹏飞,马啸. 作物种植行自动检测研究现状与趋势[J]. 中国农业科学, 2021, 54(13): 2737–2745.  
CHEN Pengfei, MA Xiao. Research status and trends of automatic detection of crop planting rows[J]. Scientia Agricultura Sinica, 2021, 54(13): 2737–2745. (in Chinese)
- [3] 王侨,孟志军,付卫强,等. 基于机器视觉的玉米苗期多条作物行线检测算法[J]. 农业机械学报, 2021, 52(4): 208–220.  
WANG Qiao, MENG Zhijun, FU Weiqiang, et al. Detection algorithm of multiple crop row lines based on machine vision in maize seedling stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 208–220. (in Chinese)
- [4] 刘路,潘艳娟,陈志健,等. 高遮挡环境下玉米植保机器人作物行间导航研究[J]. 农业机械学报, 2020, 51(10): 11–17.  
LIU Lu, PAN Yanjuan, CHEN Zhijian, et al. Inter-rows navigation method for corn crop protection vehicles under high occlusion environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 11–17. (in Chinese)
- [5] 姜国权,柯杏,杜尚丰,等. 基于机器视觉的农田作物行检测[J]. 光学学报, 2009, 29(4): 1015–1020.  
JIANG Guoquan, KE Xing, DU Shangfeng, et al. Crop row detection based on machine vision[J]. Acta Optica Sinica, 2009, 29(4): 1015–1020. (in Chinese)
- [6] OLIVEIRA H C, GUIZILINI V C, NUNES I P, et al. Failure detection in row crops from UAV images using morphological operators[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(7): 991–995.
- [7] 刁智华,赵明珍,宋寅卯,等. 基于机器视觉的玉米精准施药系统作物行识别算法及系统实现[J]. 农业工程学报, 2015, 31(7): 47–52.  
DIAO Zhihua, ZHAO Mingzhen, SONG Yinmao, et al. Method for detecting crop rows based on binocular vision with census transformation[J]. Transactions of the CSAE, 2015, 31(7): 47–52. (in Chinese)
- [8] BURGOS-ARTIZZU X P, RIBEIRO A, GUIJARRO M, et al. Real-time image processing for crop/weed discrimination in maize fields[J]. Computer and Electronics in Agriculture, 2011, 75(2): 337–346.
- [9] RONCHETTI G, MAYER A, FACCHI A, et al. Crop row detection through UAV surveys to optimize on-farm irrigation management[J]. Remote Sensing, 2020, 12: 1967.
- [10] DE SOUZA C H W, LAMPARELLI R A C, ROCHA J V, et al. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images[J]. Computers and Electronics in Agriculture, 2017, 143: 49–56.
- [11] 陶惠林,徐良骥,冯海宽,等. 基于无人机高光谱遥感的冬小麦株高和叶面积指数估算[J]. 农业机械学报, 2020, 51(12): 193–201.  
TAO Huilin, XU Liangji, FENG Haikuan, et al. Estimation of plant height and leaf area index of winter wheat based on UAV

- hyperspectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 193–201. (in Chinese)
- [12] 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)
- [13] 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)
- [14] 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)
- [15] 王晓杰.基于机器视觉的农田作物行检测方法研究[D].焦作:河南理工大学,2016.  
WANG Xiaojie. Study on crop rows detection with machine vision[D]. Jiaozuo: Henan Polytechnic University, 2016. (in Chinese)
- [16] 苏伟,蒋坤萍,闫安,等.基于无人机遥感影像的育种玉米垄数统计监测[J].农业工程学报,2018, 34(10):92 – 98.  
SU Wei, JIANG Kunping, YAN An, et al. Monitoring of planted lines for breeding corn using UAV remote sensing image[J]. Transactions of the CSAE, 2018 , 34(10) :92 – 98. (in Chinese)
- [17] RAMESH K N, CHANDRIKA N, OMKAR S N, et al. Detection of rows in agricultural crop images acquired by remote sensing from a UAV[J]. International Journal of Image, Graphics and Signal Processing, 2016, 8(11):25 – 31.
- [18] BASSO M, EDISON P D F. A UAV guidance system using crop row detection and line follower algorithms[J]. Journal of Intelligent & Robotic Systems, 2020, 97:605 – 621.
- [19] 孙红,李松,李民赞,等.农业信息成像感知与深度学习应用研究进展[J].农业机械学报,2020,51(5): 1 – 17.  
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5):1 – 17. (in Chinese)
- [20] PANG Y, SHI Y Y, GAO S C, et al. Improved crop row detection with deep neural network for early-season maize stand count in UAV imagery[J]. Computers and Electronics in Agriculture, 2020,178:105766.
- [21] BAH M D, HAFIANE A, CANALS R. CRowNet: deep network for crop row detection in UAV images[J]. IEEE Access, 2019, 8:5189 – 5200.
- [22] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481 – 2495.
- [23] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//ECCV 2018, Munich, 2018.
- [24] XIE E, WANG W, YU Z, et al. SegFormer: simple and efficient design for semantic segmentation with transformers[C]// Advances in Neural Information Processing Systems, 2021: 12077 – 12090.
- [25] GARCIA-GARCIA A, ORTS-ESCOLANO S, OPREA S, et al. A review on deep learning techniques appliedto semantic segmentation[J]. arXiv preprint arXiv: 1704.06857,2017.

---

(上接第 180 页)

- [32] 王晓波,韩艳伟,关辅兴.基于 Sentinel-1 数据的双鸭山市水体信息提取[J].测绘与空间地理信息,2022,45(增刊1):97 – 99.  
WANG Xiaobo, HAN Yanwei, GUAN Fuxing. Extraction of water body information in Shuangyashan City based on Sentinel-1 data[J]. Surveying and Mapping and Spatial Geographic Information, 2022 , 45(Supp. 1) : 97 – 99. (in Chinese)
- [33] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62 – 66.
- [34] 安成锦,牛照东,李志军,等.典型 Otsu 算法阈值比较及其 SAR 图像水域分割性能分析[J].电子与信息学报,2010, 32(9): 2215 – 2219.  
AN Chengjin, NIU Zhaodong, LI Zhijun, et al. Comparison of the threshold of typical Otsu algorithms and analysis of water segmentation performance of SAR image[J]. Journal of Electronics and Information, 2010,32(9):2215 – 2219. (in Chinese)
- [35] 田鹏,李加林,曹罗丹,等.基于超效率 SBM 模型的中国海洋渔业经济效率评价及影响因素分析[J].海洋通报,2022, 41(3): 290 – 301.  
TIAN Peng, LI Jialin, CAO Luodan, et al. Evaluation of China's marine fishery economic efficiency and analysis of its influencing factors based on the super-efficiency SBM model[J]. Marine Science Bulletin, 2022, 41(3): 290 – 301. (in Chinese)
- [36] TIAN P, LIU Y C, LI J L, et al. Mapping coastal aquaculture ponds of China using Sentinel SAR images in 2020 and Google Earth Engine[J]. Remote Sensing, 2022, 14(21):5372.