

朱伟, 马立新, 张平, 等. 基于 GoogLeNet 和无人机图像的水稻秧苗形态识别 [J]. 华南农业大学学报, 2022, 43(3): 99-106.
ZHU Wei, MA Lixin, ZHANG Ping, et al. Morphological recognition of rice seedlings based on GoogLeNet and UAV image[J]. Journal of South China Agricultural University, 2022, 43(3): 99-106.

基于 GoogLeNet 和无人机图像的水稻秧苗形态识别

朱伟¹, 马立新², 张平², 刘德营¹

(1 南京农业大学 工学院, 江苏 南京 210031; 2 江苏省农业机械试验鉴定站, 江苏 南京 210017)

摘要:【目的】针对目前国内评价插秧质量主要以人工观察和随机抽样的现状, 提出一种基于卷积神经网络 GoogLeNet 对水稻秧苗图像进行形态识别的方法。【方法】首先, 利用无人机超低空航拍获取清晰、完整的稻田秧苗图像, 通过裁剪标记制作漂秧、伤秧和合格秧苗数据集; 然后, 基于 GoogLeNet 结构训练数据, 得到最佳网络识别模型; 最后, 对单穴秧苗图像进行分类试验, 并与传统图像分类算法 (SVM、BP 神经网络) 进行对比。【结果】在相同样本的条件下, 基于 GoogLeNet 的秧苗形态识别方法更快、更准确地完成了判断分类, 秧苗形态识别的平均正确率为 91.17%, 平均耗时 0.27 s; 与 SVM 和 BP 神经网络相比, 分类平均精度分别提高了 21 和 13 个百分点, 检测时间分别缩短了 1.09 和 0.58 s。【结论】本研究可为水稻插秧质量评价提供相关支持。

关键词: 水稻; 插秧质量; 秧苗形态; GoogLeNet; 无人机; 图像分类

中图分类号: TP391

文献标志码: A

文章编号: 1001-411X(2022)03-0099-08

Morphological recognition of rice seedlings based on GoogLeNet and UAV image

ZHU Wei¹, MA Lixin², ZHANG Ping², LIU Deying¹

(1 College of Engineering, Nanjing Agricultural University, Nanjing 210031, China;

2 Jiangsu Agricultural Machinery Testing Station, Nanjing 210017, China)

Abstract: 【Objective】In view of the current situation that the quality of transplanting is mainly based on manual observation and random sampling in China, it is proposed to use the convolutional neural network GoogLeNet to recognize the morphology of rice seedlings. 【Method】Firstly, clear and intact images of rice seedlings were obtained by UAV aerial photography at low altitude. Data sets of floating seedlings, damaged seedlings and qualified seedlings were made by cutting and marking. Then, based on the GoogLeNet structure training data, the optimal network recognition model was obtained. Finally, the image classification experiment of seedlings per hole was carried out, and compared with traditional image classification algorithms (SVM, BP neural network). 【Result】Under the condition of using the same samples, the seedling morphology recognition method based on GoogLeNet completed the judgment and classification was faster and more accurately. The average accuracy of seedling morphology recognition was 91.17%, and the average detection time was 0.27 s. Compared with SVM and BP neural network, the average classification accuracy increased by 21 and 13 percentage points respectively, and the detection time was shortened by 1.09 and 0.58 s respectively. 【Conclusion】This study can provide the relevant support for evaluation of rice transplanting quality.

收稿日期: 2021-07-23 网络首发时间: 2022-03-28 12:10:55

网络首发地址: <https://kns.cnki.net/kcms/detail/44.1110.S.20220325.1348.002.html>

作者简介: 朱伟, 硕士研究生, 主要从事农业电气化与自动化研究, E-mail: 15895192169@163.com; 通信作者:

刘德营, 副教授, 博士, 主要从事模式识别与自动控制研究, E-mail: dylu@njau.edu.cn

基金项目: 江苏省农机新装备新技术研发与推广项目 (NJ2019-25)

Key words: Rice; Transplanting quality; Seedling morphology; GoogLeNet; UAV; Image classification

水稻作为我国主要的粮食作物之一，常年种植面积超过 $3\times 10^7\text{ hm}^2$ ，产量保持在 $2\times 10^8\text{ t}$ 以上。在东北、长江中下游、东南沿海三大产区，地势平坦，机械化水平高，各类型插秧机的使用大幅度提高了农业生产力^[1]。但由于稻田整地不平、沉淀时间不合理、秸秆残渣未清理和机手操作不当等问题，极易发生漏插、漂秧、伤秧等情况，造成一定的经济损失。因此，准确快速评价插秧机作业质量，是后续安排补秧计划、减小经济损失的必要前提^[2]。现行的插秧机质量评价方法仍需要工作人员克服室外高温、田地泥泞等困难，采用抽样调查法，通过目测主观判断秧苗形态，统计漏插率、漂秧率和伤秧率等指标^[3]。该方法存在环境差、任务重、客观性不足和效率低下等问题，因此实现水稻秧苗形态的快速精准识别，对于评价插秧质量具有重要意义。

近年来，随着无人机、图像处理和深度学习等技术手段在农业领域的应用不断深入，在农作物的长势判断^[4]、倒伏面积计算^[5]、病虫害诊断^[6]和产量预测^[7]等方面取得显著成效。无人机具有速度快、地形限制少、地面分辨率高等优点，结合深度学习在图像处理中的鲁棒性强、泛化能力好的特点，十分适合处理田间背景下的复杂问题^[8-11]。陶惠林等^[12]利用无人机获得冬小麦高光谱数据，通过构建光谱指数，分析其与冬小麦的长势监测指标的相关性，利用多元线性回归、偏最小二乘和随机森林 3 种机器学习方法建立冬小麦各生育期反演模型，得到冬小麦长势监测图。赵静等^[13]基于无人机 RGB 图像提取出数字表面模型，通过计算过绿指数，利用最大似然法和随机森林法监督分类提取小麦倒伏面积，试

验表明融合图像特征取得了较好的预测结果。

在目前深度学习快速发展的基础上，图像识别分类研究正大步前进^[14-17]。林相泽等^[18]基于迁移学习和 Mask R-CNN 提出了一种稻飞虱图像分类方法，通过自主研发野外昆虫图像采集装置，获取大量稻飞虱和非稻飞虱图像，试验结果表明，该算法平均识别精度达到 0.92。陈进等^[19]基于改进 U-Net 网络，通过增加网络深度，提高网络泛化能力，建立水稻籽粒图像分割模型，能较好地分割谷物籽粒、枝梗和茎秆，为水稻联合收割机含杂率实时监测提供算法支持。杨万里等^[20]使用 SegNet 和 Faster R-CNN 对盆栽水稻稻穗进行分割和计数，结合穗部、颜色、形态、纹理等表型特征构建盆栽水稻稻穗质量预测模型。

本研究提出了一种基于卷积神经网络 GoogLeNet 的水稻秧苗形态分类识别方法。该方法利用无人机超低空对稻田拍照，通过对秧苗形态判断分类，为快速、准确评价插秧机作业质量提供支持和帮助。

1 材料与方法

1.1 研究区域概述

研究区域主要分布于江淮一带，水稻栽插期通常安排在“三夏”期间，一般是 5 月下旬至六月上旬。该区域属于北亚热带南部湿润性地区，气候温和，四季分明，雨水充沛，年平均气温在 15~20℃，拥有种植水稻的良好环境。研究团队为获取不同时空条件下的秧苗样本图片，多次前往各地农场、稻田，开展前期调研、数据采集、下田试验等工作，试验信息如表 1 所示。

表 1 研究区域的试验信息

Table 1 Test information of research areas

试验地点 Test location	试验时间 Test time	插秧机 Rice transplanter	型号 Model	水稻品种 Rice variety
南京市溧水区 Lishui of Nanjing	2020-05	星月神 Seeyes	2ZG-6S	宁3828 Ning 3828
张家港市南丰镇 Nanfeng of Zhangjiagang	2020-06	久保田 Kubota	2ZGQ-6D5	南粳505 Nanjing 505
常州市新北区 Xinbei of Changzhou	2020-06	丰疆 Fengjiang	2ZG-4A	软玉2号 Ruanyu 2
靖江市东兴镇 Dongxing of Jingjiang	2020-07	富尔代 Fuerdai	2ZG-8A	南粳5055 Nanjing 5055
丹阳市章村 Zhangcun of Danyang	2021-06	沃得 World	2ZGF-8E	淮稻5号 Huaidao 5

1.2 数据获取

数据采集由大疆精灵 Phantom 4 RTK(Real-time kinematic) 完成，机身内部携带 1 张 64 GB 内存卡，负责存储航拍图片。无人机续航时间为 20~30 min，工作环境温度为 0~40℃，影像传感器大小为 13.2 mm×8.8 mm，有效像素为 2 000 万，镜

头焦距为 8.8 mm，照片分辨率为 5 472×3 648，每个像素代表的实际距离为 2.4 μm。

结合上述数据，通过公式 (1)，得到无人机在不同高度下的空间分辨率 (Ground sample distance, GSD)，以及镜头覆盖的有效距离 (表 2)。

表 2 无人机分辨率及有效距离
Table 2 UAV resolution and effective range

试验序号 Test batch	飞行相对高度/m Relative flight height	分辨率/mm Resolution	图片有效距离(长×宽)/m The effective distance of picture (Length×Width)
1	2	0.55	3.0×2
2	3	0.82	4.5×3
3	5	1.40	7.5×5
4	10	2.80	15.0×10

$$\text{GSD} = \frac{Ha}{f}, \tag{1}$$

式中:GSD 表示空间分辨率,即 1 个像素代表的实际距离大小; H 表示相对航高; f 为镜头焦距; a 为像元尺寸。以江苏地区农艺要求为例,相邻秧苗株距为 120~170 mm、行距为 270~330 mm,考虑到对于秧苗漏插率的检测,无人机飞行相对高度不宜超过 5 m。

无人机航拍时间为 2020 年 6 月 10 日 15:00—16:00,天气晴朗,无风无云,温度 33 ℃。航拍路线规划是在 IQOO Neo3 安卓设备上运行 DJI Polit APP 设计完成,航线规划选择航点飞行,高度为 3 m,速度为 1 m/s,间隔 3 m 添加航点,并设置航点拍照动作,航拍路线如图 1 所示。无人机执行飞行任务期间,云台保持垂直向下 90°,完成规定动作,待飞行任务结束,自动返航,更换飞行方向,重复飞行若干次。



图 1 无人机航拍路线
Fig. 1 UAV aerial photography route

登录 RTK 网络账号,无人机在田间整体定位精度达到 0.1 m,单次飞行时间 5 min 左右。任务结束后,取下机身内存卡,在笔记本电脑上保存,共得到试验田航拍图片 1 120 张,格式为 JPG,单张图片

大小为 10 MB 左右。

1.3 数据处理

1.3.1 图像预处理 由于田间背景复杂,需要对图片进行灰度化、阈值分割、形态学滤波、连通区域统计、单穴秧苗图片保存等操作。如图 2 所示,通过灰度化处理去除原始 RGB 图像包含的冗余信息,减少图像处理过程的数据维度;利用秧苗的绿色与泥田的土褐色差异,通过最大类间方差法 (Otsu) 来实现目标秧苗、泥田背景的分离;剔除图片中存在的孤立的、微小的噪声点;提取各连通区域的质心坐标,依据坐标大小进行排序,得到秧苗行列关系;最终按照秧苗编号进行单穴秧苗图像裁剪命名保存。通过预处理过程能将单张连续多穴秧苗图像裁剪为多张单穴秧苗图像。

通过 Otsu 确定分割阈值,可以较好地解决水面反射、光照强度变化等问题,达到期望的分割效果,实现秧苗行列关系判断与编号。按照每列次序,通过公式 (2) 计算相邻秧苗质心距离是否在正常株距范围内,判别是否发生漏插现象。设正常情况下秧苗株距像素距离为 d ,当秧苗间像素距离 D 大于 $1.5 d$,即可判断此处发生漏插,经过多次图像试验,其正确率可达到 95.6% 以上。

$$D = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}, \tag{2}$$

式中: D 表示相邻秧苗的质心距离; (x_1, y_1) 和 (x_2, y_2) 分别为相邻秧苗的质心坐标。

依据中华人民共和国国家标准 GB/T 6243—2017 水稻插秧机试验方法^[21]、农业机械推广鉴定大纲 DG/T 008—2019 水稻插秧机^[22],结合实际判断




图 2 水稻秧苗图像预处理流程
Fig. 2 Pretreatment process of rice seedling image

经验,做出下列定义:

漏插:插秧机执行栽插动作后,无水稻秧苗的插穴;

漂秧:插秧机执行栽插动作后,秧根未栽入泥土内,而漂浮于稻田中的秧苗;

伤秧:插秧机执行栽插动作后,秧苗茎部有折伤、切断等现象的秧苗;

合格:在插穴内,未发生漂浮、折伤、切断等现象的秧苗属于合格。

以质心坐标为裁剪图像中心,向四周扩展,裁剪出任意大小的单穴水稻秧苗图像,通过多次比较,发现 224 像素×224 像素图像处理效果最好,可以做到对单穴秧苗的完全容纳,且不会过多涉及其他穴秧苗,部分结果如图 3 所示。无人机在 3 m 高度下的分辨率为每像素 0.82 mm,112 像素的距离转换为实际距离大约为 92 mm,而相邻株距为 120~170 mm,可见正常情况下,图片内最少出现 1 穴完整秧苗,且不会同时出现多穴完整秧苗。考虑到田内秧苗品种、培育环境相同,自身成长特性相似,故选择面积最大的秧苗进行识别。该尺寸仅对应无人机飞行高度为 3 m 的裁剪要求,如果飞行高度变化,裁剪尺寸也应发生变化。

在试验中,首先对无人机镜头进行手动对焦,并调整光圈大小、曝光模式以确保无人机拍照清晰;其次通过对试验田开展整地工作,减少秧苗栽

a: 漂秧
a: Floating seedling



b: 伤秧
b: Damaged seedling



c: 合格秧苗
c: Qualified seedling



图 3 水稻秧苗样本图像

Fig. 3 The sample images of rice seedlings

插入土的阻力和秸秆杂物的影响;最后调节插秧机取样量,选择均匀度合格的秧盘,均匀、整齐地完成插秧作业。通过采取上述措施,可有效减少无人机航拍图像中模糊、黏连现象的发生。将所得单穴秧苗图像分为:漂秧、伤秧和合格秧苗 3 类,分类完成后,分别获得 5 247 张漂秧、5 713 张伤秧和 89 425 张合格图像,最终分别选取 3 类秧苗图像 5 000、5 000 和 80 000 张,共计 90 000 张单穴秧苗图像作为试验数据。

1.3.2 算法设计 GoogLeNet 主体结构由输入层、5 组卷积模块和输出层组成,具体包括了 22 层参数层和 5 层池化层。输入层是 224×224×3 的图像,第 1 组、第 2 组卷积模块包括卷积层、最大池化层,第 3 组、第 4 组和第 5 组卷积模块主要由 Inception Module 结构和最大池化层组成,输出层由平均池化层、Dropout、全连接层组成。网络结构图如图 4 所示。




图 4 GoogLeNet 结构
Fig. 4 GoogLeNet structure

Inception module 结构有 4 条并行路径,前 3 条路径分别使用 1×1、3×3 和 5×5 卷积核提取不同图像感受野特征信息,第 4 条路径使用 3×3 的池化核来选取特征点、防止过度拟合,并添加 1×1 卷积。为降低模型复杂度、减少数据维度,在第 2 条、第 3 条路径中加入 1×1 卷积操作。Inception module 结构图如图 5 所示。

对于输入图像为 224×224×3 时,GoogLeNet 各层参数如表 3 所示。

1.3.3 对比试验算法设计 为体现 GoogLeNet 卷积神经网络在水稻秧苗形态识别的优势,选取传统的支持向量机 (Support vector machine, SVM) 和




图 5 Inception module 结构
Fig. 5 Inception module structure

表 3 GoogLeNet 结构参数¹⁾
Table 3 The structural parameters of GoogLeNet

结构 Structure	核尺寸 Patch size	步长 Stride	填充数 Padding	C1×1	#3×3	C3×3	#5×5	C5×5	P3×3	数据维度 Data dimension
输入 Input										224×224×3
卷积层1 Convolutional layer 1	7×7	2	3							112×112×64
池化层1 Pooling layer 1	3×3	2	1							56×56×64
卷积层2a Convolutional layer 2a	1×1	1	0							56×56×64
卷积层2b Convolutional layer 2b	3×3	1	1							56×56×192
池化层2 Pooling layer 2	3×3	2	1							28×28×192
Inception 3a				64	96	128	16	32	32	28×28×256
Inception 3b				128	128	192	32	96	64	28×28×480
池化层3 Pooling layer 3	3×3	2	1							14×14×480
Inception 4a				192	96	208	16	48	64	14×14×512
Inception 4b				160	112	224	24	64	64	14×14×512
Inception 4c				128	128	256	24	64	64	14×14×512
Inception 4d				112	144	288	32	64	64	14×14×528
Inception 4e				256	160	320	32	128	128	14×14×832
池化层4 Pooling layer 4	3×3	2	1							7×7×832
Inception 5a				256	160	320	32	128	128	7×7×832
Inception 5b				384	192	384	48	128	128	7×7×1 024
池化层 Pooling layer	7×7	1	0							1×1×1 024
Dropout										1×1×1 024
FC layer										1×1×3
输出 Output										1×1×3

1) “C1×1” “C3×3” 和 “C5×5” 表示在Inception module结构中相对应的卷积核数量, “#3×3” 和 “#5×5” 表示在对应卷积之前, 使用的1×1的卷积核数量, “P3×3” 表示经过最大池化后, 使用的1×1的卷积核数量

1) “C1×1”, “C3×3” and “C5×5” indicate the corresponding number of convolution kernels in the inception module structure, and “#3×3” and “#5×5” indicate the number of 1×1 convolution kernels used before the corresponding convolution, and “P3×3” indicates the number of 1×1 convolution kernels used after max pooling

BP(Back propagation) 神经网络作为对比试验方法进行分类准确性的比较。如图 6 所示,通过对单穴秧苗图像的 Otsu 阈值分割、形态学滤波、边界提取、参数计算等处理,得到相关特征值。




图 6 水稻秧苗图像的特征提取
Fig. 6 Feature extraction of rice seedling image

考虑到目标秧苗与稻田背景的颜色差异,其分别占据不同灰度范围,同时阈值分割计算简单、性能稳定,通过 Otsu、双峰法、迭代法的试验比较,最终选用 Otsu 确定阈值作为分割依据,判定图像中像素点灰度值小于 k 的属于泥田背景,像素点灰度值大于 k 的属于秧苗,通过求解秧苗和泥田背景之间方差最大值,此时 k 值即为最佳阈值,能达到最好的分割效果。

在进行形态学滤波处理时,建立轮廓层次,区分外部、内部 2 种轮廓,使用开闭运算,通过设置阈值,针对小于阈值 s 的孔洞进行填充,避免因填充造成的轮廓变化,影响到特征值的大小,防止对秧苗形态误判。

选择秧苗的轮廓信息作为描述秧苗形态的特征参数,通过有效筛选,确定狭长度、矩形度、紧凑度、HU 不变矩 4 组特征值。

狭长度(L)为秧苗轮廓外接矩形的狭长程度,反映秧苗自身有效尺寸。

$$L = \text{Length}/\text{Width},$$

(3)

式中:Length、Width 分别为最小面积矩形的长、宽。

矩形度(R)为秧苗对其外接矩形的填充程度,反映每穴秧苗的分叉情况。

$$R = S_{\text{Area}}/S_{\text{MABR}},$$

(4)

式中: S_{Area} 为秧苗填充区域的像素和, S_{MABR} 为最小外接矩形的面积。

紧凑度(C)为秧苗边界的紧凑程度,反映秧苗边缘轮廓的粗糙情况。

$$C = \frac{4\pi S_{\text{Area}}}{\text{Perimeter}^2},$$

(5)

式中:Perimeter 为秧苗周长,即秧苗边界的像素点和。

HU 不变矩包括 7 组特征量 [$M_1, M_2, M_3, M_4, M_5, M_6, M_7$],其具有平移、旋转和尺度不变性,可以用来描述秧苗图像的全局特征。考虑到二阶矩稳定性更好,误差更小,故选择 M_1, M_2 作为 HU 不变矩的代表特征。

$$\begin{cases} M_1 = \eta_{20} + \eta_{02} \\ M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \end{cases},$$

(6)

式中: $\eta_{20}, \eta_{02}, \eta_{11}$ 均代表图像不同次幂的二阶归一化中心矩。

通过对大量秧苗图像处理,计算有关特征参数均值,结果如表 4 所示。

表 4 水稻秧苗轮廓特征参数信息
Table 4 Parameter information of rice seedling outline feature

图像类别 Image type	狭长度 Aspect ratio	矩形度 Rectangularity	紧凑度 Compactness	M_1	M_2
漂秧 Floating seedling	1.837	0.445	0.150	1.181	3.492
伤秧 Damaged seedling	1.440	0.457	0.119	1.361	4.735
合格秧苗 Qualified seedling	2.554	0.477	0.134	1.075	2.626

选择表格内的特征参数,作为 SVM 和 BP 神经网络的输入特征向量矩阵, SVM 基于径向基核函数(Radial basis function),通过 Class-weight 对不同类别设置不同惩罚参数($C_1 \sim C_3$, C_1 为 16、 C_2 为 16、 C_3 为 1),惩罚系数一般为样本数据各类别比例倒数,使用网格搜索法确定 rbf_sigma 为 0.3, BP 网络包括输入层、单层隐含层和输出层,输入层神经元节点数取决于输入的特征向量维数,输出层节点

数对应输出的识别种类个数, 隐含层节点数一般由经验公式 (7) 确定, 故本 BP 神经网络中输入层节点数为 5, 隐含层节点数为 4, 输出层节点数为 3。隐含层神经元的激活函数为 Logsig 函数 (线性函数), 输出层激活函数为 Purelin 函数 (非线性函数), 训练函数为 Traingdx 函数 (梯度下降自适应学习率训练函数), 学习函数为 Learngdm 函数 (梯度下降动量学习函数), 训练回合数为 20 次, 训练目标为 0.1, 学习速率为 0.05, 继而得到传统图像处理方法对秧苗形态识别正确率。

$$G = \sqrt{m+n} + b,$$

(7)

式中: G 表示隐含层节点数; m 表示输入层节点个数; n 表示输出节点个数; b 为 1~10 的调节常数。

2 试验与结果分析

2.1 试验环境及参数设置

试验涉及到的所有模型均在以 Win10 专业版为操作系统、CPU 为 Xeon E-2176M、显卡为 NVIDIA Quadro P3200 和 Intel HD630、软件运行环境为 Matlab2020b 上的戴尔工作站上完成。

将裁剪、分类、标记完成的 90 000 张单穴水稻

图像, 按照 7:2:1 的比例随机分成训练集、验证集、测试集。经多次试验后依据准确率最优原则, 初始学习率设置为 0.000 1, 动量设置为 0.9, 最大训练回合数为 10, 批尺寸为 32, 迭代次数设定为 2 000 次, 优化函数选择 Sgdm, 通过引用代价向量, 首先依据样本比例指定代价向量初值, 结合训练过程中得到的混淆矩阵对代价向量进行调整, 参考错分比例增减漂秧、伤秧样本的惩罚向量权值, 调整模型在小样本的注意力, 缓解样本不平衡带来的影响。

2.2 结果与分析

在水稻秧苗图像分类试验中, 使用计时器, 对遍历测试集文件夹内水稻单穴图像分类试验过程进行计时, 通过公式 (8) 分别计算 3 种方法分类平均时长, 对比 GoogLeNet、SVM 和 BP 神经网络的分类结果, 如表 5 所示。

$$T = \frac{t}{TP+FP},$$

(8)

式中: T 表示平均识别时间, 即包括输入水稻图像、图像处理、特征值计算和输出分类结果等完整过程的耗时均值; t 表示分类试验时长; TP 表示秧苗图像正确分类的数量; FP 表示秧苗图像错误分类的数量。

表 5 3 种算法的秧苗形态识别试验结果

Table 5 The experimental results of three algorithms for recognition of seedling morphology

算法 Algorithm	识别正确率/% Recognition accuracy			平均识别时间/s
	漂秧 Floating seedling	伤秧 Damaged seedling	合格秧苗 Qualified seedling	Average recognition time
GoogLeNet	91.6	85.5	96.4	0.27
SVM	69.6	64.2	76.3	1.36
BP神经网络 BP neural network	76.9	72.7	86.9	0.85

由表 5 可见, 基于卷积神经网络的 GoogLeNet 模型, 对于秧苗形态的平均识别正确率达到 91% 以上, 单穴图像检测时间仅为 0.27 s。而传统的分类方法, SVM 平均识别正确率仅在 70% 左右, BP 神经网络平均识别正确率在 78% 左右, 分别下降了 21、13 个百分点, 检测速率也分别增加到 1.36 和 0.85 s。通过深度学习能有效减少对于图像的预处理操作, 避免人工提取特征时间, 有效提高检测效率。

经过归纳总结发现, 秧苗茎叶折伤的程度有轻有重, 其角度、位置、数量都会影响伤秧的正确识别。伤秧的程度较轻, 如出现小角度、前端折伤, 秧苗与正常秧苗子叶弯曲相似, 此时伤秧形态和合格秧苗差异较小, 容易误判; 伤秧的程度过重, 如出现大幅度、大面积的倒伏, 此时伤秧形态与漂秧差异

较小, 也会发生误判。这两类情况的出现, 造成了伤秧识别率在秧苗形态分类准确率中偏低。

3 结论

- 1) 通过规划航线, 无人机超低空航拍, 可以快速、准确地取田间秧苗图片, 及时评价插秧质量, 对后续补秧计划提供支持。
- 2) 基于卷积神经网络 GoogLeNet 进行秧苗形态判断, 可以实现漂秧、伤秧、合格秧苗形态的平均识别正确率为 91.17%。
- 3) 基于卷积神经网络 GoogLeNet 进行秧苗形态判断, 减少了传统图像识别方法中的预处理和特征提取操作, 单穴水稻图像形态判断可以在 0.27 s 内完成, 提高了算法的响应速度和泛化能力。

4) 算法的局限性: 目前仅对部分秧苗种类数据做出判断识别, 后续可以通过增加其他品牌、育秧方式、培育周期等秧苗数据, 丰富不同秧苗形态模型结构。

参考文献:

[1] 李鸣钰, 高西宁, 潘婕, 等. 未来升温 1.5 ℃ 与 2.0 ℃ 背景下中国水稻产量可能变化趋势[J]. 自然资源学报, 2021, 36(3): 567-581.

[2] 李忠华, 刘欣. 影响高速插秧机作业质量的因素分析[J]. 现代化农业, 2014(4): 56-57.

[3] 辛明金, 邬立岩, 宋玉秋, 等. VP6 型水稻插秧机作业质量试验研究[J]. 中国农机化学报, 2016, 37(4): 19-23.

[4] 潘海珠, 陈仲新. 无人机高光谱遥感数据在冬小麦叶面积指数反演中的应用[J]. 中国农业资源与区划, 2018, 39(3): 32-37.

[5] 胡琪, 武红旗, 轩俊伟, 等. 基于无人机 DSM 的小麦倒伏信息提取[J]. 安徽农业科学, 2020, 48(16): 227-231.

[6] 赵春霞. 基于 ResNet18 的图像分类在农作物病虫害诊断中的应用[J]. 农业与技术, 2021, 41(19): 10-13.

[7] 程千, 徐洪刚, 曹引波, 等. 基于无人机多时相植被指数的冬小麦产量估测[J]. 农业机械学报, 2021, 52(03): 160-167.

[8] 王林惠, 甘海明, 岳学军, 等. 基于图像识别的无人机精准喷雾控制系统研究[J]. 华南农业大学学报, 2016, 37(6): 23-30.

[9] ASHOURLOO D, AGHIGHI H, MATKAN A A, et al. An investigation into machinelearning regression techniques for the leaf rust disease detection using hyperspectral measurement[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(9): 4344-4351.

[10] HAQ M A, RAHAMAN G, BARAL P, et al. Deep learning based supervised image classification using UAV images for forest areas classification[J]. Journal of the Indian Society of Remote Sensing, 2020, 49(3): 601-606.

[11] 王丽君, 淮永建, 彭月橙. 基于叶片图像多特征融合的

观叶植物种类识别[J]. 北京林业大学学报, 2015, 37(1): 55-61.

[12] 陶惠林, 徐良骥, 冯海宽, 等. 基于无人机高光谱遥感数据的冬小麦产量估算[J]. 农业机械学报, 2020, 51(7): 146-155.

[13] 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.

[14] 刘嘉政, 王雪峰, 王甜. 基于深度学习的 5 种树皮纹理图像识别研究[J]. 北京林业大学学报, 2019, 41(4): 146-154.

[15] ZHANG Q, CHEN MESJ, LI B. A visual navigation algorithm for paddy field weeding robot based on image understanding[J]. Computers and Electronics in Agriculture, 2017, 143: 66-78.

[16] 李静, 陈桂芬, 安宇. 基于优化卷积神经网络的玉米螟虫害图像识别[J]. 华南农业大学学报, 2020, 41(3): 110-116.

[17] WEI D, HUANG Y B, ZHAO C J, et al. Identification of seedling cabbages and weeds using hyperspectral imaging[J]. International Journal of Agricultural and Biological Engineering, 2015, 8(5): 65-72.

[18] 林相泽, 朱赛华, 张俊媛, 等. 基于迁移学习和 Mask R-CNN 的稻飞虱图像分类方法[J]. 农业机械学报, 2019, 50(7): 201-207.

[19] 陈进, 韩梦娜, 练毅, 等. 基于 U-Net 模型的含杂水稻籽粒图像分割[J]. 农业工程学报, 2020, 36(10): 174-180.

[20] 杨万里, 段凌凤, 杨万能. 基于深度学习的水稻表型特征提取和穗质量预测研究[J]. 华中农业大学学报, 2021, 40(1): 227-235.

[21] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 水稻插秧机试验方法: GB/T 6243—2017[S]. 北京: 中国标准出版社, 2017.

[22] 中华人民共和国农业农村部. 水稻插秧机: DG/T 008—2019[S]. 北京: 中国农业出版社, 2019.

【责任编辑 庄 延】