

基于深度学习的水稻表型特征提取和穗质量预测研究

杨万里¹,段凌凤¹,杨万能²

1.华中农业大学工学院,武汉 430070; 2.华中农业大学作物遗传改良国家重点实验室,武汉 430070

摘要 水稻产量与水稻穗数和穗质量密切相关,精确预测水稻产量可以加快育种速度。以盆栽水稻为研究对象,首先利用可见光图像结合图像处理技术进行特征提取,获取整株水稻的51个表型特征。结合深度学习,运用Faster R-CNN卷积神经网络训练模型对水稻穗数进行检测,同时使用SegNet网络框架训练得到的模型对水稻稻穗进行分割,得到水稻穗部的二值图像,结合图像处理技术提取穗部的33个表型特征数据。提取了颜色、形态、纹理共85个表型参数,对所有85个数据进行归一化处理,将归一化的85个表型数据与稻穗鲜质量、干质量进行逐步线性回归,挑选相关性高的特征数据。分别使用穗数和33个特征穗部、51个特征整株、所有85个特征中相关性高的特征数据构建盆栽水稻稻穗鲜质量、干质量的预测模型,最后根据模型的决定系数 R^2 、平均相对误差(MAPE)和相对误差绝对值的标准差(SAPE)挑选最优预测模型。预测结果表明穗部特征预测效果最好,其中效果最好的模型鲜质量、干质量预测值与真实值的决定系数 R^2 分别达到 0.787 ± 0.051 和 0.840 ± 0.054 。

关键词 水稻产量预测;植物表型组学;深度学习;图像处理;水稻穗质量预测;SegNet;Faster R-CNN

中图分类号 S 51 **文献标识码** A **文章编号** 1000-2421(2021)01-0227-09

我国是世界上最大的稻米消费国^[1],为提高我国稻米的自给率,水稻单产的持续增加一直是育种和栽培研究的重要目标^[2-3],精准的产量预测可以加快育种的速度并为粮食的种植提供指导^[4]。水稻穗部的表型特征、穗数、稻穗的投影面积等与产量有着极为密切的关系^[5],而且穗部表型特征的识别在水稻的病虫害检测、营养分析、抽穗期的检测具有重要的指导意义^[6-7]。因此,水稻稻穗准确识别和分割是水稻产量预测和表型研究的关键。

随着近年水稻功能基因组学的发展,准确快速获取大规模群体表型数据对水稻的育种和改良具有重要意义^[8-9],而传统的表型数据获取往往需要进行大量的人工实验且费时费力,自动化快速的表型提取方法可以突破传统水稻表型技术的瓶颈,加快水稻育种速度。现有研究通过图像颜色特征分割果穗^[10-12],但是这种方法分割的准确度不高且容易产生噪声,不能满足复杂环境下稻穗分割的要求。随着深度学习的快速发展,其在作物果穗的识别和分

割上得到广泛应用。Ghosal等^[13]提出一种基于卷积神经网络的高粱穗的计数方法;Xiong等^[14]提出一种基于卷积神经网络的Panicle-SEG网络进行水稻稻穗分割,针对复杂环境具有很好的适应性;Sadeghi-Tehran等^[15]提出一种基于简单线性迭代聚类和深度卷积神经网络的田间小麦穗自动技术的系统DeepCount;段凌凤等^[16]对多个大田稻穗分割模型进行比较,得出基于SegNet的卷积神经网络分割效果与耗时的性价比最高。部分研究基于土壤性质^[17]、气温、降水^[18]等因素并结合遥感技术预测大田水稻产量,但该方法无法预测单株水稻产量。由于水稻产量预测可以更好地为生长发育、遗传育种等研究提供数据支持,因此,精确提取水稻整株和穗部的表型特征数据及产量预测,是未来水稻育种和表型组学研究的重要内容。

本研究使用卷积神经网络SegNet^[19]和Faster R-CNN^[20]对盆栽水稻稻穗分别进行分割和穗数计数,基于分割后稻穗图像,提取穗部图像的表型特征,

收稿日期:2020-06-15

基金项目:国家自然科学基金面上项目(31770397);国家自然科学基金青年项目(31701317)

杨万里,E-mail: yangwanli@webmail.hzau.edu.cn

通信作者:杨万能,E-mail: ywn@mail.hzau.edu.cn

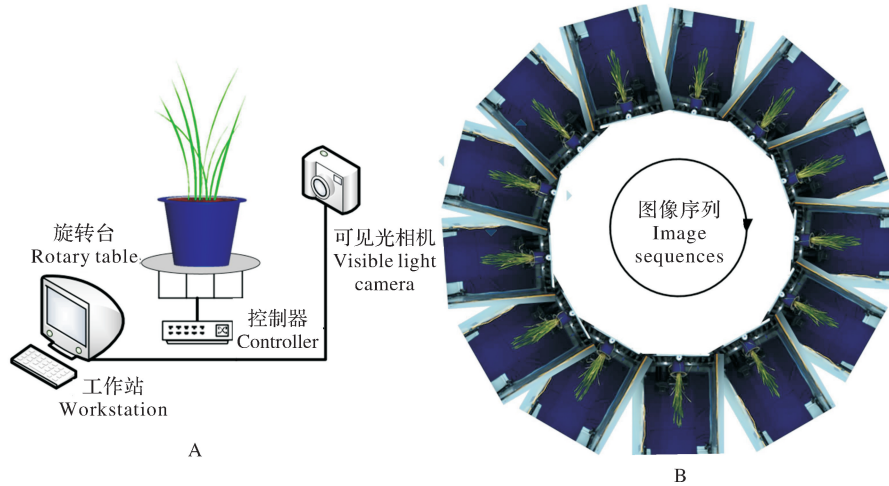
结合整株水稻的颜色纹理等表型特征,构建盆栽水稻稻穗鲜质量、干质量预测模型,旨在为水稻穗质量预测提供新的思路和方法,进一步提高水稻穗质量预测的准确性。

1 材料与方 法

1.1 图像采集系统

图像采集系统如图 1A 所示,采用自动化工业

流水线表型检测平台获取图像^[8],盆栽水稻通过送检线运送到旋转台,按照等角度旋转 13 次共 360°,位于水稻侧面的可见光工业相机(AVT Stingray F-504)在每次旋转的间隙拍摄,每盆水稻共采集 13 张侧视 png 格式的 RGB 图片,图像的分辨率为 2 452 像素×2 056 像素,自动采集图像并储存至工作站,检测完毕的水稻通过出检线送出。



A: 图像采集系统,控制器控制旋转台旋转,可见光相机拍的照片存入工作站 Refers to the image acquisition system, the controller controls the rotation of the rotary table, and the photos taken by the visible light camera are stored in the workstation; B: 采集的图像,随着旋转台旋转相机拍摄的 13 张不同角度的 RGB 图片 Refers to the collected images, 13 RGB pictures with different angles taken by the rotating camera of the rotary table.

图 1 成像系统及采集图像

Fig.1 Imaging system and acquired image

1.2 试验材料与数据

本试验的水稻品种为华粳 295,试验基地位于华中农业大学盆栽场,水稻种植于塑料盆中。盆钵规格为下部直径 16 cm、上部直径 19.5 cm、盆高 19 cm,每盆均装入 5.0 kg 风干土壤,添加适量水将水稻幼苗种植其中,共 83 盆,试验期间适时追肥、人工除草和病虫害防治。在水稻蜡熟期采集了 1 079 张 RGB 图像,图像获取后,人工统计每株水稻的穗数,并将穗部剪下称质量,记作穗鲜质量(FW),烘干后再次称质量,记作穗干质量(DW)。Faster R-CNN 模型训练数据集材料,共 322 盆水稻,生长环境与华粳 295 相同,共采集了 4 186 张 RGB 图片。

1.3 基于 Faster R-CNN 的穗数计数模型

使用 Faster R-CNN 目标检测网络对稻穗进行计数^[20]。Faster R-CNN 网络主要包括:特征提取网络 CNN、区域建议网络 RPN、特征金字塔网络 FPN 以及目标区域池化 ROI pooling 层、分类和回

归层。特征提取网络 CNN 采用 ResNet101 残差网络结构,其中包括卷积层、激活层和池化层,其作用是在训练过程中对输入 CNN 网络的图片进行特征提取并输出特征图;FPN 结构将不同卷积层的特征图生成一个特征图金字塔,将特征图金字塔输入区域建议网络 RPN 得到候选区域;目标区域池化层将每个候选区域映射到特征图上,然后对每个区域进行最大池化得到区域建议特征图;分类和回归层根据输入的区域建议特征图输出候选区域的类别和检测框。

训练数据集使用 322 盆水稻拍摄的 4 186 张 2 452 像素×2 056 像素的盆栽水稻图片,每张图片中的水稻均抽穗。首先利用 labellmg 软件对目标稻穗进行标注,生成 xml 格式的文件,再转化为 json 格式的文件,4 186 张图片和 json 文件按照 3 : 1 的比例随机划分为训练集和验证集,随后进行模型训练,模型训练采用的是 PyTorch 框架,使用 GPU 训

练,参数设置学习率为 0.01,学习的动量因子为 0.9,权重衰减 weight_decay 为 0.000 1,epoch 为 1 000,训练后得到稻穗检测的模型。

1.4 基于 SegNet 的稻穗分割模型

稻穗分割使用的是 SegNet 网络,SegNet 是由剑桥大学研发的开源图像分割项目^[19],网络结构如图 2 所示。在 FCN 网络结构上,搭建编码解码网

络结构,从而实现从端到端的逐像素图像分割,图 2 中绿色部分为卷积层+BN 层+激活层,黄色为池化层,红色为上采样层,蓝色为分类层。由于本研究只需要分割出稻穗,属于二分类问题,只有前景点和背景点两个类别,所以要把 SegNet 最后 1 个输出层通道数改为 2,得到本研究的网络结构。

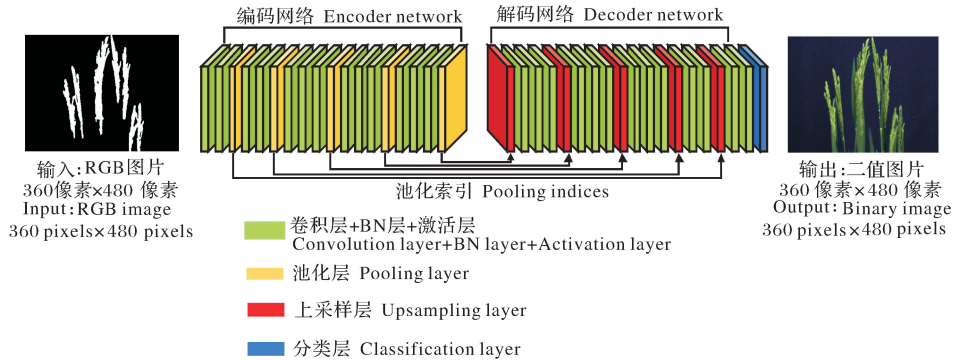


Fig.2 Schematic diagram of SegNet network structure

网络训练。第一步,训练数据集准备。使用 Photoshop 对 70 张 2 452 像素×2 056 像素(高×宽)的盆栽水稻图片进行人工标注,将背景点标注为 0,稻穗像素点标注为 1。第二步,数据扩增。由于盆栽图片中稻穗部分前景点的像素占比很小,因此需扩大前景点样本量以保持样本平衡,首先进行图片裁剪,有稻穗的区域,使用 360 像素×480 像素(高×宽)和 480 像素×360 像素(高×宽)的框在该区域上、下和左、右共 4 个方向采用滑动窗口的形式裁剪出子图,只有背景的区域随机框出 20% 并裁减;对所有稻穗区域的子图进行旋转镜像实现数据扩增,得到 3 960 张 360 像素×480 像素(高×宽)的子图。第三步,数据集划分。将 3 960 张子图按照 83:17 的比例随机划分训练集和验证集,得到 3 304 张训练集样本和 656 张验证集样本,标签图采用同样的方式处理使之与子图一一对应。

由于训练样本较少,在模型训练的过程中很容易导致过拟合,所以本研究使用网络结构相似的大田稻穗分割模型 PanicleNet 进行网络初始化^[16],以提高模型的分割精度、缩短训练时间。基于 caffe 平台随机梯度下降法训练,学习率设置为 0.001,epoch 为 100 即所有样本训练 100 次,训练集的 batchsize 为 4,验证集的 batchsize 为 2,学习的动量因子为 0.9。

1.5 图像分割、处理及特征提取

1) 整株特征提取。图 3 左侧为整体特征提取部

分,主要处理过程如下:①预处理。对 ROI 区域进行裁剪。②二值化。将彩色 RGB 图进行阈值分割,公式为: $2G-R-B \geq N$ (其中, G 为像素点的绿色分量, R 为红色分量, B 为蓝色分量), $N=20$ 为阈值,得到水稻植株的二值图,将整株分割的二值图与 RGB 图片进行掩膜得到整株分割图像。③提取绿色部分分量。使用裁剪过的植株 RGB 图像,利用绿色和红色分量,如果像素点绿色分量大于阈值 $Eg_{threshold}$ 并且红色分量小于阈值 $ER_{threshold}$ 则判定为绿色部分,与原图掩膜得到绿色分割效果图, $Eg_{threshold}=0.3$, $ER_{threshold}=0.15$ 。④将预处理的 RGB 图转化为 HSI 图像,然后提取 I 分量得到的灰度图像与二值图掩膜,得到最终的灰度图。⑤将预处理的 RGB 图转化为 HSL 图像,然后提取 G 分量的梯度图。

基于以上的图像处理过程可以提取 51 个整株水稻特征。高(H):植株形态参数,植株外接矩形的高度;宽(W):植株形态参数,植株外接矩形的宽度;周长/面积(PAR):植株形态参数,植株的周长与植株投影面积的比值;总投影面积(TPA):植株形态参数,植株所占的像素点个数;面积/外接矩形的面积(TBR):植株形态参数,总投影面积(TPA)与外接矩形面积的比值;高/宽(HWR):植株形态参数,外接矩形高(H)与宽(W)的比值;分形维数(FDN-IC):植株形态参数,预处理裁剪后 RGB 图的分形

维数;分形维数(FDIC):植株形态参数,植株外接矩形裁剪后 RGB 图的分形维数;频数(F1~F13):植株形态参数,每盆水稻每次拍摄在 360°范围内拍摄 13 张侧视图片,统计在 13 张图片中每个相同位置像素点出现前景点的频数,不考虑频数为 0 的点, F1 为 13 张图中相同位置只出现 1 次前景点的像素个数,以此类推,得到 F1~F13;紧凑度(PC1-PC6):植株形态参数,反映植株的紧凑程度;绿色程度(GCV):植株颜色参数,图片中绿色部分所有像素点 R 分量数值的平均值;绿色投影面积(GPA):植

株颜色参数,绿色部分像素点个数;绿色比例(GPAR):植株颜色参数,绿色投影面积与整株投影面积的比值; I 分量灰度直方图:植株纹理参数,均值 M_I 、平滑度 SE_I 、标准差 S_I 、三阶矩 $MU3_I$ 、一致性 U_I 、熵 E_I ;灰度-梯度共生矩阵特征($T_1 \sim T_{15}$):植株纹理参数,包含了像素的灰度信息和梯度信息, $T_1 \sim T_{15}$ 分别表示相关性、小梯度优势、大梯度优势、能量、灰度分布不均匀性、梯度分布不均匀性、灰度均值、梯度均值、灰度熵、梯度熵、混合熵、差分矩、逆差分矩、灰度标准差、梯度标准差。

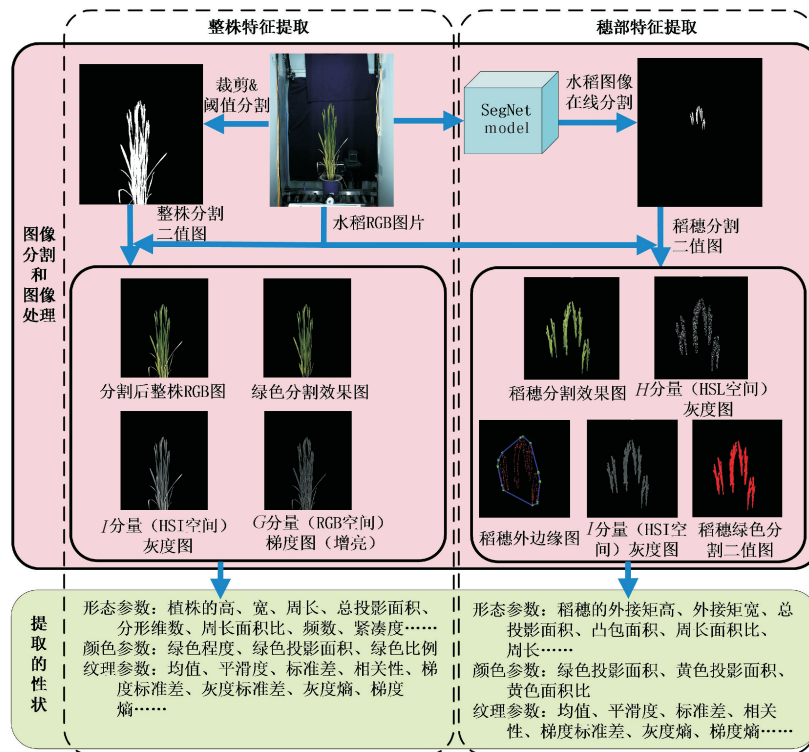


图 3 特征提取流程

Fig.3 Feature extraction process

2) 穗部特征提取。如图 3,主要处理过程:①将所有待分割的水稻盆栽图片裁剪为 360 像素×480 像素(高×宽)的子图,输入训练好的 Rice-PanicleNet 模型,得到分割的二值水稻子图。将这些图片拼接得到整株的稻穗分割图,将其与原图掩膜,得到分割后的 RGB 稻穗图。②RGB 稻穗分割效果图处理后得到 H 分量灰度图、稻穗外边缘图、 I 分量灰度图、稻穗绿色分割二值图,图 3 只显示穗部区域。

基于以上图像处理过程,共提取 33 个穗部特征。稻穗纹理参数:均值 P_M_I 、平滑度 P_SE_I 、标准差 P_S_I 、三阶矩 P_MU3_I 、一致性 P_U_I 、熵 P_E_I 、灰度-梯度共生矩阵特征($P_T1 \sim P_T15$);

稻穗形态参数:总投影面积 P_TPA 、外接矩高 P_H 、外接矩宽 P_W 、总投影面积/外接矩面积 P_TBR 、凸包面积 P_HA 、投影面积/凸包面积 P_THR 、周长/面积 P_PAR 、分形维数 P_FDIC 、周长 P_P ;稻穗的颜色参数:黄色投影面积 P_YPA 、绿色投影面积 P_GPA 、黄色面积比 P_YTR 。

1.6 稻穗计数和稻穗分割模型的评价标准

稻穗计数模型评估,将模型统计穗数与人工统计的实际穗数进行比较,误差越小,相关性越高,则模型的计数效果越好。主要的稻穗分割评价指标有 4 种:交并比 (IOU)、精度 (Precision)、召回率 (Recall) 和 F 值 (F -measure),其中,交并比 (IOU) 表示

分割结果与实际的一致性,取值范围为[0,1],交并比值越大表示分割效果越好,一般认为 IOU 达到 0.7 以上,表明分割结果比较准确。精度表示分割为稻穗的像素点中真实样本的比例,精度越高分割效果越好。召回率是真实稻穗像素点被分割出来的比例,数值越大表示分割的完整性越好。 F 值是一个综合性能指标,由于实际情况中,分割精度越高,召回率就越低,两者存在矛盾,故提出由两者计算得到的 F 值作为一个指标, F 值越大,表示分割效果越好。具体公式如下:

$$IOU = \frac{S_p}{S_p + S_f + T_p} \tag{1}$$

$$Precision = \frac{S_p}{S_p + S_f} \tag{2}$$

$$Recall = \frac{S_p}{S_p + T_p} \tag{3}$$

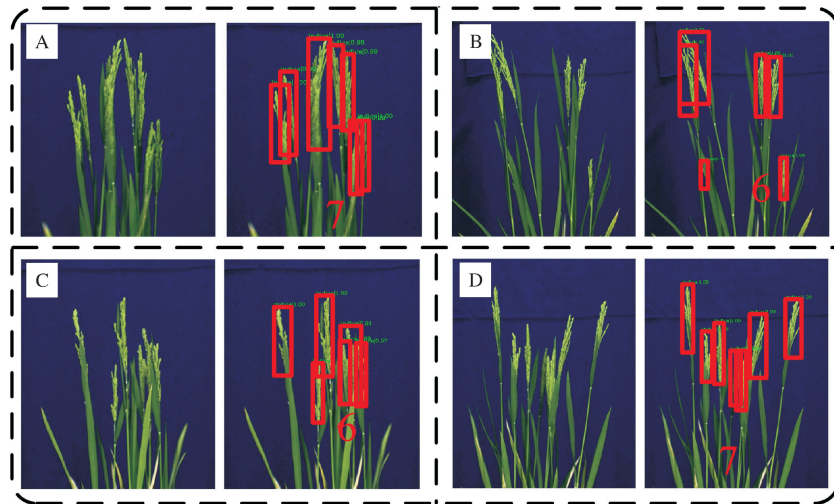
$$F\text{-measure} = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \tag{4}$$

式(1)~(4)中, S_p 表示预测和真实标签都为前景点的像素个数, S_f 表示预测为前景点而真实标签为背景点的像素个数, T_p 表示预测为背景点而真实标签为前景点的像素个数, T_f 表示预测和真实标签都为背景点的像素个数。

2 结果与分析

2.1 基于 Faster R-CNN 的水稻穗数计数模型准确性评估

在试验过程中,人工统计了每盆水稻稻穗的穗数。在测试阶段阈值设置为 0.5,利用训练好的 Faster R-CNN 模型,在线输入待检测的 1 079 张原始 RGB 图片,输出检测图。效果示意图见图 4。图 4 中稻穗部分用红色矩形框标出,同时在图中显示稻穗个数。每盆水稻每次拍摄 13 张图片,所以检测出 13 个稻穗的数值,考虑到不同角度拍照时存在遮挡及稻穗重叠的现象,取 13 张图片中检测到稻穗



A、B、C、D 为 4 组稻穗检测示意图,左边是原始图片的局部示意图,右边是检测结果输出图片。A、B、C 和 D are four groups of schematic diagram of rice panicle detection, the left is the local schematic diagram of the original picture, and the right is the output picture of the detection result.

图 4 Faster R-CNN 模型稻穗检测效果示意图

Fig.4 Schematic diagram of rice panicle detection effect of Faster R-CNN model

数目最大值作为检测结果,记做穗数(PN)。

图 5A 为 Faster R-CNN 模型自动检测穗数与人工统计的每盆水稻穗数的误差。从图 5 可以看出,自动检测与人工统计穗数误差为 0 的有 62 盆,穗数误差为 1 的有 18 盆,穗数误差为 2 的有 3 盆;

可以得出检测完全正确的盆数占总数 75%,误差在 ±1 以内的占总数 96%。图 5B 为穗数自动检测值与人工统计穗数的散点图,每个点左侧数字为该点的数据个数,红色线为 $Y=X$ 的直线,共 83 个数据,相关系数 $R^2=0.7607$ 。




图 5 穗数自动检测值与人工统计值的相关性分析

Fig.5 Correlation analysis between automatic detection value and manual statistical value of panicle number

2.2 基于 SegNet 的稻穗分割模型准确性评估

首先,将 1 079 张彩色 RGB 原图输入训练好的 SegNet 模型,输出得到二值化的分割效果图,然后,随机挑选 6 张彩色 RGB 原图作为测试集,使用 Photoshop 人工制作标签,原始 RGB 图片中的稻穗用白色填充,所有的背景像素用黑色填充,得到人工二值图。将人工二值图和 SegNet 模型分割二值结果图进行对比,计算出每张图的 IOU、Precision、Recall、F-measure。根据这些数据计算平均数。从表 1 可以看出,6 张图片的 4 个评价标准的值都在 0.8 以上,平均值分别为 0.970、0.861、91.168%、0.838,其中,综合评价参数 F 值达到 91% 以上,最能反映分割准确度的交并比平均值达到 0.83 以上。

表 1 分割效果评估

Table 1 Segmentation effect evaluation

序号 Number	精度 Precision	召回率 Recall rate	F 值/% F-measure	交并比 IOU
1	0.958	0.875	91.489	0.843
2	0.974	0.887	92.836	0.866
3	0.972	0.870	91.825	0.849
4	0.979	0.842	90.524	0.827
5	0.945	0.870	90.592	0.828
6	0.992	0.819	89.740	0.814
平均 Average	0.970	0.861	91.168	0.838

2.3 水稻穗质量预测模型的建立

本研究提取了整株水稻 51 个特征数据和穗部 33 个特征数据,以及 Faster R-CNN 网络检测得到穗数(PN),共 85 个特征,人工统计测量得到穗数(MN)、干质量(DW)、鲜质量(FW)共 3 个数据。每张图像 85 个特征数据,每盆水稻 13 张图片,计算 13 张图片特征数据的平均值,所有数据全部归一化处理。模型分别使用干质量和鲜质量作为因变量,

自变量从 3 种不同特征数据集中筛选:整株和穗的所有 85 个特征数据、Faster R-CNN 网络检测得到的穗数(PN)和穗部 33 个特征、整株水稻的 51 个特征。用这些自变量分别与因变量鲜质量、干质量数据建立预测模型,使用 SPSS 软件进行逐步线性回归分析,若挑选出来的特征 VIF 低于 10 表示特征之间的共线性较弱,特征的 Sig 小于 0.05 表示显著,当所挑选的特征满足 VIF 低于 10 和 Sig 小于 0.05,则用于预测模型。为了验证模型的性能,避免产生过拟合的现象,采用 K 折交叉验证的方法,这里 K 取数值 5,首先将所有数据集随机划分为 5 份,每次选取其中的 1 份作为测试集,其余 4 份为训练集,以此建立 5 个预测模型并测试,记录每次的评估参数,取平均值并计算标准偏差。本研究使用 R^2 、MAPE 和 SAPE 作为模型的评价指标, R^2 为决定系数、MAPE 为平均相对误差、SAPE 为相对误差绝对值的标准差, R^2 越高越接近于 1 预测效果越好,MAPE 和 SAPE 越小表示模型越稳定拟合效果越好,建立的 6 个模型的拟合效果评估见表 2。

由表 2 可知,稻穗鲜质量的 3 个预测模型中,穗部特征熵(P_E_I)和灰度-梯度共生矩阵特征混合熵(P_T11)作为自变量建立的模型预测效果最好, R^2 为 0.787 ± 0.051 、MAPE 为 0.107 ± 0.024 、SAPE 为 0.088 ± 0.029 。模型 1 和 2 对比,使用所有特征和仅使用穗特征时,挑选的模型自变量一样,而模型 3 仅使用整株特征预测的 R^2 为 0.505 ± 0.177 ,表明穗部特征作为自变量鲜质量的预测效果最好。

稻穗干质量的 3 个预测模型中,模型 4 使用所有特征预测效果最好 R^2 为 0.840 ± 0.054 、MAPE 为 0.103 ± 0.019 、SAPE 为 0.087 ± 0.019 。对比模型

表 2 稻穗鲜质量和干质量的多个预测模型五倍交叉验证性能评估

Table 2 Five times cross validation performance evaluation of multiple prediction models for fresh and dry weight of rice panicle

因变量 Dependent variable	模型序号 Model number	模型特征集 Model feature set	模型自变量 Model independent variables	决定系数 R^2	平均相对误差 MAPE	相对误差绝对值 的标准差 SAPE
鲜质量 FW	1	a	P_E_I,P_T11	0.787 ± 0.051	0.107 ± 0.024	0.088 ± 0.029
	2	b	P_E_I,P_T11	0.787 ± 0.051	0.107 ± 0.024	0.088 ± 0.029
	3	c	M_I,F6,H	0.505 ± 0.177	0.190 ± 0.069	0.183 ± 0.108
干质量 DW	4	a	P_E_I,P_T11,H,F6	0.840 ± 0.054	0.103 ± 0.019	0.087 ± 0.019
	5	b	P_E_I,P_T11	0.808 ± 0.043	0.103 ± 0.020	0.079 ± 0.024
	6	c	SE_I,PC1	0.512 ± 0.187	0.175 ± 0.066	0.171 ± 0.080

注 Note: a: 整株和穗的所有 85 个特征数据 85 feature data; b: Faster R-CNN 网络检测得到穗数(PN)和穗部的 33 个特征 Faster R-CNN network detects 33 features of panicle number (PN) and panicle; c: 整株水稻的 51 个特征 51 Features of the whole rice plant.

4 和 5, 在没有整株特征时模型 5 的 R^2 达到 0.808 ± 0.043 , 与模型 4 的 R^2 很接近, 而模型 6 仅使用整株特征预测时, R^2 为 0.512 ± 0.187 , 这表明当穗部特征和整株特征都作为自变量时稻穗干质量的预测效果最好。

6 个模型拟合效果表明, 对于水稻稻穗鲜质量的预测, 使用穗特征预测效果较好, 而使用整株特征时预测效果相对较差; 对于水稻稻穗干质量的预测, 穗部特征和整株特征都作为自变量预测效果最好, 仅使用整株特征预测效果相对较差。

3 讨 论

本研究提出了一种针对室内盆栽水稻特征提取和穗质量预测的新方法, 对比传统的表型特征获取方法, 可以实现高通量并且快速的水稻特征提取。通过稻穗分割, 提取了传统方法难以获取的穗部特征, 然后使用特征数据对稻穗的鲜质量、干质量进行预测。本研究基于卷积神经网络 Faster R-CNN 实现了盆栽水稻穗数的自动检测, 基于 SegNet 网络框架训练模型对盆栽水稻稻穗进行分割。利用 RGB 和 HIS 等颜色空间对整株水稻图片和分割后稻穗图片进行阈值分割, 经过图像处理, 提取了 51 个整株水稻特征和 33 个穗部特征。根据提取的 85 个特征数据, 建立多个盆栽水稻稻穗鲜质量和干质量预测模型, 使用五倍交叉验证对模型进行评估, 结果表明穗部特征的预测效果最好, 仅使用整株特征预测相对效果最差。水稻稻穗鲜质量预测模型中 R^2 最高达到 0.787 ± 0.051 , 稻穗干质量预测模型中 R^2 最高达到 0.840 ± 0.054 。

盆栽水稻产量预测对大田产量研究具有一定的

指导性, 由于大田水稻生长环境的复杂性, 生长过程不可控制, 产量预测具有一定的误差。研究预测盆栽水稻质量, 生长环境可控, 因为盆栽可移动性, 提取的表型数据多且数据更加精准, 通过盆栽种植水稻预实验, 挑选出与产量相关性高的表型特征, 在研究大田水稻时关注高相关性特征, 可以大幅度提高实验效率, 减少实验工作量, 从而快速挑选出高产品种。

参考文献 References

- [1] 袁隆平. 杂交水稻超高产育种[J]. 杂交水稻, 1997, 12(6): 1-6. YUAN L P. Super high yield breeding of hybrid rice[J]. Hybrid rice, 1997, 12(6): 1-6 (in Chinese with English abstract).
- [2] 石世杰, 李纯杰, 曹凑贵, 等. 稻虾共作模式下不同播期对水稻产量和品质的影响[J]. 华中农业大学学报, 2020, 39(2): 25-32. SHI S J, LI C J, CAO C G, et al. Effects of different sowing date on yield and quality of high quality rice in rice-crayfish ecosystem[J]. Journal of Huazhong Agricultural University, 2020, 39(2): 25-32 (in Chinese with English abstract).
- [3] 张佑宏, 王治虎, 张舒, 等. 栽培方式对水稻生育进程、主要病害严重度及产量的影响[J]. 华中农业大学学报, 2019, 38(3): 1-6. ZHANG Y H, WANG Z H, ZHANG S, et al. Effects of cultivation modes on growth process, severity of main diseases and yield of rice[J]. Journal of Huazhong Agricultural University, 2020, 39(2): 25-32 (in Chinese with English abstract).
- [4] HUANG J F, WANG X Z, LI X X, et al. Remotely sensed rice yield prediction using multi-temporal NDVI data derived from NOAA's AVHRR [J/OL]. PLoS One, 2013, 8: e70816 [2020-12-19]. <https://www.researchgate.net/publication/256073043>. DOI: 10.1371/journal.pone.0070816.
- [5] MAYUKO I, YOSHITSUGU H, TOMONORI T, et al. Analysis of rice panicle traits and detection of QTLs using an image analyzing method[J]. Breeding science, 2010, 60(1): 55-64.
- [6] GUO W, FUKATSU T, NINOMIYA S, et al. Automated characterization of flowering dynamics in rice using field-acquired

- time-series RGB images[J]. *Plant methods*, 2015, 11(1): 1-15.
- [7] KOBAYASI K. The analysis of the process in spikelet number determination with special reference to nitrogen nutrition in rice[J]. *Bulletin of the Faculty of Life & Environmental Science Shimane University*, 2000, 5: 13-18.
- [8] YANG W N, GUO Z L, HUANG C L, et al. Combining high-throughput phenotyping and genome-wide association studies to reveal natural genetic variation in rice[J/OL]. *Nature communications*, 2014, 5: 5087 [2020-12-19]. <https://www.researchgate.net/publication/266681466>. DOI: 10.1038/ncomms56087.
- [9] SACCONI N L, DOWNEY T J, MEYER D J, et al. Mapping genotype to phenotype for linkage analysis[J]. *Genetic epidemiology*, 1999, 17(S1): S703-S708.
- [10] LU H, CAO Z G, XIAO Y, et al. Region-based colour modelling for joint crop and maize tassel segmentation[J]. *Biosystems engineering*, 2016, 147: 139-150.
- [11] TANG W, ZHANG Y, ZHANG D Y, et al. Corn tassel detection based on image processing[C/OL]//International Society for Optics and Photonics. International Workshop on Image Processing and Optical Engineering. International Society for Optics and Photonics, 2012, 8335: 83350J-1-83350J-7 [2020-12-19]. <https://www.researchgate.net/publication/258714814>. DOI: 10.1117/12.917672.
- [12] 段凌凤. 水稻植株穗部性状在体测量研究[D]. 武汉: 华中科技大学, 2013. DUAN L F. Panicle traits measurement of rice plant *in vivo*[D]. Wuhan: Huazhong University of Science and Technology, 2013 (in Chinese with English abstract).
- [13] GHOSAL S, ZHENG B, CHAPMAN S C, et al. A weakly supervised deep learning framework for sorghum head detection and counting[J/OL]. *Plant phenomics*, 2019: 1525874 [2020-12-18]. <https://www.researchgate.net/publication/334070734>. DOI: 10.34133/2019/1525874.
- [14] XIONG X, DUAN L F, LIU L B, et al. Panicle-SEG: a robust image segmentation method for rice panicles in the field based on deep learning and superpixel optimization[J/OL]. *Plant methods*, 2017, 13(1): 104 [2020-12-03]. <https://link.springer.com/article/10.1186/s13007-017-0254-7>.
- [15] SADEGHI-TEHRAN P, VIRLET N, AMPE E M, et al. Deep-Count: in-field automatic quantification of wheat spikes using simple linear iterative clustering and deep convolutional neural networks[J/OL]. *Frontiers in plant science*, 2019, 10: 1176 [2020-12-19]. <https://www.frontiersin.org/articles/10.3389/fpls.2019.01176/full>. DOI: 10.3389/fpls.2019.01176.
- [16] 段凌凤, 熊雄, 刘谦, 等. 基于深度全卷积神经网络的大田稻穗分割[J]. *农业工程学报*, 2018, 34(12): 202-209. DUAN L F, XIONG X, LIU Q, et al. Field rice panicle segmentation based on deep full convolutional neural network[J]. *Transactions of the Chinese society of agricultural engineering*, 2018, 34(12): 202-209 (in Chinese with English abstract).
- [17] CASANOVA D, GOUDRIAAN J, FORNER M M C, et al. Rice yield prediction from yield components and limiting factors[J]. *European journal of agronomy*, 2002, 17(1): 41-61.
- [18] GANDHI N, PETKAR O, ARMSTRONG L J. Rice crop yield prediction using artificial neural networks[C/OL]//IEEE. IEEE technological innovations in ICT for agriculture and rural development. Chennai, 2016: 105-110 [2020-12-19]. <https://ieeexplore.ieee.org/document/7801222>. DOI: 10.1109/TIAR.2016.7801222.
- [19] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for scene segmentation[J]. *IEEE transactions on pattern analysis & machine intelligence*, 2017, 39(12): 2481-2495.
- [20] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2017, 39(6): 1137-1149.

Deep learning-based extraction of rice phenotypic characteristics and prediction of rice panicle weight

YANG Wanli¹, DUAN Lingfeng¹, YANG Wanneng²

1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China;

2. National Key Laboratory of Crop Genetic Improvement, Huazhong Agricultural University, Wuhan 430070, China

Abstract The yield of rice is closely related to the panicle number and the panicle weight of rice. The accurate prediction of rice yield can accelerate the speed of breeding. In order to study the relationship between rice yield and rice phenotypic characteristics, the visible light images combined with image

processing technology was used for extracting feature of potted rice. 51 phenotypic traits of whole rice were obtained. Combined with deep learning technology, the Faster R-CNN convolutional neural network training model was used to detect the number of rice spikes. At the same time, the SegNet model was trained using the SegNet network framework to segment the rice spikes to obtain the binary image of the rice spikes. 33 phenotypic feature data of the panicle were extracted with image processing technology. A total of 85 phenotypic parameters of color, shape, and texture were extracted, and all 85 data were normalized. The 85 phenotypic data normalized were gradually linearly regressed with the fresh and dry quality of rice panicle, and the correlation was selected. The artificial measurement data in the experiment included the fresh weight and dry weight of potted rice panicle. The models of predicting fresh and dry panicle weight of potted rice were established separately by using panicle number and characteristic panicles, 51 characteristics of whole plants and all 85 characteristics of high correlation characteristic data. The prediction model was optimized according to the determination coefficient R^2 , mean relative error (MAPE) and standard deviation of absolute relative error (SAPE). The optimal prediction model was selected according to the decision coefficient R^2 , average relative error (MAPE) and standard deviation of relative absolute value (SAPE) of the model. The results of prediction showed that the effect of predicting panicle characteristics is the best. The decision coefficients R^2 of the predicted value and the real value of the model with the best effect are 0.787 ± 0.051 and 0.840 ± 0.054 , respectively. Combined with deep learning, the number and characteristics of panicle difficult to obtain automatically by traditional methods are extracted. It will provide a new idea and method for predicting rice panicle weight, and further improving the accuracy of predicting rice panicle weight.

Keywords prediction of rice yield; plant phenomics; deep learning; image processing; rice panicle weight prediction; SegNet; Faster R-CNN

(责任编辑:陆文昌)