

周云成, 张羽, 刘泽钰, 等. 基于深度学习的稻粒在穗计数方法研究[J]. 沈阳农业大学学报, 2025, 56(1): 82-91.
ZHOU Y C, ZHANG Y, LIU Z Y, et al. Study on counting method of on panicle rice grains based on deep learning[J]. Journal of Shenyang Agricultural University, 2025, 56(1): 82-91.

基于深度学习的稻粒在穗计数方法研究

周云成, 张羽, 刘泽钰, 李瑞阳
(沈阳农业大学 信息与电气工程学院, 沈阳 110161)

摘要: [目的] 稻粒计数是水稻考种的重要环节。针对传统稻穗粒人工计数存在着效率低、易出错等问题, 研究构建一种稻穗原位计数模型。原位计数方法可以不破坏稻穗原有拓扑结构, 进而进一步应用于其他表型参数获取。[方法] 模型以 ResNet 作为骨干网络, 应用图像和范本稻粒之间的特征相关性, 预测稻粒概率密度分布, 进而通过密度图求和获取稻粒数量。构建稻穗图像数据集, 定义稻粒在穗计数模型的损失函数, 该函数同时考虑预测密度图与实际稻粒分布的一致性, 以及范本标注框的相关约束。用平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Squared Error, RMSE)、平均相对误差 (Mean Relative Error, MRE) 作为衡量模型性能的评估指标。[结果] 以 ResNet50 作为模型骨干网络, 模型可取得较理想的精度, 其 MAE、RMSE、MRE 分别为 10.937, 19.286, 13.4%, 该方法有着较为准确的计数性能。与 YOLOv8-seg 相比, 本研究模型的 MRE 下降 2.2%, 与基于实例分割的 SAM (Segment Anything Model) 模型相比, 本研究模型的 MRE 降低了 12.2%, 与 T-Rex2 模型相比, 则降低 6.5%。[结论] 基于深度学习模型构建, 能够自动识别和计数图像中稻粒, 提高计数效率, 同时相较于其他深度学习模型, 本研究模型具有更强的少样本学习能力。本方法可应用于稻粒在穗计数任务, 可为稻穗表型参数获取等提供一定技术参考。

关键词: 稻穗表型; 原位计数; 水稻; 特征提取; 表型参数

中图分类号: TP181; S126

文献标识码: A

文章编号: 1000-1700(2025)01-0082-10

Study on Counting Method of on Panicle Rice Grains Based on Deep Learning

ZHOU Yuncheng, ZHANG Yu, LIU Zeyu, LI Ruiyang

(College of Information and Electronic Engineering, Shenyang Agricultural University, Shenyang 110161, China)

Abstract: [Objective] Rice grain counting is a crucial step in rice seed testing. To address the inefficiencies and errors associated with traditional manual counting of rice grains, this study constructed an in-situ counting model for rice grains. In-situ counting method can not destroy the original topological structure of rice panicles, and then it can be further applied to obtain other phenotypic parameters. [Methods] The model employs ResNet as its backbone network and predicts the probability density distribution of rice grains by leveraging the feature correlation between image and rice grain exemplars. Subsequently, the number of rice grains is obtained by summing the density maps. An image dataset of rice panicles was collected, and a loss function tailored for rice grain counting on panicles was defined. This function takes into account both the consistency between the predicted density map and the actual rice grain distribution, as well as the relevant constraints of the exemplar labeling box. The performance of the model was evaluated using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Relative Error (MRE). Experimental [Results] Utilizing ResNet50 as the model's backbone network achieves impressive accuracy, with MAE, RMSE, and MRE values of 10.937, 19.286, and 13.4%, respectively. This method exhibits superior counting performance. Compared to YOLOv8-seg, the MRE of

收稿日期: 2024-10-10 收稿日期: 2024-12-30

基金项目: 国家重点研发计划项目 (2021YFD1500204, 2023YFD1501303)

第一作者: 周云成 (1979-), 男, 博士, 教授, 从事机器学习在农业信息处理中应用研究, Email: zhouyc2002@syau.edu.cn

the proposed model is reduced by 2.2%. When compared to the SAM (Segment Anything Model) based on instance segmentation, the MRE of the proposed model decreases by 12.2%, and compared to the T-Rex2 model, it is reduced by 6.5%. **[Conclusion]**This research method is based on the deep learning model, which can automatically identify and count rice grains in the image and improve the counting efficiency. At the same time, compared with other deep learning models, this research model has stronger learning ability with few samples. The method presented in this paper can be effectively applied to the task of rice grain counting in panicles, and the research provides valuable insights for obtaining phenotypic parameters of rice panicles.

Key words: phenotype of rice panicle; *in-situ* counting; rice; feature extraction; phenotypic parameter

我国水稻产量占全国粮食总产量的近 30%^[1],是全球最大的水稻生产国和消费国,稳定的水稻生产对维护国家粮食安全至关重要,而选育高产优质品种是保障水稻产量的关键^[2]。水稻穗粒数是表征水稻性状的重要指标之一,在一定程度上决定了水稻的产量潜力^[3]。传统人工计数法费时费力,通过结合计算机视觉和深度学习技术,实现水稻穗原位稻粒快速计数,对降低考种劳动强度,加快育种速度具有一定意义^[4-5]。

稻粒计数可分为在穗计数和脱穗计数两种。脱穗计数需要在水稻收获后逐一脱粒^[6],这种方式时间成本较高且具有破坏性。而在穗计数省时省力,无需脱粒,是一种具有实时性和非破坏性的方法^[7]。从计数方法上看,稻粒计数可分为人工方法和基于计算机视觉技术^[8]的方法。人工计数简单,但效率低、易出错。随着计算机视觉技术的进步,当前也出现了一些用于穗粒计数的软硬件^[9-10]。范梦扬等^[11]应用支持向量机(Support Vector Machine, SVM)作为分类器,构建了一种大田麦穗计数模型,但精度难以满足稻粒原位计数的要求。YAM-AUCHI 等^[12]通过建立多元线性回归模型来估计稻穗抽穗数量,此模型处理非线性关系的能力有限,无法提供准确预测。刘成良等^[13]提出了一种基于深度学习的水稻穗稻粒原位无损计数方法,此方法在一定程度上提高了谷粒计数的准确性和效率,但其训练样本要根据生成的概率图精确标注每个谷粒的位置,耗时且需要专业知识,如标注不准确,会导致计数结果的偏差。王宏乐等^[14]采用深度学习技术,基于无人机采集的水稻稻穗 RGB 图像,利用 YOLOv7 模型进行稻穗快速计数,该方法具有较高精度和实用性,但当水稻处于成熟后期时,单穗较重,容易弯曲并交缠在一起,导致分割结果不准确,增加了稻穗识别的难度,同时基于目标检测的计数方法也需要大量的框标注工作,增加了模型构建的成本。

为满足水稻穗稻粒原位精确计数的要求,本研究在参考已有研究基础上,构建一种用于稻粒原位计数的深度学习模型,该模型通过预测稻粒在穗上的概率密度分布,来实现在穗计数。模型只需通过对稻粒的点标注和少量的框标注来构建训练样本。本研究模型应用深度神经网络提取稻穗图像特征,基于少量框标注样本的深度特征与图像特征的相关性来预测稻粒的概率密度分布,进而通过对概率密度的统计实现稻粒原位计数。通过试验验证方法的有效性,以期稻穗表型参数获取提供支撑。

1 材料与方法

1.1 稻穗图像数据集构建

1.1.1 成像平台设计 将吸光布平铺在平直硬木板上,并用图钉固定,用摄像头支架将数码相机固定于平台正中央上方,垂直距离 30 cm,并在摄像头上方放置 LED 照明灯作为光源。相机型号为 DC201S,分辨率为 6 880×5 160 像素。成像平台示意图如图 1。选用黑色吸光布,提供一个颜色均匀、色调简单的背景,并通过吸收光线,产生漫反射,避免可能的镜面反射对图像采集结果的干扰,提高图像质量。通过光源,确保平台光照分布均匀,在自然光不足时,通过人工光源还原稻穗细节,得到更为清晰的高质量图像。

1.1.2 稻穗图像采集及预处理 稻穗试验材料为天域稻 2 号,于 2023 年 9 月,采集自沈阳农业大学水稻研究所试验基地,品种处于灌浆期和成熟期之间^[15]。稻穗采集后,自然风干备用。将稻穗放置于载物台中心,依次梳




图 1 平台各硬件组装配置

Figure 1 Hardware assembly configuration of platform

理开稻穗的一次枝梗、二次枝梗,在恰当位置用固定针予以固定,使枝梗之间不产生遮挡,稻粒暴露在外。试验过程中,平均每穗梳理时间1.5 min。通过稻穗梳理,可有效减少稻粒被遮挡的情况,提高后续稻粒计数精度。先后采集了1 360幅稻穗图像。

为进一步提高图像质量,以利于后续稻粒原位测量,应用前馈去噪卷积神经网络 DnCNN(Deep Neural Network for Image Denoising)对稻穗图像进行盲高斯去噪^[16-17]。DnCNN通过引入学习算法、正则化、残差学习^[18]和批量归一化的方法提高去噪性能。DnCNN的输入为带噪声的原始图像,表示为 $y = x + v$,其中 y 为噪声图像, x 为无噪声图像, v 为图像噪声。DnCNN采用残差学习方式训练其预测原始图像全部噪声的能力,即输出结果是一个无限接近 v 的量 $R(y)$, R 为基于DnCNN的去噪过程,最后通过 $x = R(y) - v$ 得到去噪后的图像。为了保持输出噪声图与输入图像尺度的一致,DnCNN去除了池化层,并为中间层的特征图在每次卷积之前进行全零边界填充,该网络的结构如图2,用其对稻穗图像进行去噪,结果如图3。




图2 DnCNN网络的结构

Figure 2 The architecture of DnCNN network




图3 图像去噪前后对比

Figure 3 Comparison before and after image denoising

虽然图像采集平台可应用光源进行补光,然而当环境光线弱时,仍会使稻穗成像结果偏暗。本研究采用低光照图预测模型^[19]和Retinex算法^[20]对图像进行光线增强处理。低光照图预测模型的基本原理为学习预测低光照图像与相应亮度图之间的映射关系并输出低光照图像的光照图,其骨干网络采用CNN结构^[21],具体包括3层卷积,第一层主要针对高光区域进行特征提取,第二层通过非线性映射保留低光区域的最本质特征,最后一层用于聚合图像并输出预测的低光照图,进一步通过Gamma校正调整预测图,增强图像对比度。通过图像增强,可有效改善图像偏暗的问题(图4)。

1.1.3 稻穗图像标注及数据集构建 使用图像标注工具Labelme对去噪和增强后的稻穗图像进行标注,共进行2种类型的标注,即点标注和框标注。首先进行点标注,标注每颗稻粒的近似中心位置。其次进行框标注,选取图像上的少量范本稻粒,用矩形框标注稻粒的最小外接矩形。范本稻粒在选取时,所选稻粒朝向尽量不同,以提高范本的多样性和代表性。标注结果示例如图5。稻穗图像和标注结果共同构成稻穗图像数据集。




图4 图像增强前后对比

Figure 4 Comparison before and after image enhancement




图5 稻穗图像标注示例

Figure 5 Example of rice panicle image labeling

1.2 稻粒原位计数模型构建

1.2.1 技术框架图 本研究在参考FamNet^[22]少样本计数模型基础上,设计稻粒原位计数模型,该模型的整体结构如图6。本研究模型基于稻穗图像特征和图像中少量范本稻粒间的特征相关性来预测图像上的稻粒概率密度分布,并通过进一步对稻粒概率密度分布的统计求和来获取稻粒数量。模型主要由特征提取模块(Fea-

ture Extraction Module, FEM)、兴趣区池化(Region of Interest Pooling, ROI Pool)、特征相关层(Feature Correlation Layer, FCL)、密度预测模块(Density Prediction Module, DPM)4部分构成,其中FEM和DPM为关键模块^[23]。模型的输入为稻穗图像 $I \in R^{H \times W \times 3}$ 和在同一图像上的范本稻粒的边界标注框。FEM对原始图像进行特征提取,所提取的图像特征图连同范本稻粒的标注框坐标信息一起作为ROI Pool的输入。ROI Pool层应用范本稻粒的边界标注框坐标,在图像特征图上直接获取范本稻粒的特征。FCL应用范本稻粒的特征向量和输入稻穗图像的特征图,计算二者之间的特征相关图,计算方法为应用范本特征向量和特征图上的每个位置的特征向量之间的特征近似性,及通过二者之间的点积来计算相关性。以相关性图作为DPM的输入,由DPM预测稻粒的概率密度分布图 $Z \in R^{H \times W}$,通过对 Z 求和获取稻粒数量。

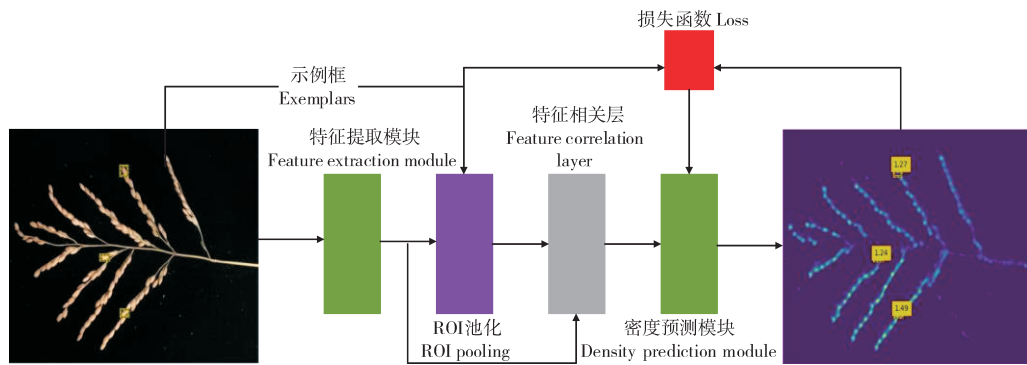



图6 稻粒原位计数模型
Figure 6 In-situ rice grain counting model

1.2.2 特征提取网络设计 应用卷积神经网络(Convolution Neural Network, CNN)作为稻粒原位计数模型的特征提取器。ResNet50^[24]是一种优秀的CNN网络,其在多种计算机视觉任务上都取得了良好的性能。本文也采用ResNet50骨干网络的前4组残差块(ResModule)作为模型的FEM,其网络结构如图7。ResModule包含Conv Block与Identity Block两种基本的块,其结构如图8,Conv Block为每组Block中的首个基本块,且每组仅有一个,除Conv Block外,其余块均为Identity Block。ResNet50从输入到输出共经过4组Block,每组分别有3,4,6,3个基本残差块ResModule,每个ResModule由3层卷积(conv)堆叠而成。

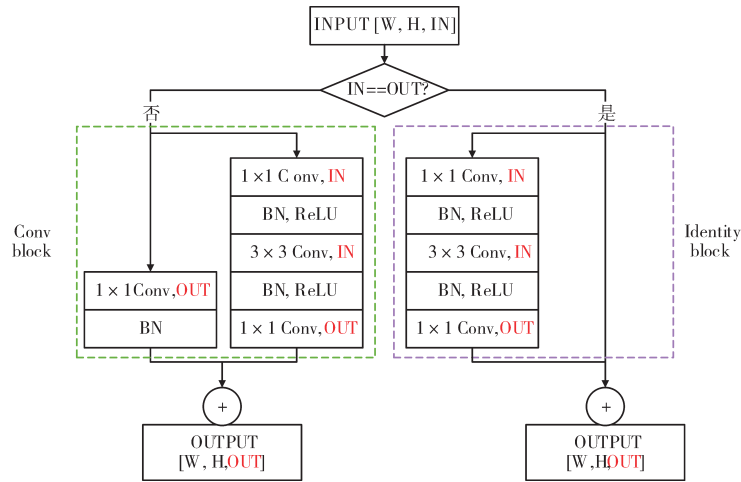


Conv表示卷积层,BN为批归一化层,ReLU为调整线性单元激活函数,FC为全连接层。下同
Conv is short for Convolution, BN denotes batch normalization layer, ReLU stands for rectifier linear unit activation, FC means fully-connected layer. The same below

图7 ResNet50网络结构
Figure 7 Network architecture of ResNet50

用ImageNet1000数据集训练带分类器部分(由全连接层构成)的ResNet50,训练结束后去除分类器,将如图7所示的骨干网络部分用作模型的FEM,同时在计数模型的进一步训练中,冻结FEM的权重参数。将FEM第3、第4残差组中最后一个残差模块的输出特征图用作后续ROI Pool模块的输入。

1.2.3 ROI Pool 为增强特征的多尺度表达能力,本模型应用特征金字塔网络(Feature Pyramid Network, FPN)捕捉不同大小和形状的稻穗谷粒特征,方法为用ROI池化,通过标注范本标注框定位,从第3和第4组残差块输出的卷积特征图中提取特定区域的范本特征。在计数任务中,通常需要处理几何特征不同的目标,即在范本尺度不统一的前提下,将目标转换为尺度统一的特征表示。要ROI Pool通过对每个示例的特征图进行上



W、H、IN 分别表示输入特征图的宽度、高度以及通道数，OUT 表示输出特征图的通道数

W, H, and IN represent the width, height, and number of input channels of the input feature map, respectively, while OUT represents the number of output channels of the output feature map

图8 残差模块结构

Figure 8 Residual module structure

采样,将目标区域逐个映射到固定大小的特征图上,这样无论目标在原始图像中尺度如何,经过ROI Pool后,都会生成一个固定大小的特征向量,便于后续处理。ROI Pool在范本标注框的位置引导下,可从输入特征图中提取稻粒范本的统一尺度特征向量,用于后续计算特征相关图。

1.2.4 特征相关层 特征相关层FCL使用范本特征作为卷积核来卷积图像特征,将卷积结果称为特征相关图,卷积过程的点积运算可在运算结果中体现特征之间的相关性,当在特征图的某个空间位置上为稻粒特征时,稻粒范本特征和该位置的特征之间应具有近似性,因此该位置的卷积结果应具有高响应^[25],这为后续稻粒概率分布预测提供了线索,因此将特征相关图用于后续的稻粒概率密度预测。为了更好地计数不同尺度下的稻粒,将稻粒范本缩放为0.9和1.1比例的不同尺度,并将缩放后的范本特征和原始比例的范本特征分别对原始图像特征建立相关性,以生成多个尺度的特征相关图。最后将3个相关图在通道维度上合并,以得到最终的特征相关图,过程如图9。

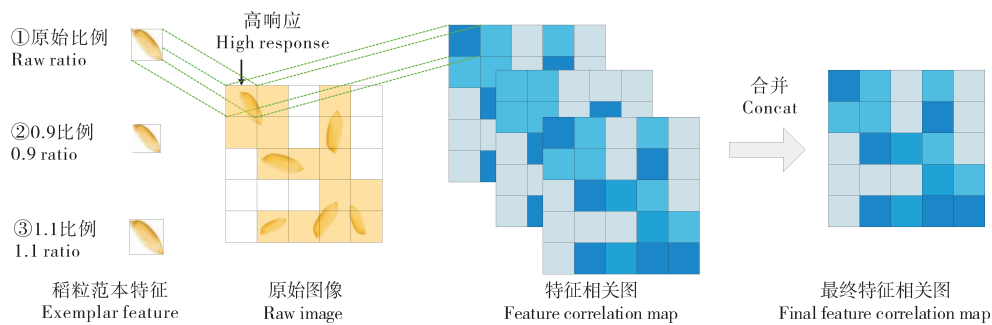


图9 特征相关层结构

Figure 9 Feature correlation layer structure

1.2.5 密度预测模块设计 密度预测模块DPM基于FCL生成的相关图来预测稻穗图像上的稻粒概率密度分布。DPM由5个卷积层和设置在第1、第2、第3卷积层之后的3个上采样层构成,最后一层是1x1卷积层,用于预测稻粒分布概率密度图Z,用于表示图像中稻粒的分布情况,最后通过对所有密度值求和获得稻粒数量^[26]。DPM的结构如图10。

1.2.6 损失函数定义 为充分利用范本稻粒边界框位置提供的信息,为计数模型定义两种类型的损失,一种考虑预测密度图的准确性,另一种考虑预测区域与真实标注之间的一致性。设B表示范本稻粒的标注框集合,




图10 DPM结构

Figure 10 DPM structure

对于每个范本稻粒的标注框 $b \in B$, 设 Z_b 为计数模型预测的概率密度图 Z 在标注框 b 内的裁剪, 根据穗粒分布实际情况, b 内的穗粒样本和其他穗粒之间可能存在重叠, 因此在 b 指定的范围内至少存在一颗穗粒, 即 b 内的预测计数值至少为 1, 因此应有 $\|Z_b\|_1 \geq 1$, $\|Z_b\|_1$ 表示 Z_b 的元素值求和结果。当 b 内样本数少于 1 时, 将对预测模型进行惩罚, 该约束通过引入式 (1) 所示的最小计数损失 (Min-Count Loss) l_{mc} 来实现。当 $\|Z_b\|_1 < 1$ 时, 模型将产生预测损失, 该损失通过误差回传, 修正预测模型的可学习参数, 使模型逐渐生成正确的预测。

$$l_{mc} = \sum_{b \in B} \max(0, 1 - \|Z_b\|_1) \quad (1)$$

在给定范本稻粒的边界框内, 计数方法应学得一个滤波器, 该滤波器在边界框的精确位置时应具有最高响应, 而在受干扰的其他位置应具有较低响应。响应值会随着扰动距离增加呈指数衰减, 通常为高斯分布。预测的密度图 Z 本质上是范本和图像之间的卷积特征图, 因此, 样本位置周围的密度值在理想状态下也应是高斯分布, 通过式 (2) 所示的扰动损失 (Perturbation Loss) l_p [27-28] 来实现该约束, 使标注框内的特征值呈高斯分布。

$$l_p = \sum_{b \in B} \|Z_b - G_{h \times w}\|_2^2 \quad (2)$$

式中: $G_{h \times w}$ 表示大小为 $h \times w$ 的 2D 高斯分布图。最小计数损失和扰动损失使模型预测的密度图在范本标注区域与实际标注之间具有分布一致性。

除范本标注区域的一致性外, 模型预测的稻粒概率密度分布图也应与基于稻粒点标注结果生成的密度图具有一致性, 这可以使模型预测的结果与实际稻粒数量相符。通过应用式 (3) 所示的一致性损失 l_s , 来约束预测密度与真实密度图的一致性。

$$l_s = \|Z - \bar{Z}\|_2^2 \quad (3)$$

式中: \bar{Z} 为应用高斯平滑生成的真实稻粒分布密度图。

用 l_s 、 l_{mc} 和 l_p 的线性组合, 作为模型的总损失函数, 其定义为:

$$l = l_s + \lambda_1 l_{mc} + \lambda_2 l_p \quad (4)$$

式中: λ_1 、 λ_2 为线性组合系数。

1.2.7 计数模型的训练与测试方法 基于 PyTorch 计算框架, 应用 Python 编程实现本研究稻粒在穗计数模型。在配置有 Intel Xeon Silver 4312 CPU、128GB 内存, Nvidia Tesla A10 GPU, Windows Server 2019 操作系统的计算机上开展训练与测试试验。将稻穗图像数据集按 7:1:2 比例划分为训练集、验证集和测试集。训练过程中, 将输入图像设置为 512×384 像素, 并采用随机翻转、颜色抖动等图像增广方法增加样本多样性。采用随机梯度下降法训练本研究模型, 学习率设置为 10^{-5} 。测试过程中, 则调整输入图像大小, 不再采用任何数据增广方法, 且测试过程中, 输入图像仅需少量范本稻粒的框标注, 不再需要其他的点标注。

2 结果与分析

2.1 评价指标定义

用观测值和预测值之间的平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Squared Error, RMSE)、平均相对误差 (Mean Relative Error, MRE) 3 项指标来衡量模型的稻粒计数性能, 各指标的定义为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

$$MRE = \frac{1}{n} \left(\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100\% \quad (7)$$

式中： n 为稻穗图像样本数量； y_i 和 \hat{y}_i 分别为第 i 幅图像对应的人工计数值和计数模型的预测值。

2.2 骨干网络选择

本研究计数模型采用 ResNet 作为特征提取骨干网络,其中 ResNet34、ResNet50 和 ResNet101 是 3 种标准的网络结构,在分类任务上的性能逐渐提高,为分析骨干网络本身的性能对模型计数性能的影响,分别用 ResNet34、ResNet50、ResNet101 作为模型骨干网络,训练计数模型并用其对稻粒图像验证集和测试集进行稻粒数量预测,结果如表 1。

表 1 骨干网络对稻粒计数性能的影响

Table 1 Influence of backbone network on rice grain counting performance

骨干网络 Backbone network	验证集 Validation set			测试集 Test set		
	MAE	RMSE	MRE/%	MAE	RMSE	MRE/%
ResNet34	12.062	22.059	14.9	12.323	27.073	17.2
ResNet50	11.663	18.125	11.9	10.937	19.286	13.4
ResNet101	11.912	20.053	13.2	11.877	20.015	13.6

由表 1 可知,在验证集上,使用 ResNet34 为骨干网络时模型的 MAE 为 12.062,使用 ResNet101 的 MAE 为 11.912,相较于这两种网络,使用 ResNet50 的模型 MAE 最低,为 11.663。对于 RMSE 指标,ResNet50 网络的指标值为 18.125,低于使用 ResNet34 和 ResNet101 时的该项指标值。对于 MRE 指标,ResNet50 的值比 ResNet34 网络下降 3.0%,比 ResNet101 网络下降了 1.3%。在测试集上,3 种网络相比,ResNet34 的 MAE、RMSE、MRSE 分别为 12.323, 27.073, 0.172, ResNet101 的 MAE、RMSE、MRE 分别为 11.877, 20.015, 13.6, ResNet50 的 MAE、RMSE、MRE 分别为 10.937, 19.287, 13.4。显然,使用 ResNet01 网络时模型的 3 项指标均处 ResNet34 和 ResNet50 网络之间,模型性能没有达到最优,而使用 ResNet50 为骨干网络时的指标最好,优于另外 2 种网络。ResNet50 网络相较于 ResNet34 有更多的卷积层,网络结构越深学习能力越强,所以 ResNet50 更能够捕捉到更复杂的图像特征,进而提高了模型性能。ResNet101 在 3 种骨干网络中网络结构最深,但卷积层数过多反而让模型过度关注细节而忽略整体,导致模型性能不升反降。因此,本研究用 ResNet50 作为模型的骨干网络,并用于后续试验。

2.3 稻粒在穗计数方法有效性验证

用本研究稻粒在穗计数模型,预测稻穗图像测试集中部分样本对应的稻粒分布,通过求和获得计数结果,并与人工计数结果进行比较,结果如表 2。同时对模型预测的稻粒分布概率密度图用热力图的方式进行可视化,结果如图 11。

表 2 部分稻穗测试样本计数结果

Table 2 Counting results of some rice panicle test sample

样本编号 Sample no.	真实值 True value	预测值 Predictive value	绝对误差 Absolute error	相对误差/% Relative error
1	168	171.14	3.14	1.86
2	167	164.65	2.35	1.40
3	175	183.5	8.50	4.85
4	122	129.43	7.43	6.09
5	151	143.24	7.76	5.13
6	142	141.25	0.75	0.52
7	134	134.20	0.20	0.14
8	136	141.84	5.84	4.29
9	131	123.77	7.23	5.51
10	116	118.63	2.63	2.26



图11 测试结果

Figure 11 Test results

测试结果表明,模型通过结合多特征提取和密度预测模块,能够有效预测图像中的目标数量。在面对图像中目标大小差异、稻穗谷粒粘连等挑战时,模型展现出了良好的鲁棒性。得益于模型在训练过程中学习到的多尺度特征,其能保持较高的计数准确度,在部分测试样本上,其相对误差低至0.14%。

图11中,真实密度图基于点标注结果生成,用于反映稻粒真实分布情况,而预测密度图基于模型对稻粒分布的预测结果生成,反映了模型对稻粒分布的理解和预测能力,通过视觉对比两幅密度图可初步判断预测分布结果与实际分布结果相似性极高,从预测数值来看,预测稻粒数为171.14与真实结果168的绝对误差为3.14,相对误差为1.86%,模型具有较好的准确性。

2.4 方法间比较与分析

为进一步分析本研究模型在稻粒在穗计数任务上的有效性和可靠性,用本研究方法在全部稻穗图像验证集和测试集上进行性能测试。同时与T-Rex2^[29]、SAM^[30]和YOLOv8-seg^[31]等常用模型进行计数性能比较。T-Rex2模型通过视觉和文本提示协同来实现通用对象的检测计数,SAM是一种新出现的可以分割任何目标对象的通用视觉模型,YOLOv8-seg则为可实现实例分割的专用模型。本研究同时通过后两种模型的实例分割结果进行目标统计计数。4个模型在稻穗图像验证集和测试集上的计数结果如表3。

表3 不同计数模型间的性能比较

Table 3 Performance comparison among different counting models

方法 Methods	验证集 Validation set			测试集 Testing set		
	MAE	RMSE	MRE/%	MAE	RMSE	MRE/%
FamNet	11.663	18.125	11.9	10.937	19.286	13.4
T-Rex2	21.307	28.674	18.6	23.748	29.384	19.9
SAM	31.680	36.754	24.9	33.531	42.272	25.6
YOLOv8-seg	14.985	23.399	15.9	17.347	23.320	15.6

由表3可知,在验证集上,本研究模型的MAE为11.663,比T-Rex2、SAM和YOLOv8-seg的MAE分别降低9.644,20.017,3.322, RMSE则为18.125,优于其他3种模型,本研究模型的MRE为11.9%,比T-Rex2、SAM和YOLOv8-seg分别降低6.7%、13.0%和4.0%。在测试集上,本研究模型的MAE、RMSE和MRE均最低,与T-Rex2相比,本研究模型的MRE下降6.5%,与SAM相比,MRE下降12.2%,与YOLOv8-seg相比,MRE则下降2.2%。本研究模型在各项指标上均优于T-Rex2、SAM和YOLOv8-seg,表明本研究模型在稻粒原位计数任务上的有效性。

3 讨论与结论

水稻作为我国最主要的粮食作物之一,其产量对保障粮食安全具有重要作用。稻穗上稻粒着生数量是水稻产量潜力的重要指标之一,通过准确稻粒计数,可以更好地估算作物产量潜力,从而筛选培育出优质高产的水稻品种,为粮食自给提供保障。传统的稻粒计数方法主要依靠人工,存在人员主观干扰、工作强度大、易出错等问题。通过图像处理和传统机器学习的谷粒计数方法也存在着需要人工干预、无法处理大量数据,对复杂场景处理能力不足的问题。本研究方法基于深度学习模型构建,能够自动识别和计数图像中稻粒,提高了计数效率,同时相较于其他深度学习模型,本研究模型具有更强的少样本学习能力。同时,在穗计数方法可以

不破坏稻穗原有拓扑结构,可进一步应用于其他表型参数获取。和现有模型进行了比较,结果显示本研究方法在稻粒在穗计数上的精度优于其他方法。本研究模型是基于范本稻粒标注与图像的相关性来预测稻粒的概率密度分布的,这种处理可以提高计数精度,但也同时要求模型在训练和推理阶段都要有范本标注,这增加了模型在实际应用中的工作量,即在推理时也需少量标注范本稻粒。同时本研究模型虽在精度上优于当前常用的基准模型,然而相对误差仍较高,下一步将通过引入通用视觉大模型作为特征提取模块,同时优化模型损失函数,以期进一步提高模型计数精度。

构建了一种基于深度学习的稻粒在穗计数方法,对其在稻粒原位计数上的有效性进行了试验分析,结果表明,骨干网络对模型的计数性能具有一定影响,与ResNet34和ResNet101相比,ResNet50具有更好的计数性能。该方法有着较为准确的计数性能,在验证集上MAE为11.663, RMSE为18.125, MRE为11.9%,在测试集上的MAE为10.937, RMSE为19.286, MRE为13.4%。与现有的计数方法相比,本研究方法具有更高的稻粒计数性能,其中与基于实例分割SAM模型相比, MRE下降12.2%,与T-Rex2相比, MRE则下降6.5%。本研究模型能够有效检测并计数稻粒,为快速获取稻穗在穗籽粒数提供了一种有效方法。

参考文献:

- [1] 陆开峰.水稻高产栽培技术探究[J].农业与技术,2017,37(11):80-81.
LU K F.Exploration of high yield cultivation techniques for rice[J].Agriculture and Technology,2017,37(11):80-81.
- [2] 段凌凤,杨万能.水稻表型组学研究概况和展望[J].生命科学,2016,28(10):1129-1137.
DUAN L F,YANG W N.Overview and prospects of rice phenotypomics research[J].Chinese Bulletin of Life Sciences,2016,28(10):1129-1137.
- [3] 杨万里.基于深度学习的水稻表型特征提取和产量预测研究[D].武汉:华中农业大学,2020.
YANG W L.Research on rice phenotypic feature extraction and yield prediction based on deep learning[D].Wuhan:Hua-zhong Agricultural University,2020.
- [4] 鲍文霞,张鑫,胡根生,等.基于深度卷积神经网络的田间麦穗密度估计及计数[J].农业工程学报,2020,36(21):186-193.
BAO W X,ZHANG X,HU G S,et al.Field wheat ear density estimation and counting based on deep convolutional neural network[J].Transactions of the Chinese Society of Agricultural Engineering,2020,36(21):186-193.
- [5] 刘云玲,张品戈,王千航,等.基于多列空洞卷积神经网络的麦穗计数方法研究[J].吉林农业大学学报,2021,43(2):171-180.
LIU Y L,ZHANG P G,WANG Q H,et al.Research on wheat ear counting method based on multi column hollow convolutional neural network[J].Journal of Jilin Agricultural University,2021,43(2):171-180.
- [6] 田孟祥,张时龙,何友勋,等.1种快速高效的水稻谷粒自动计数方法[J].江苏农业科学,2014,42(2):64-66.
TIAN M X,ZHANG S L,HE Y X,et al.A fast and efficient automatic counting method for rice grains[J].Jiangsu Agricultural Sciences,2014,42(2):64-66.
- [7] 范圣哲,贡亮,杨智宇,等.面向水稻穗上谷粒原位计数与遮挡还原的轻量级I2I深度学习[J].华南农业大学学报,2023,44(1):74-83.
FAN S Z,GONG L,YANG Z Y,et al.Lightweight I2I deep learning method for in-situ counting and occlusion restoration of grains on rice panicles[J].Journal of South China Agricultural University,2023,44(1):74-83.
- [8] 董洪丽,江翰屿,高晨翔,等.结合图像处理和深度学习的麦穗识别方法[J].人工智能与机器人研究,2021,10(4):299-305.
DONG H L,JIANG H Y,GAO C X,et al.Wheat ear recognition method combining image processing and deep learning[J].Artificial Intelligence and Robotics Research,2021,10(4):299-305.
- [9] 焦雁翔,唐玉琴,黄成志,等.Matlab图像处理在水稻谷粒计数中的应用[J].南方农业,2018,12(4):82-84,92.
JIAO Y X,TANG Y Q,HUANG C Z,et al.Application of MATLAB image processing in rice grain counting[J].South China Agriculture,2018,12(4):82-84,92.
- [10] 李毅念,杜世伟,姚敏,等.基于小麦群体图像的田间麦穗计数及产量预测方法[J].农业工程学报,2018,34(21):185-194.
LI Y N,DU S W,YAO M,et al.Field wheat ear counting and yield prediction method based on wheat population images[J].Transactions of the Chinese Society of Agricultural Engineering,2018,34(21):185-194.
- [11] 范梦扬,马钦,刘峻明,等.基于机器视觉的大田环境小麦麦穗计数方法[J].农业机械学报,2015,46(增刊1):234-239.
FAN M Y,MA Q,LIU J M,et al.Machine vision based wheat ear counting method in field environment[J].Transactions of the Chinese Society for Agricultural Machinery,2015,46(S1):234-239.

- [12] YAMAUCHI Y,HIRAI Y,SARUTA K,et al.Evaluation of a multiple linear regression model for the prediction of panicle number in rice[J].Journal of the Faculty of Agriculture,Kyushu University,2012,57(2):421-426.
- [13] 刘成良,贡亮,吴伟,等.基于深度学习的水稻穗株谷粒原位无损计数方法:CN201910501939.9[P].2019-10-25.
LIU C L,GONG L,WU W,et al.In situ non-destructive counting method for rice grains based on deep learning: CN201910501939.9[P].2019-10-25.
- [14] 王宏乐,叶全洲,王兴林,等.基于YOLOv7的无人机影像稻穗计数方法研究[J].广东农业科学,2023,50(7):74-82.
WANG H L,YE Q Z,WANG X L,et al.Research on rice ear counting method based on YOLOv7 UAV image[J].Guangdong Agricultural Sciences,2023,50(7):74-82.
- [15] SHAO H M,TANG R,LEI Y J,et al.Rice ear counting based on image segmentation and establishment of a dataset[J].Plants, 2021,10(8):1625.
- [16] ZHANG K,ZUO W M,CHEN Y J,et al.Beyond a Gaussian denoiser:Residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing:a Publication of the IEEE Signal Processing Society,2017,26(7):3142-3155.
- [17] SUN Y N,XUE B,ZHANG M J,et al.Evolving deep convolutional neural networks for image classification[J].IEEE Transactions on Evolutionary Computation,2020,24(2):394-407.
- [18] SHAFIQ M,GU Z Q.Deep residual learning for image recognition:A survey[J].Applied Sciences,2022,12(18):8972.
- [19] 李江华,王坤.一种基于卷积神经网络的低光照图像增强方法[J].江西理工大学学报,2020,41(5):73-79.
LI J H,WANG KUN.A low light image enhancement method based on convolutional neural network[J].Journal of Jiangxi University of Science and Technology,2020,41(5):73-79.
- [20] JI K,LEI W M,ZHANG W A deep Retinex network for underwater low-light image enhancement[J].Machine Vision and Applications,2023,34(6):122.
- [21] ZHANG Q W,XU Z,ZHANG P Y.Modulation scheme recognition using convolutional neural network[J].The Journal of Engineering,2019,2019(23):9075-9078.
- [22] RANJAN V,SHARMA U,NGUYEN T,et al.Learning to count everything[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Nashville,TN,USA.IEEE,2021:3393-3402.
- [23] LUO T G,GAO W,BELOTSERKOVSKY A,et al.VrsNet - density map prediction network for individual tree detection and counting from UAV images[J].International Journal of Applied Earth Observation and Geoinformation,2024,131:103923.
- [24] HE K M,ZHANG X Y,REN S Q,et al.Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).Las Vegas,NV,USA.IEEE,2016:770-778.
- [25] CHU P,LING H B.FAMNet:joint learning of feature,affinity and multi-dimensional assignment for online multiple object tracking[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV).Seoul,Korea (South).IEEE,2019:6171-6180.
- [26] KANG B Y,LIU Z,WANG X,et al.Few-shot object detection via feature reweighting[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV).Seoul,Korea (South).IEEE,2019:8419-8428.
- [27] WANG Q,ZHANG L,BERTINETTO L,et al.Fast online object tracking and segmentation:A unifying approach[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Long Beach,CA,USA.IEEE,2019:1328-1338.
- [28] VALMADRE J,BERTINETTO L,HENRIQUES J,et al.End-to-end representation learning for correlation filter based tracking [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).Honolulu,HI,USA.IEEE,2017:5000-5008.
- [29] JIANG Q,LI F,ZENG Z Y,et al.T-Rex2:Towards generic object detection via text-visual prompt synergy[EB/OL].2024:arXiv: 2403.14610.http://arxiv.org/abs/2403.14610.
- [30] KIRILLOV A,MINTUN E,RAVI N,et al.Segment anything[EB/OL].2023:arXiv:2304.02643.http://arxiv.org/abs/2304.02643
- [31] JOCHER G,CHAURASIA A,QIU J,et al.YOLOv8 by ultralytics [EB/OL].(2023-05-21)[2023-01-10].https://github.com/ultralytics/ultralytics.