doi:10.6041/j.issn.1000-1298.2025.09.046

基于无人机图像的大田结球生菜密度图计数方法

刘云玲[1]　李佳琪[1]　王　莹[1]　李东林[2]　宋坚利[3]

(1.中国农业大学信息与电气工程学院,北京 100083;2.哥伦比亚大学傅氏基金工程和应用科学学院,纽约 10027;
3.中国农业大学理学院,北京 100193)

摘要:在大田种植结球生菜结球期,通过计数进行产量估测对于评估经济效益、指导播种计划具有重要意义。但目前人工计数方法存在耗时长、工作量大等问题,本文提出了一种基于密度图回归的结球生菜轻量化计数网络,前端网络由卷积降采样模块和 CSP 结构堆叠而成以提取图像特征,通过降采样操作减小网络规模,并将不同层次特征进行拼接融合;后端网络采用扩张卷积结构,进一步提取图像特征并融合前端特征,增强模型特征表达能力,最后由生成头生成高质量密度图,通过积分得到计数结果。实验结果表明,本文提出的计数方法实现了较低的平均绝对误差(8.96)、均方根误差(14.21)、相对平均绝对误差(0.065 1)、相对均方根误差(0.103 2)以及较高的决定系数(0.974 9)和准确率(93.49%),优于同类其他模型 MCNN、CANNet、CSRNet、DSNet、MSPSNet、WHCNet、MLAENet;此外,本文模型在高计数准确性的同时保持了较低的资源占用,模型参数量和浮点运算次数分别为4.1×10^6和5.8×10^{10}。本文提出的模型准确率和模型轻量化上均实现了较为优越的性能,可为田间生菜产量估测提供技术方法。

关键词:结球生菜;无人机图像;密度图回归;计数;轻量化

中图分类号:S126　　**文献标识码**:A　　**文章编号**:1000-1298(2025)09-0557-09　　**OSID**:

Counting Method of Density Map for Field Head Lettuce Based on UAV Images

LIU Yunling[1]　LI Jiaqi[1]　WANG Ying[1]　LI Donglin[2]　SONG Jianli[3]

(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Fu Foundation School of Engineering and Applied Science*, *Columbia University*, *New York* 10027, *USA*
3. *College of Science*, *China Agricultural University*, *Beijing* 100193, *China*)

Abstract: It is of great significance to estimate the yield of head lettuce by counting during the heading stage in field planting for evaluating economic benefit, crop management and guiding seeding plan. Aiming at the problems of long time and heavy workload in current manual counting methods, a lightweight counting network of head lettuce was proposed based on density map regression. The front-end network was stacked by convolutional downsampling module and CSP structure to extract image features, and the network size was reduced by downsampling operation, and then features of different levels were splicing and fusion. The back-end network used an extended convolution structure to increase the receptive field without changing the size of the feature map, and further extract image features and fuse front-end features to enhance the feature representation ability of the model. Finally, a high quality density map was generated by the generating head, and the counting result was obtained by integrating. Experimental results showed that the proposed counting method achieved low mean absolute error (8.96), root mean square error (14.21), relative mean absolute error (0.065 1), relative root mean square error (0.103 2), high R^2 (0.974 9) and accuracy (93.49%), which was better than other models of the same kind, such as MCNN, CANNet, CSRNet, DSNet, MSPSNet, WHCNet and MLAENet. In addition, the proposed model maintained a low resource occupation while maintaining high counting accuracy, and the number of parameters and the number of floating-point operations of the model were 4.1×10^6 and 5.8×10^{10}, respectively. In general, the model proposed achieved relatively superior performance in both counting accuracy and model lightweighting, which can provide an effective techniques and methods for estimating lettuce yield in the field.

Key words: head lettuce; UAV images; density map regression; counting; lightweight

收稿日期:2024-06-19　修回日期:2024-08-22

基金项目:国家重点研发计划项目(2023YFD2001202)和现代农业产业技术体系建设专项资金项目(CARS-23-D02)

作者简介:刘云玲(1976—),女,副教授,博士,主要从事人工智能技术农业应用和农业信息化研究,E-mail:lyunling@163.com

0 引言

在收获期对大田种植结球生菜进行快速计数,对产量估测[1]、评估经济效益[2]、改善作物种植管理[3-5]等具有重要意义。目前田间生菜计数方式通常是在收获时进行人工计数,一般情况下,高畦种植生菜定植行距为 30 ~ 40 cm,种植密度为 60 000 ~ 75 000 株/hm^2[6],人工计数方法费时费力。传统的基于图像处理的计数方法主要依赖于形态学处理技术,例如阈值分割、边缘检测和形态学运算等[7-9]。这些方法通过提取目标形态特征进行目标分割和计数,适用于结构较为清晰、目标分布较为均匀的场景。在复杂背景、高密度重叠或光照变化较大的情况下,这类方法鲁棒性和泛化能力较弱,容易受到噪声干扰,从而影响计数精度,模型泛化性不强。

近年来,随着计算机视觉技术快速发展,出现了基于深度学习计数模型,相比于传统图像处理方法,这类方法能够提取图像高级特征,有更优越的计数能力。在深度学习计数方法中,基于目标检测的计数方法主要通过检测框进行识别[10-17],这类方法能够精准地定位个体目标,适用于目标大小较均匀、目标间遮挡较少的应用场景。在高密度场景下,目标检测方法可能会出现漏检或重叠目标难以区分的问题。此外,基于深度学习的计数方法还包括密度图回归计数方法。相比目标检测计数方法,其将检测框标注改为点标注,更适用于处理具有密度高、目标小、有遮挡特点的计数任务。基于密度图的计数方法通过学习从图像到密度图的映射关系,使用积分获得计数总和。密度计数研究最早开始于人群计数领域,ZHANG 等[18]采用多列卷积网络来适应目标尺度变化,并提出了生成几何自适应高斯核密度图方法,但多列网络使得其存在模型参数量和计算量较大的问题;CSRNet 网络[19]前端用于特征提取,后端增大感受野进一步丰富特征,具有良好的性能;CAO 等[20]建立编码器-解码器结构网络来适应复杂的计数任务,编码器用来提取多尺度特征,解码器通过 1 组转置卷积生成高分辨率密度图,表现出良好的计数性能。DAI 等[21]针对网路分支数限制导致尺度变换能力有限的问题,提出包含密集扩展卷积块的 DSNet 网络,在公开数据集上实现了良好的效果;针对人群图像中背景干扰和尺度变化问题,陈江川等[22]以细粒度提取多尺度特征,有效改善复杂场景计数效果,验证了模型准确性。在基于密度图的农作物计数研究方面,刘云玲等[23]通过改进 MCNN 和 CSRNet 网络结构实现麦穗计数,网络平均准确率为 81.9%;其他一些研究融合上下文特征[24-27]、引入注意力机制[28-29]、提高密度图质量[30],上述方法在保证计数准确性的同时需要占用较多的计算资源,或在追求模型轻量化而影响了计数精确性。

在生菜自动检测方面,ZHANG 等[31]采集多个品种盆栽直立生菜 9 个生长时期的图像,提出了一种改进 YOLO v5s 的模型,完成了多生长时期的室内生菜植株计数;LI 等[32]提出了一种针对温室水培生菜幼苗检测方法,平均精度为 86.2%。这些计数方法主要针对室内小规模种植生菜,相比温室栽培作物,室外种植是更常见的种植方式,田间作物种植存在密度大,数量多、环境复杂、种植面积大等特点,本文从模型高效化和轻量化两个角度出发,提出一个大田种植结球生菜密度图计数网络模型。

1 数据预处理

1.1 数据来源

实验数据来源于北京市延庆结球生菜种植区域(图 1),使用大疆 Mavic 3M 型航测无人机进行图像采集[33],将图像裁剪后,每幅图像为 1 024 像素 × 1 024 像素,共 382 幅图像,生菜数量最少的图像有 15 颗生菜,最多有 673 颗。平均每幅图像有 142.5 颗生菜,生菜总数共 54 436 颗。

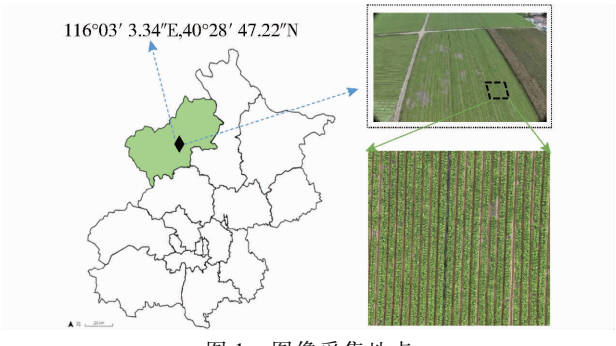


图 1 图像采集地点

Fig. 1 Location of image acquisition

1.2 数据标注

在结球生菜球心进行点标注,相比于方框标注方式,点标注方式能够降低标注成本,对于密集聚集的数据样本,点标注可避出现框重叠问题,更易区分样本点,图 2 为结球生菜数据点标注示例。

1.3 生成密度图

生成密度图类型为自适应核的高斯密度图[18],相较于固定高斯核,几何自适应高斯核有助于自适应地确定每个目标样本的参数,能够有效避免拍摄角度、距离等因素导致样本尺度不一造成的参数难以确定的问题。通过高斯核 G_{σ_i} 卷积可获取连续密



图 2　点标注示例

Fig. 2　Examples of dot annotations

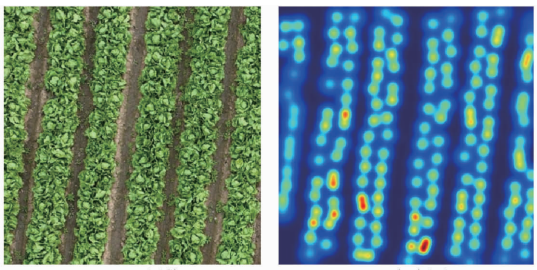


图 3　密度图示例

Fig. 3　Example of density map

度图，最终密度图计算式为

$$F(x)=\sum_{i=1}^{N_l}\delta(x-x_i)G_{\sigma_i}(x) \tag{1}$$

其中

$$\sigma_i=\beta\bar{d}^i \tag{2}$$

式中　N_l——生菜总数

x_i——结球生菜中心坐标

$\delta(x-x_i)$——图像中第 i 个生菜中心坐标

σ_i——二维高斯分布标准差

$G_{\sigma_i}(x)$——自适应高斯核函数

β——增益系数，取 0.3

$\bar{d}^i$——目标样本与其 k 个近邻之间平均距离

图 3 为生菜 RGB 图像生成几何自适应高斯核密度图像效果。

2　基于密度回归的的轻量化计数模型

2.1　模型结构

所提出的生菜密度图计数框架如图 4 所示，整个网络框架分为 3 部分：前端网络、后端网络、生成头。前端网络用于提取特征，前端网络由 3×3 卷积和 CSP 结构模块堆叠而成，保证模型特征提取能力。此外，为实现模型轻量化，使用降采样减少模型通道数，通过拼接操作整合多层特征，提高模型多尺度特征提取能力。拼接后特征输入到后端网络中进行进一步的特征提取，后端网络由 4 个扩张卷积层组成，扩张率为 2。最后，生成头生成高质量预测密度图，通过积分获取最终计数结果。

2.2　前端网络

田间场景复杂，为了使模型对目标的边界敏感，模型主干采用串行多尺度分支结构，在有限的目标图像质量下尽可能地获取更多上下文信息。前端主干网络输入流程为：输入图像首先通过 2 个 3×3 卷积，特征图尺寸分别变为 $(H/2,W/2)$、$(H/4,W/4)$，后经过 1 个 C2f[34] 模块，特征图尺寸保持不变，并在旁路对输出特征进行额外降采样操作；通过 1 个 3×3卷积模块和一个 C2f 模块后，特征图尺寸变为 $(H/8,W/8)$，同时在旁路对输出的特征进行通道卷

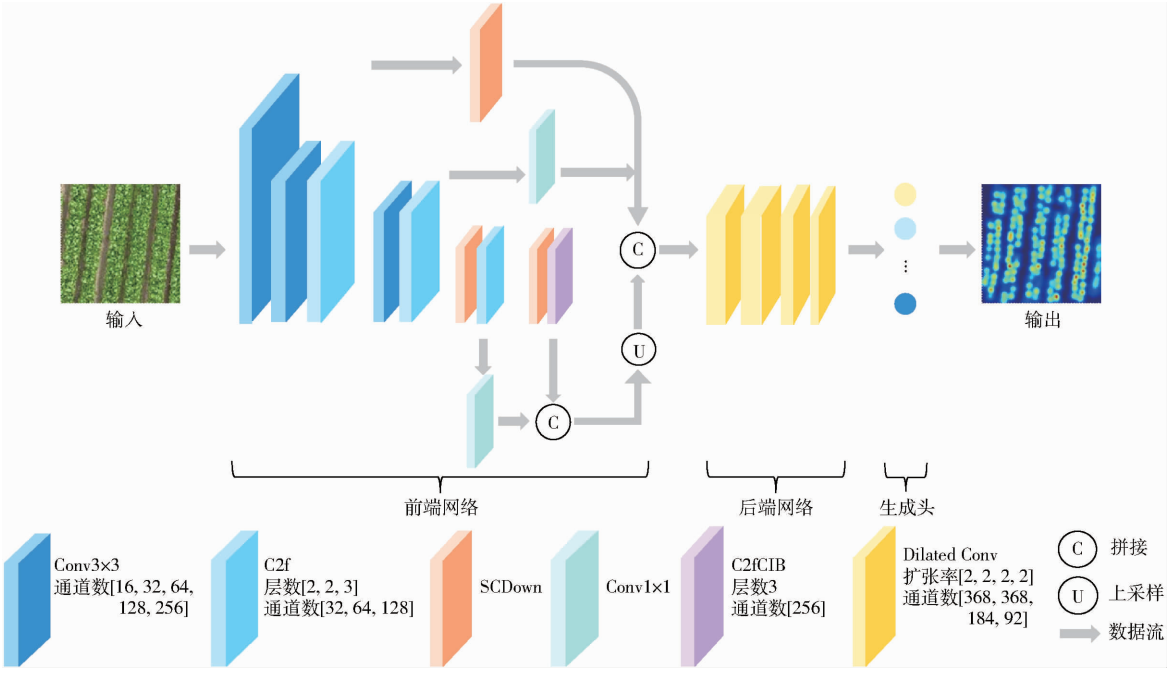


图 4　模型框架

Fig. 4　Model structure

积以减少通道数；接着，前端网络经过一个 SCDown[35] 模块和一个 C2f 模块，特征图尺寸变为（$H/16$，$W/16$），旁路将输出特征经过通道卷积后，进入前端第 4 部分：经过 1 个 SCDown 模块和 1 个 C2fCIB[35] 模块，特征图尺寸保持（$H/16$，$W/16$）不变；第 3 部分经过通道卷积的特征与第 4 部分输出特征在通道维度上拼接后，与前两个通道过滤后特征图尺寸进行匹配，经过前端 4 层网络通道数变化为[32，64，128，256]。

前端网络主干由 3×3 卷积与 CSP 结构模块堆叠而成，相比更大的卷积核，3×3 卷积核参数量更少的同时能捕捉到丰富图像特征。降采样模块使用空间-通道分离降采样（SCDown）。SCDown 模块结构如图 5 所示，由 1 个 1×1 卷积和 1 个 3×3 卷积组成，步长分别为 1 和 3，SCDown 模块将缩小特征和增加通道的操作分离，能够在减少计算成本的保持特征提取能力，从而完成高效降采样操作。



图 5 SCDown 结构

Fig. 5 SCDown module

大田生菜种植密度高，生菜目标之间不易区分，需借助浅层特征定位目标，并且结球生菜尺寸不一。因此为了能够更有效识别出低对比度目标，在保持模型轻量化的同时获取丰富的多尺度特征信息，前端特征提取网络采用 CSP 结构的特征融合模块，促进模型对小物体、低对比度目标的检测。图 6、7 为 C2f 模块与 C2fCIB 模块，其中 C2f 模块包含两个 CGH 卷积层。

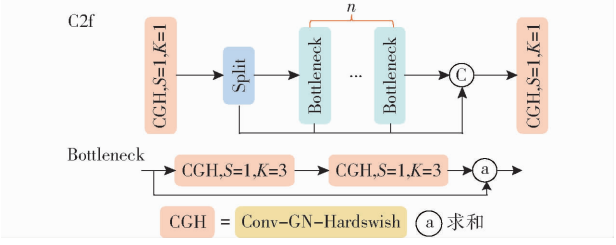


图 6 C2f 结构

Fig. 6 C2f module

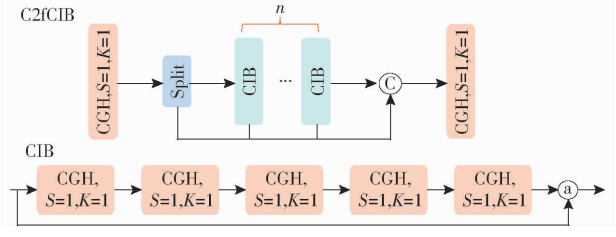


图 7 C2fCIB 结构

Fig. 7 C2fCIB module

经过第 1 个 CGH 模块后，特征图被拆分进入 Bottleneck 模块获取更多的特征信息，随后将经过 Bottleneck 后的特征图拼接以增强模型特征表达能力。由于 C2f 模块结构相对简单，因此在计算资源有限的情况下，可以有效降低模型计算量和复杂度，提高模型运行效率。C2fCIB 模块将 C2f 模块中的 Bottleneck 替换为一种紧凑倒置块（Compact inverted block，CIB）的结构，该结构采用深度卷积进行空间特征提取，并采用逐点卷积进行跨通道的信息整合，能够获得生菜图像细节特征，有助于生菜个体目标区分。

在经过前端 4 个模块后，将旁路中富含纹理特征的局部浅层信息与具有图像上下文信息的高级特征进行融合，浅层特征有助于识别和定位小目标，深层特征提供了图像全局语义信息，多尺度特征融合有助于模型学习不同尺度权重，进而区分生菜目标，增强模型分辨能力。先降采样后融合操作保证了模型轻量化。

前端网络激活函数采用由 HOWARD 等[36] 提出的 h－swish 函数，其采用分段计算减少了内存访问次数，降低了等待时间成本，并运用简单线性函数，能够有效降低计算开销，计算式为

$$\text{h-swish}(x) = x\frac{\text{ReLU6}(x+3)}{6} \tag{3}$$

其中

$$\text{ReLU6} = \min(6, \max(0, x)) \tag{4}$$

2.3 后端网络

模型后端网络由 4 层扩张卷积层组成，扩张率为 2，以保持特征图尺寸（$H/8$，$W/8$）不变，通道数分别为[368，368，184，92]。

后端采用扩张卷积层扩大感受野，并将前端网络拼接获得的特征进行融合，提取更精细的图像特征。一般来说，增加模型感受野对于提升模型高级特征提取能力具有重要意义，然而依靠下采样增加感受野的传统方法减弱了模型对微小目标的关注程度，而扩张卷积通过在卷积核元素间入空洞来增加感受野，无需堆叠卷积层来捕获多种特征，在不增加计算量的同时达到相似的感受野效果。扩张卷积层实际感受野 R 为

$$R = K + (K-1)(D-1) \tag{5}$$

式中 K——扩张卷积核和尺寸

D——扩张率

每个卷积核元素之间增加 $D-1$ 的间隔，对于 K 个元素，扩展间隔出现 $K-1$ 次，因此整体扩展效果为 $(K-1)(D-1)$，实际感受野为 R。

2.4 归一化方法

将原 C2f 模块中的批归一化（Batch normalization）操作改为组归一化（Group

normlization)操作。图 8 为 2 种归一化方法的可视化示例，N 为批轴，C 为通道轴，(H,W)为空间轴，将蓝色方块部分采用相同均值和方差归一化。常规的批归一化操作通过在批处理内均值和方差对特征进行归一化，可以加速深层网络收敛。实验批处理设置为 1，批归一化往往在批处理尺寸(Batch size)较大的情况下才具有良好的表现，批处理尺寸过小会导致数据估计不准确，进而增加模型的误差。针对该问题，WU 等[37]提出了组归一化，组归一化不依赖任务的批处理尺寸，通过在多个组内进行归一化进而提供更稳定的训练性能，基于此，本文将卷积层后原本使用的批归一化改为组归一化操作。

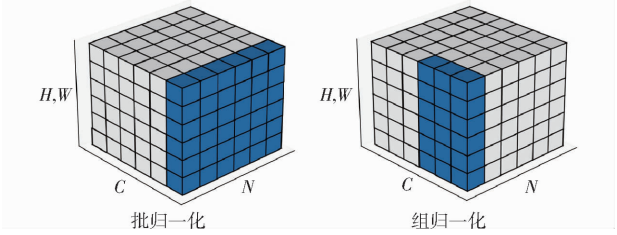


图 8　归一化方法可视化示例

Fig. 8　Visualization example of normalization methods

3　实验与结果

3.1　实验配置

基于 Ubuntu 22.04.3 LTS 操作系统和 PyTorch 框架实现，实验迭代周期为 200，初始学习率为 1×10^{-6}，将数据集按照比例 3∶1∶1 分为训练集、验证集和测试集，采用 Adam 优化器优化参数，所有实验均在 NVIDIA GeForce RTX 4090 D 显卡上进行训练。

3.2　损失函数

为评估真实值与模型预测值之间的差距，采用均方差损失函数作为损失函数，均方差损失 L 计算式为

$$L=\frac{1}{M}\sum_{i=1}^{M}|x_{gt}-x_p|^2 \tag{6}$$

式中　M——样本数量　　x_{gt}——真实值

x_p——预测值

3.3　评价指标

使用平均绝对误差(Mean absolute error, MAE)、均方根误差(Root mean squared error, RMSE)、相对平均绝对误差(Relative mean absolute error, rMAE)、相对均方根误差(Relative root mean squared error, rRMSE)和决定系数 R^2 作为指标对模型进行评判，MAE、RMSE、rMAE、rRMSE 越小表示计数性能越好，决定系数 R^2 能够评估回归模型解释能力，反映模型对数据的拟合程度，越接近 1，表明模型拟合程度越高。此外，准确率(Accuracy, ACC)能够反映模型预测值与真实值之间的一致程度，ACC 越高表明计数精确度越高，ACC 计算式为

$$V_{ACC}=1-\frac{1}{M}\sum_{i=1}^{M}\frac{|C_i^{GT}-C_i^{P}|}{C_i^{GT}}\times100\% \tag{7}$$

式中　V_{ACC}——准确率

C_i^{GT}——第 i 幅图像中真实生菜数量

C_i^{P}——第 i 幅图像中预测生菜数量

在评估模型轻量化程度的指标方面，模型参数量表示可训练参数数量，与网络复杂程度相关，参数量越大，网络复杂程度越高。浮点运算次数反映模型一次前向传播过程中浮点运算次数，运算次数越多，计算复杂度和计算资源需求越高，因此使用参数量和浮点运算次数作为评价指标。

3.4　对比实验

选取计数领域较为经典及表现较好的 MCNN[20]、CANNet[38]、CSRNet[19]、DSNet[21] 和 MSPSNet[27]模型和目前用于大田作物(小麦、玉米穗)性能较好的模型 WHCNet[30] 和 MLAENet[29]，共 7 个对比模型进行实验，结果如表 1 所示。由表 1 可知，本文提出模型 MAE、RMSE、rMAE 和 rRMSE 为 8.96、14.21、0.065 1 和 0.103 2，低于其他 7 种模型，R^2 和 ACC 为 0.974 9 和 93.49%，优于其他 7 种模型。

表 1　不同计数模型实验结果对比

Tab. 1　Comparison of experimental results for different counting models

模型	平均绝对误差	均方根误差	相对平均绝对误差	相对均方根误差	决定系数	准确率/%
MCNN	17.43	30.35	0.126 6	0.220 4	0.885 3	87.34
CANNet	15.30	28.16	0.111 1	0.204 5	0.901 3	88.89
CSRNet	9.44	17.02	0.068 6	0.123 6	0.964 0	93.14
DSNet	10.10	16.70	0.083 1	0.130 0	0.965 3	91.69
MSPSNet	9.85	17.60	0.078 6	0.148 9	0.961 5	92.14
WHCNet	11.57	20.76	0.085 1	0.179 8	0.946 4	91.49
MLAENet	11.62	16.29	0.090 3	0.131 9	0.967 0	90.97
本文模型	8.96	14.21	0.065 1	0.103 2	0.974 9	93.49

表 2 为各个模型参数量和浮点运算次数比较结

表 2　参数量和浮点运算次数比较结果

Tab. 2　Comparison results on params and FLOPs

模型	参数量	浮点运算次数
MCNN	1.3×10^5	2.8×10^{10}
CANNet	1.8×10^7	4.6×10^{11}
CSRNet	1.6×10^7	4.3×10^{11}
DSNet	2.1×10^7	5.1×10^{11}
MSPSNet	2.2×10^7	1.1×10^{12}
WHCNet	1.0×10^7	3.4×10^{11}
MLAENet	1.4×10^7	4.0×10^{11}
本文模型	4.1×10^6	5.8×10^{10}

果,和其他方法相比,MCNN 是 8 种模型中参数量和浮点运算次数最低的模型,但由于其浅层网络设计限制了计数性能,在计数指标上效果不佳,本文提出模型参数量和浮点运算次数仅次于 MCNN 模型,但在计数性能上取得了最佳的结果。

3.5 可视化分析

为了直观反映不同模型在遥感生菜图像上的计数效果,图 9 为各个模型在同一图像上的计数效果。图 9a 为生菜 RGB 原图,图 9b 为标注后生成的几何自适应高斯密度图,图 9c ~ 9j 分别为 MCNN、CANNet、CSRNet、DSNet、MSPSNet、WHCNet、MLAENet 和本文模型预测密度。从图 9 可以看出,MLAENet 模型和 MCNN 模型密度图存在条状红色高密度区域,密度点之间粘连,区分度低。CSRNet 和在其基础上改进的 CANNet 的密度图中目标边界呈网格状,影响了密度图质量。相较于其他模型,本文模型生成的密度图质量相对更高,预测数量(473)最接近真实值(478)。

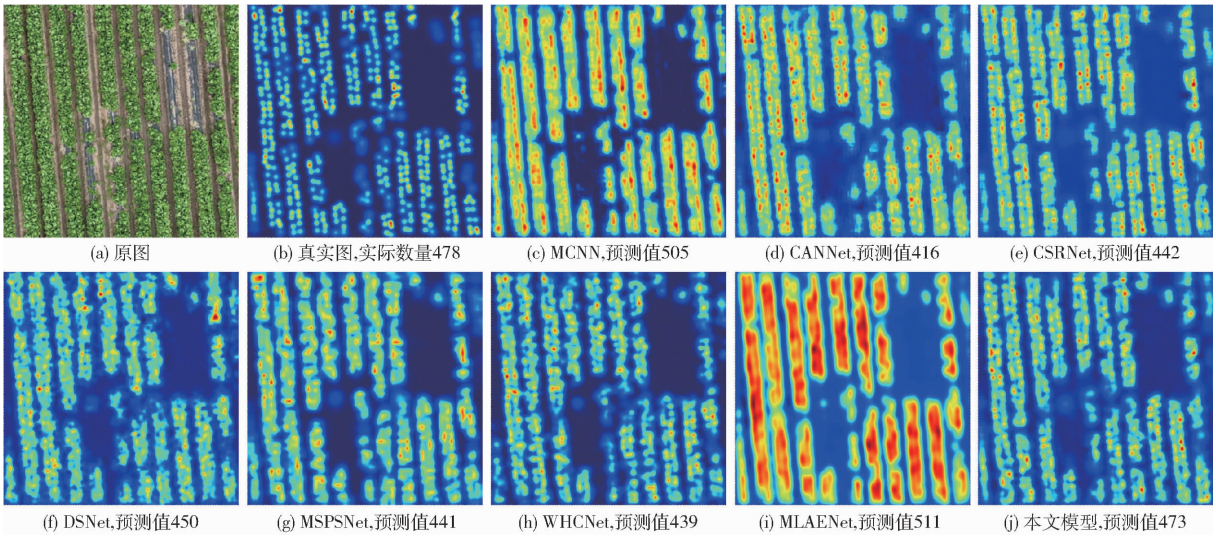


图 9 可视化密度计数对比

Fig. 9 Comparisons of visual density counts

3.6 消融实验

为了验证网络结构中所引入模块的有效性,进行消融实验,结果如表 3 所示。由表 3 可知,在模型适当位置加入 3 种模块后,网络性能有所提升,其中 MAE、RMSE、rMAE、rRMSE 4 个指标随着模块引入而降低,MAE 从 10.59 降至 8.96,RMSE 从 21.73 降至 14.21,此外 rMAE 和 rRMSE 均有所降低。同时,模型 R^2 和 ACC 随着模块的引入而提高,表明了所引入模块的有效性。

表 3 消融实验结果

Tab. 3 Results of ablation experiment

C2f	C2fCIB	SCDown	平均绝对误差	均方根误差	相对平均绝对误差	相对均方根误差	决定系数	准确率/%
-	-	-	10.59	21.73	0.073 8	0.142 5	0.941 2	92.62
√	-	-	10.28	18.07	0.074 7	0.131 2	0.959 3	92.53
-	√	-	10.25	18.90	0.074 4	0.137 2	0.955 6	92.56
-	-	√	10.43	18.16	0.075 8	0.131 9	0.958 9	92.42
-	√	√	10.10	17.05	0.073 3	0.123 8	0.963 8	92.67
√	-	√	9.29	16.17	0.067 5	0.117 4	0.967 5	93.25
√	√	-	9.99	16.36	0.072 5	0.118 8	0.966 7	92.75
√	√	√	8.96	14.21	0.065 1	0.103 2	0.974 9	93.49

注:“-”表示未使用;“√”表示使用。

4 分析与讨论

大田结球生菜种植环境具有作物规模大、种植密等特点,导致了目标计数过程中的目标点密集,目标样不易区分等挑战。本文提出了一种基于密度图回归的大田结球生菜计数方法,通过引入 CSP 结构,提取图像精细特征,以增加模型对小目标的辨别能力,通过设计浅层特征与深层特征拼接结构,增强图像上下文信息,提高模型在生菜尺寸不一时的计数能力;后端采用扩张卷积增大感受野,既融合前端拼接特征,又进一步增强了网络对特征感知能力,在

不增加计算资源同时丰富细节特征信息，提高模型计数性能。此外，针对目前大多模型需要占用较高计算资源来达到较强的计数能力的问题，从轻量化角度出发，通过对前端网络特征进行通道简化来降低模型参数量，最终实现计数性能和模型轻量化平衡。针对模型所引入的模块进行了消融实验，消融实验结果表明 C2f、C2fCIB、SCDown 3 个模块的有效性，随着模块增加，模型在各个指标上的结果逐渐达到最佳。

通过与 MCNN、CANNet、CSRNet、DSNet、MSPSNet、WHCNet 和 MLAENet 模型对比实验可知，本文模型在 MAE、RMSE、rMAE、rRMSE、R^2 和 ACC 共 6 个指标均实现最优结果，分别为 8.96、14.21、0.065 1、0.103 2、0.974 9 和 93.49%。模型参数量为 4.1×10^6，浮点运算次数为 5.8×10^{10}，轻量化网络结构为未来在嵌入式设备上进行模型部署提供了可能。综合表 1 和表 2 看，以对比模型中计数性能较好的 CSRNet 模型为例，CSRNet 模型使用 VGG 网络结构作为前端，保证了模型特征提取能力，但也使得 CSRNet 模型占用了较多计算资源；由表 2 可知，MCNN 模型参数量和浮点运算次数均最低，但表 1 结果反映出 MCNN 模型在各项计数指标上的结果不佳。相比之下，本文模型创建了卷积-轻量化模块交叠前端网络，增强模型特征表达能力，使用通道降采样保证模型的轻量化，后端网络进一步融合前端的多尺度特征，保证计数低误差的同时降低计算资源占用。图 10 为不同模型参数与 MAE 的关系，相比其他 7 种模型，本文模型更接近坐标轴的原点，MAE 和参数量都更小，证明了本文模型在准确性和速度上实现了良好的平衡。

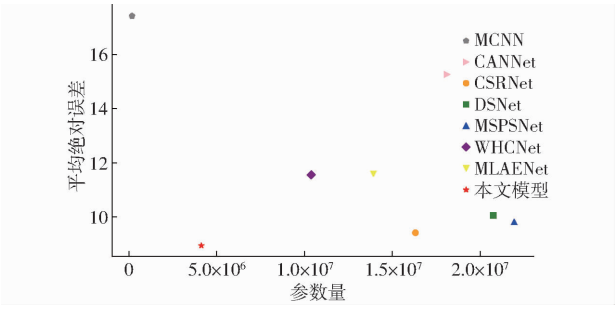


图 10　参数量-平均绝对误差散点

Fig. 10　Params - MAE scatter plot

5　结束语

基于大田结球生菜无人机遥感图像进行计数方法研究，提出了一种基于密度图回归的计数方法，主要分为前端网络、后端网络和生成头 3 个部分。前端进行浅层特征提取，采用 CSP 结构在保持轻量化的同时融合多种特征信息，此外，前端特征经过通道过滤的降采样操作控制参数量，并拼接多尺度特征信息，提高了模型特征表达能力。后端网络为了进一步融合前端网络拼接特征，采用扩张卷积层扩大感受野，关注图像细节特征，最后生成头输出预测密度图。相比其他 7 种模型，本文模型在计数性能上取得了最优结果，有效平衡了模型性能与模型规模，能够为大田结球生菜计数提供技术方法。

参　考　文　献

[1] SHATILOV M V, RAZIN A F, IVANOVA M I. Analysis of the world lettuce market[C]//IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2019, 395(1): 012053.

[2] MAJA M RANKO Č, LJILJANA N, et al. Ground cover management and farmyard manure effects on soil nitrogen dynamics, productivity and economics of organically grown lettuce (*Lactuca sativa* L. subsp. secalina)[J]. Journal of Integrative Agriculture, 2017, 16(4): 947 - 958.

[3] SHAFI U, MUMTAZ R, GARCÍA-NIETO J, et al. Precision agriculture techniques and practices: from considerations to applications[J]. Sensors, 2019, 19(17): 3796.

[4] SISHODIA R P, RAY R L, SINGH S K. Applications of remote sensing in precision agriculture: a review[J]. Remote Sensing, 2020, 12(19): 3136.

[5] TORKY M, HASSANEIN A E. Integrating blockchain and the internet of things in precision agriculture: analysis, opportunities, and challenges[J]. Computers and Electronics in Agriculture, 2020, 178: 105476.

[6] 范双喜，刘超杰，韩莹琰，等. 北京生菜产业发展现状及展望[J]. 蔬菜，2021(增刊)：12 - 17.
FAN Shuangxi, LIU Chaojie, HAN Yingyan, et al. The development status and prospect of lettuce industry in Beijing[J]. Vegetables, 2021(Supp.): 12 - 17. (in Chinese)

[7] 刘哲，黄文准，王利平. 基于改进 K-means 聚类算法的大田麦穗自动计数[J]. 农业工程学报，2019，35(3)：174 - 181.
LIU Zhe, HUANG Wenzhun, WANG Liping. Field wheat ear counting automatically based on improved K-means clustering algorithm[J]. Transactions of the CSAE, 2019, 35(3): 174 - 181. (in Chinese)

[8] 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)：234 - 239.
FAN Mengyang, MA Qin, LIU Junming, et al. Counting method of wheatear in field based on machine vision technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(Supp.): 234 - 239. (in Chinese)

[9] 杜世伟，李毅念，姚敏，等. 基于小麦穗部小穗图像分割的籽粒计数方法[J]. 南京农业大学学报，2018，41(4)：742 - 751.

DU Shiwei, LI Yinian, YAO Min, et al. Counting method of grain number based on wheatear spikelet image segmentation[J]. Journal of Nanjing Agricultural University, 2018, 41(4): 742 - 751. (in Chinese)

[10] 王金鹏,何萌,甄乾广,等. 基于改进 COF - YOLOv8n 的油茶果静态与动态检测计数方法[J]. 农业机械学报,2024,55(4): 193 - 203.
WANG Jinpeng, HE Meng, ZHEN Qianguang, et al. *Camellia oleifera* fruit static and dynamic detection counting based on improved COF - YOLOv8n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 193 - 203. (in Chinese)

[11] 肖伸平,赵倩颖,曾甲元,等. 基于 YOLO - DCL 的复杂环境油茶果遮挡检测与计数研究[J]. 农业机械学报, 2024,55(10): 318 - 326,480.
XIAO Shenping, ZHAO Qianying, ZENG Jiayuan, et al. *Camellia oleifera* fruits occlusion detection and counting in complex environments based on improved YOLO - DCL[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10): 318 - 326,480. (in Chinese)

[12] SHAHID R, QURESHI W S, KHAN U S, et al. Aerial imagery-based tobacco plant counting framework for efficient crop emergence estimation[J]. Computers and Electronics in Agriculture, 2024, 217: 108557.

[13] LI J, MAGAR R T, CHEN D, et al. SoybeanNet: transformer-based convolutional neural network for soybean pod counting from unmanned aerial vehicle (UAV) images[J]. Computers and Electronics in Agriculture, 2024, 220: 108861.

[14] 肖克辉,杨宏,苏章顺,等. 基于改进 YOLOv5 的蝴蝶兰花朵识别与计数[J]. 中国农机化学报,2023,44(11): 155 - 161,209.
XIAO Kehui, YANG Hong, SU Zhangshun, et al. Identification and counting of phalaenopsis flowers based on improved YOLOv5[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(11): 155 - 161. (in Chinese)

[15] ZHOU B, LIN X, ZHOU J, et al. An improved lightweight parameters network for strawberry flowers detection[J]. IEEE Access, 2023, 11: 63761 - 63772.

[16] LIU Y, CEN C, CHE Y, et al. Detection of maize tassels from UAV RGB imagery with Faster R - CNN[J]. Remote Sensing, 2020, 12(2): 338.

[17] ZHANG Y, WANG H, XU R, et al. High-precision seedling detection model based on multi-activation layer and depth-separable convolution using images acquired by drones[J]. Drones, 2022, 6(6): 152.

[18] ZHANG Y, ZHOU D, CHEN S, et al. Single-image crowd counting via multi-column convolutional neural network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016: 589 - 597.

[19] LI Y, ZHANG X, CHEN D. CSRNet: dilated convolutional neural networks for understanding the highly congested scenes[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2018: 1091 - 1100.

[20] CAO X, WANG Z, ZHAO Y, et al. Scale aggregation network for accurate and efficient crowd counting[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 734 - 750.

[21] DAI F, LIU H, MA Y, et al. Dense scale network for crowd counting[C]// Proceedings of the 2021 International Conference on Multimedia Retrieval, 2021: 64 - 72.

[22] 陈江川,吴云韬,孔权. 基于 CBAM - Res2Net 的人群计数算法[J]. 武汉工程大学学报,2022,44(6): 664 - 669.
CHEN Jiangchuan, WU Yuntao, KONG Quan. Crowd counting algorithm based on CBAM - Res2Net[J]. Journal of Wuhan Institute of Technology, 2022, 44(6): 664 - 669. (in Chinese)

[23] 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 Yunling, ZHANG Pinge, WANG Qianhang, et al. Counting method for wheat spikes based on dilated multi column convolutional neural network[J]. Journal of Jilin Agricultural University, 2021, 43(2): 171 - 180. (in Chinese)

[24] 孙俊,杨锴锋,罗元秋,等. 基于无人机图像的多尺度感知麦穗计数方法[J]. 农业工程学报,2021,37(23): 136 - 144.
SUN Jun, YANG Kaifeng, LUO Yuanqiu, et al. Method for the multiscale perceptual counting of wheat ears based on UAV images[J]. Transactions of the CSAE, 2021, 37(23): 136 - 144. (in Chinese)

[25] YANG X, ZHOU W, YAN W, et al. CAGNet: coordinated attention guidance network for RGB - T crowd counting[J]. Expert Systems with Applications, 2024, 243: 122753.

[26] 申华磊,张洁,刘栋,等. 增强局部上下文监督信息的麦苗计数方法[J]. 农业机械学报,2023,54(7): 243 - 251,312.
SHEN Hualei, ZHANG Jie, LIU Dong, et al. Wheat seedling counting method with enhanced local contextual supervised information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 243 - 251, 312. (in Chinese)

[27] ZAND M, DAMIRCHI H, FARLEY A, et al. Multiscale crowd counting and localization by multitask point supervision[C]// IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2022: 1820 - 1824.

[28] BAI X, LIU P, CAO Z, et al. Rice plant counting, locating, and sizing method based on high-throughput UAV RGB images [J]. Plant Phenomics, 2023, 5: 0020.

[29] ZHENG H, FAN X, BO W, et al. A multiscale point-supervised network for counting maize tassels in the wild[J]. Plant Phenomics, 2023, 5: 0100.

[30] GUO H. Wheat head counting by estimating a density map with convolutional neural networks[EB/OL]. (2023 - 03 - 19).

[2023 - 07 - 01]. https://doi.org/10.48550/arXiv.2303.10542.
[31] ZHANG P, LI D. Automatic counting of lettuce using an improved YOLOv5s with multiple lightweight strategies[J]. Expert Systems with Applications, 2023, 226: 120220.
[32] LI Z, LI Y, YANG Y, et al. A high-precision detection method of hydroponic lettuce seedlings status based on improved Faster R - CNN[J]. Computers and Electronics in Agriculture, 2021, 182: 106054.
[33] RADOGLOU-GRAMMATIKIS P, SARIGIANNIDIS P, LAGKAS T, et al. A compilation of UAV applications for precision agriculture[J]. Computer Networks, 2020, 172: 107148.
[34] VARGHESE R, SAMBATH M. YOLO v8: a novel object detection algorithm with enhanced performance and robustness[C]// 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). IEEE, 2024: 1 - 6.
[35] WANG A, CHEN H, LIU L, et al. YOLOv10: real-time end-to-end object detection[J]. arXiv preprint arXiv: 2405. 14458, 2024.
[36] HOWARD A, SANDLER M, CHU G, et al. Searching for Mobilenetv3[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 1314 - 1324.
[37] WU Y, HEE K. Group normalization[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 - 19.
[38] LIU W, SALZMANN M, FUA P. Context-aware crowd counting[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5099 - 5108.

(上接第 556 页)

[28] 冯浩, 杨祯婷, 陈浩,等. 基于无人机多光谱影像的夏玉米 SPAD 估算模型研究[J]. 农业机械学报, 2022, 53(10): 211 - 219.
FENG Hao, YANG Zhenting, CHEN Hao, et al. Estimation of summer maize SPAD based on UAV multispectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(10): 211 - 219. (in Chinese)
[29] 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(3): 160 - 167.
CHENG Qian, XU Honggang, CAO Yinbo, et al. Grain yield prediction of winter wheat using multi-temporal UAV based on multispectral vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 160 - 167. (in Chinese)
[30] 韩文霆, 崔家伟, 崔欣,等. 基于特征优选与机器学习的农田土壤含盐量估算研究[J]. 农业机械学报, 2023, 54(3): 328 - 337.
HAN Wenting, CUI Jiawei, CUI Xin, et al. Estimation of farmland soil salinity content based on feature optimization and machine learning algorithms[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 328 - 337. (in Chinese)
[31] 韦春宇, 杜娅丹, 程智楷,等. 基于无人机遥感植被指数优选的覆膜冬小麦估产研究[J]. 农业机械学报,2024,55(4): 146 - 154,175.
WEI Chunyu, DU Yadan, CHENG Zhikai, et al. Yield estimation of mulched winter wheat based on UAV remote sensing optimized by vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(4):146 - 154, 175. (in Chinese)
[32] 韩建文, 冯春晖, 彭杰,等. 不同分辨率无人机多光谱影像的棉花叶面积指数估测研究[J]. 棉花学报, 2022, 34(4): 338 - 349.
HAN Jianwen, FENG Chunhui, PENG Jie, et al. Estimation of leaf area index of cotton from unmanned aerial vehicle multispectral images with different resolutions[J]. Cotton Science, 2022, 34(4): 338 - 349. (in Chinese)
[33] CHENG Z, GU X, ZHOU Z, et al. Enhancing in-season yield forecast accuracy for film-mulched wheat: a hybrid approach coupling crop model and UAV remote-sensing data by ensemble learning technique[J]. European Journal of Agronomy, 2024, 156:127174.
[34] ZOU M, LIU Y, FU M, et al. Combining spectral and texture feature of UAV image with plant height to improve LAI estimation of winter wheat at jointing stage[J]. Frontiers in Plant Science, 2024, 14: 1272049.