

基于三维点云的植株联合任务分割框架

汤继锐¹ 潘 丹² 刘立程¹ 彭 鸿³ 刘柏菁¹ 王家豪³

(1. 广东工业大学信息工程学院 广州 510006; 2. 广东技术师范大学电子与信息学院 广州 510665;

3. 海南大学信息与通信工程学院 海口 570228)

摘 要:传统的植株器官分割方法依赖经验选择阈值参数,而当前的深度学习浅层框架可能会导致植株重要的几何特征丢失,并难以有效整合植株的局部和全局特征。因此,提出了一个基于三维点云的植株器官分割网络(local global feature fusion segmentation network, LGF-SegNet)模型,通过引入双权重注意力机制模块和位置编码,更适合在植株点云数据中表达几何特征。在提出的框架的解码层引入特征聚合模块,融合植株点云的局部和全局特征,使得该框架能够关注植株的整体特征轮廓同时保留细节植物纹理(如茎和叶)。实验结果表明,提出的架构在语义分割的交并比、精确率和 F1 分数的平均值分别达到 85.76%、93.18%、91.08%,在实例分割的平均精确率、平均实例覆盖率以及平均实例加权覆盖率达到 85.27%、78.46%、79.63%,优于当前流行的植株点云分割任务中使用的深度学习网络架构,并适用于植株语义分割和实例分割的双重任务。这为后续的植株生长预测等研究奠定基础。

关键词:深度学习;三维点云;植株器官分割;特征融合;注意力机制

中图分类号: TP3 **文献标识码:** A **国家标准学科分类代码:** 520.604

Plant joint task segmentation framework based on 3D point cloud

Tang Jirui¹ Pan Dan² Liu Licheng¹ Peng Hong³ Liu Baijing¹ Wang Jiahao³

(1. School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China;

2. School of Electronics and Information, Guangdong Polytechnic Normal University, Guangzhou 510665, China;

3. School of Information and Communication Engineering, Hainan University, Haikou 570228, China)

Abstract: The traditional plant part segmentation methods rely on empirical selection of threshold parameters, while the current shallow deep learning framework may lead to the loss of important geometric features of the plant cloud, and it is difficult to effectively integrate the local and global features of the plant. Therefore, a plant part segmentation network was proposed on 3D Point Cloud (LGF-SegNet), which was more suitable for expressing geometric features in plant point-cloud data by introducing double-weighted attention mechanism module and location coding. A feature aggregation module was introduced into the decoding layer of the proposed framework to fuse the local feature and global feature of the plant point cloud, so that the framework could focus on the overall feature outline of the plant while preserving the detailed plant textures (such as stems and leaves). The experimental results show that the average of intersection ratio, precision and F1 score of semantic segmentation reach 85.76%, 93.18% and 91.08%, respectively. The mean precision, mean coverage and mean weighted coverage of instance segmentation reach 85.27%, 78.46% and 79.63%, the proposed architecture is better than the current deep learning network architecture used in the current plant point cloud segmentation task, and is suitable for the dual tasks of plant semantic segmentation and instance segmentation. This lay a foundation for the subsequent research on plant growth prediction.

Keywords: deep learning; 3D point cloud; plant part segmentation; feature fusion; attention mechanism

0 引言

植物表型是植物生长过程中,受基因和环境因素决定或影响的,反映植物结构及组成、植物生长发育过程及结果的全部物理、生理、生化特征和性状。植物的形态表型包括植物的叶、茎、果实等,其中叶器官构成了植物形态表型的大多数性状。在现代农业科学研究中,植物表型的获取对研究植物生长发育、生理代谢、环境适应性等方面有非常重要的意义。传统的农作物表型性状测量由人工手动完成,客观性差,难以满足研究需要,为了能自动、准确、高通量地对植物形态表型参数进行测量,基于三维点云的植株器官分割方法为其提供了关键的技术手段。

基于三维点云的分割方法逐步成为农业技术研究中的热点问题,喻奎慎等^[1]对激光扫描获取的点云数据分别使用支持向量机、近似支持向量机和广义特征值近似支持向量机作分类器并使用图割理论进行再分割得到枝叶分离。彭程等^[2]对番茄点云利用拉普拉斯变换修正后分割为茎秆和叶片子骨架,再通过 Mean Shift 聚类分割叶片和叶柄。任彪等^[3]使用 K-means 聚类分割算法计算点云曲率值并结合点云形态确定 K 值,再人工确定聚类中心实现花瓣点云分割。苏宝峰等^[4]基于运动恢复结构算法重建三维植株点云,然后将阈值分割去噪的点云使用 K-means 聚类算法实现实例分割。杨琳等^[5]利用八叉树根据点云的空间位置和法向量信息进行初始分割得到超体素,然后将点云下采样后建议 K-D 数索引,根据局部特征得到点云簇,最后聚类得到实例分割结果。赖亦斌等^[6]采用区域增长算法、边缘提取算法、超体素聚类算法以及凹凸性的方法分割黄瓜、烟草、玉米的三维植株点云。El-nashef 等^[7]提出了一种基于一阶和二阶张量的分割算法,实现植株点云的茎叶分割,并基于密度的聚类算法实现对单个叶片的分割。Li 等^[8]提出一种小面过度分割和小面区域生长的密集植物点云的单叶分割方法并在温室观赏性植物上进行单叶分割。朱超等^[9]采用基于骨架的玉米植株茎叶分割方法,在成熟期植株点云实现骨架提取、子骨架分解以及器官点云分割。林承达等^[10]使用基于欧氏距离的聚类分割得到田间作物每个单体植株的点云数据。Li 等^[11]对多视图玉米图像序列使用运动恢复结构(structure from motion, SFM)算法进行三维重建,然后使用聚类算法、颜色滤波算法和体素滤波算法处理玉米植株点云得到玉米植株模型,最后通过区域增长算法进行对单个叶片和茎的分割。然而,上述传统点云分割方法具有较明显的局限性。基于边缘检测方法不仅容易丢失三维几何信息,且易出现过分割结果;基于区域增长的分割方法过度依赖人工,需要预选种子点或者人工设置阈值,客观性较差;基于特征聚类的分割方法需要计算特征空间中点的距离,在大型密集点云中,计算点的特征信息具有较大的复杂度,时间成本会明显增大^[12-13]。

随着深度学习的发展,将深度学习和点云分割结合的

方法逐渐成为热门的研究方向。目前基于深度学习的点云处理方法有基于多视图的方法,基于体素的方法和基于点的方法^[14]。Li 等^[15]对体素化并且最远点采样后的烟草、番茄、高粱植株点云用 PSegNet 网络分割出植株的叶和茎。Ni 等^[16]采用 Mask R-CNN 网络模型从二维图像中分割出单个蓝莓,并建立 2D-3D 对应关系,以获得浆果的数量、体积和成熟度。Shi 等^[17]使用全卷积网络(fully convolutional network, FCN)和 R-CNN 网络对植株二维图像进行语义分割和实例分割,然后将不同视点结合起来实现三维点云分割。Yu 等^[18]提出 LFPNet,结合三维空间变换网络(spatial transformer network, STN)、特征提取、特征聚合和反卷积模块,对水果植株点云实例分割。

目前影响植株分割的问题主要包括点云数据非结构化,不规则且无序;目前常用点云分割任务数据集为大型室内场景数据集 S3DIS 和 3D CAD 模型数据集 ShapeNet,市面上缺乏有标注的三维植株点云数据集;在植株点云的深度学习分割框架中,体素化的处理方法会消耗大量内存,而且采用稀疏卷积虽然减少内存消耗,但会导致点云的许多空间结构信息丢失^[19];在当前植株分割网络框架中,并未考虑到聚合特征和全局特征的结合,由于网络的层数越深会越聚焦于局部特征而丢失了全局特征,因此会引发各种分割过拟合带来的精度下降的问题。

针对上述问题,本文首先搭建了一个针对植株数据的多角度采集平台,用于采集植株的各不同角度二维图像再进行三维重建以构建植株的三维点云数据。我们形成了一个植株点云数据库以方便后人进行植株分割以及生长预测的相关研究。然后针对现有点云深度学习分割框架的缺陷,本文提出了一个联合语义分割以及实例分割任务的植株分割框架(local global feature fusion segmentation network, LGF-SegNet)。该框架可以做到分别自动化执行两项不同的分割任务。针对几何空间架构的信息损失,本文设计了一个双权重的注意力机制模块(dual-weight attention module)将植株点云数据进行联合位置编码来使网络框架跟聚焦于植株点云数据的几何信息。针对全局特征损失的问题,该文参考了 U-Net^[20]跳跃连接的残差思想设计了特征聚合模块(feature-fuse module)可以使得网络框架学习到局部特征与全局特征之间的依赖关系,极大增强了模型架构的鲁棒性。

1 数据获取及预处理

本文以广州某花卉培养基地的彩叶芋植株为实验对象,通过多视图植株图像采集平台获取植株的不同角度的若干张二维图像。

将植株在同一时段拍摄得到的若干张不同角度二维图像使用 SFM 算法重建出三维植株点云图像,获取的点云数据不可避免存在一定的噪声^[21]。为消除离群点和多余背景点,对重建出的点云数据进行统计滤波、颜色滤波和体素滤波处理,去除噪点后降采样以减少后续计算负

担^[22]。最后,通过点云处理软件 CloudCompare 对点云数据进行语义标记和实例标记。其中,语义标记是将点云中的每个点标记为叶、茎、花盆中的一类,实例标记则是将不同的叶片区分开,标记为不同实例,得到 1 000 个植株点云数据。本文对点云数据采用随机旋转、缩放和加入高斯噪声等数据增强操作,最后获得 2 700 个植株点云数据,以 1:3 的比例划分为测试集和训练集,并且使用测试集作为验证集。部分彩叶芋植株点云如图 1 所示。



图 1 部分彩叶芋点云

2 植株点云分割网络

本文的植株分割框架流程如图 2 所示,提出的网络 LGF-SegNet 实现如图 2 的联合任务植株分割步骤,结构如图 3 所示,主要由位置编码模块、注意力模块、空间金字塔池化模块、上采样模块、下采样模块构成。整体结构由局部特征编解码和全局特征编解码两个并行支路和特征聚合模块组成。网络以含有 N 个点, C 个特征维度的点云作为输入,其中 $C=9$,包括坐标 (x, y, z) ,颜色 (r, g, b) ,法向量 (n_x, n_y, n_z) 。首先,对输入点云进行位置编码;然后分成两个支路,点云全局特征编解码支路和点云局部特征编解码,两支路分别得到局部解码特征 F_l 和全局解码特征 F_g 。最后,将这两个特征输入到特征聚

合模块,再由两个分支输出得到语义和实例预测结果。以下对网络中的重要模块进行分析。

2.1 双权重自注意力

传统注意力机制实现如下:

$$Att(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

$$Q = MLP_1(x), K = MLP_2(x), V = MLP_3(x) \quad (2)$$

在网络浅层的时候,由于每个点没有被学习到足够的特征来获得点之间的相似性,点的几何关系变得更加重要。因此,本文的注意力机制改进了自注意力,在其基础上增加了一个权重矩阵,并加入到网络中,称为双权重自注意力层。本文的双权重注意力机制权重矩阵实现如下:

$$W = QK_1^T \oplus QK_2^T \quad (3)$$

$$K_1 = MLP(x), K_2 = MLP(x_p) \quad (4)$$

式中: $\oplus$ 表示矩阵拼接操作; x 是网络上一层的输出; x_p 是位置编码模块的输出。

点云全局特征编解码支路(图 3)的层次注意力块由 4 个串联的注意力层组成,每一层的输入都是上一个注意力层的输出,最后将 4 个注意力层的输出拼接起来。有利于网络学习到点的语义特征,得到层次注意力块的输出。

2.2 空间金字塔池化

在传统最大池化或者平均池化,由于池化窗口大小固定,只能得到固定维度大小的全局特征信息。为此,本文采用空间金字塔池化,通过不同大小的多窗口池化形式以获得不同维度的全局信息,实现多尺度特征提取,可提高算法精度和鲁棒性。

$$F(x_1, \dots, x_N) = MLP_{x=x_1, \dots, x_N} [c(p(f, s_1), \dots, p(f, s_n))] \quad (5)$$

式中: f 表示输入的特征; s_n 表示池化窗口尺寸; p 表示最大池化; c 表示将不同尺度的池化输出结果拼接起来。最后通过 MLP 完成空间金字塔池化。当输入 $N \times D$ 的点云特征时,池化窗口尺寸分别为 $\frac{N}{s_1}, \dots, \frac{N}{s_n}$,最后聚合不同维度的特征得到 $(s_1 + \dots + s_n) \subseteq D$ 维度的特征。

2.3 下采样层

下采样层首先通过 FPS(farthest point sampling)算

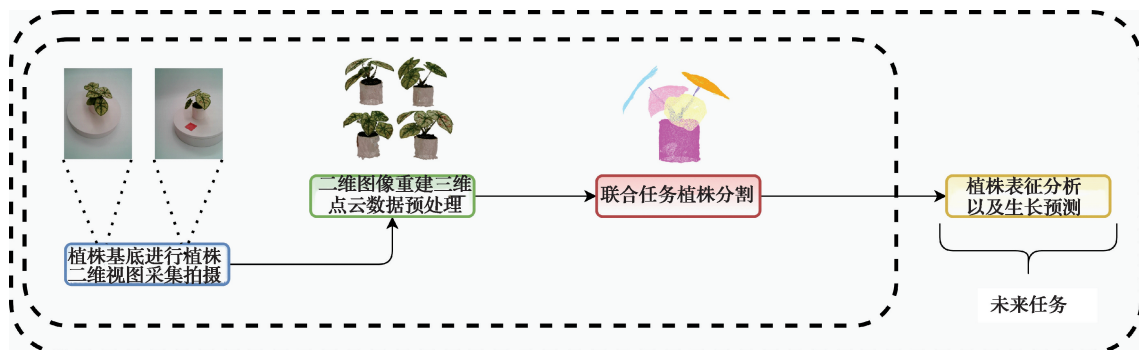


图 2 植株分割框架




图3 LGF-SegNet 网络结构

法进行采样,将输入点集降低到更小的规模。与随机采样相比,首先它能更好地覆盖到整个点集并且采样结果均匀。其次,通过分层逐步筛选点,在保留最初的局部信息的同时,提升感受野。最后采用球查询算法,查找所有中心点的邻点,得到每个中心点的一个局部邻域。相比KNN算法,球查询保证了每个邻域的区域大小,使得局部区域在全局空间上更具有泛化性。

2.4 上采样层

在LGF-SegNet的局部特征提取支路中,随着网络的下采样层逐层降低点云密度,从4096个点下采样到16个点。虽然网络获得更加抽象的点云特征信息,但由于分割任务需要保证输入输出的点数是相同,所以在网络后半部分对点云进行了4次上采样操作。采用基于距离的插值和跨层跳跃连接的分层传播策略,该方法类似反卷积操作。上采样过程如式(6)、(7)所示,使用基于 k 近邻的逆距离加权平均, $k=3$ 。

$$f^{(i)}(\mathbf{x}) = \frac{\sum_{i=1}^3 w_i(\mathbf{x}) f_i^{(j)}}{\sum_{i=1}^3 w_i(\mathbf{x})} \quad (6)$$

$$w_i(\mathbf{x}) = \frac{1}{(\mathbf{x} - \mathbf{x}_i)^2} \quad (7)$$

式中: $\mathbf{x}_i$ 是 $\mathbf{x}$ 的近邻点。

2.5 特征聚合模块

特征聚合模块是融合局部特征和全局特征的关键模块。三维点云是高度结构化数据,算法的性能会被噪声的变化所影响,全局信息的聚合首先可以提高算法的鲁棒性,其次产生更抽象和复杂的特征表示,有利于网络更好地学习点云特征,提高分割性能。在图3中,将网络特征解码后分别得到的局部特征 F_l 和全局特征 F_g 输入到特征聚合模块中,特征融合操作如式(8)所示,特征聚合模块结构如图4所示。

$$F_g = f(p(f(F_l) + F_g) + F_l) \quad (8)$$




图4 特征聚合模块

2.6 损失函数和评估指标

LGF-SegNet模型的损失函数是最后两个支路输出的损失之和:

$$L = L_{sem} + L_{ins} \quad (9)$$

式中: L_{sem} 为语义类别预测损失; L_{ins} 为实例嵌入损失。 L_{sem} 定义为普通交叉熵损失:

$$L_{sem} = - \sum_{i=1}^N \sum_{j=1}^K p(\mathbf{x}_i = j) \ln q(\mathbf{s}_j = j) \quad (10)$$

式中: N 为点的数量; K 为语义类别数量; $p(\mathbf{x}_i = j)$ 为点 $\mathbf{x}_i$ 被预测为 j 类的概率。

实例嵌入损失定义为3个损失的加权和,如式(11)所

示,在本文实验中 $\alpha = 1, \beta = 1, \gamma = 0.001$ 。其中, L_c 用来衡量不同点是否属于同一实例对象,使同个实例的点聚集起来,其计算方式如式(12)所示。其中, I 是实例个数, N_i 为该实例包含的点数, u_i 是该实例中所有点在多维空间的均值, e_j 为点 j 的特征向量, δ_v 为边界阈值, $[x]_+$ 表示 $\max(0, x)$ 。 L_d 用于排斥不同实例的点,如式(13)所示。其中, $2\delta_d$ 表示两个实例之间的距离。 L_r 为正则化损失,如式(14)所示,表示回归实例质心。

$$L_{ins} = \alpha L_c + \beta L_d + \gamma L_r \quad (11)$$

$$L_c = \frac{1}{I} \sum_{i=1}^I \frac{1}{N_i} \sum_{j=1}^{N_i} [\|u_i - e_j\|_1 - \delta_v]_+^2 \quad (12)$$

$$L_d = \frac{1}{I(I-1)} \sum_{i=1}^I \sum_{j=1, i \neq j}^I [2\delta_d - \|u_i - u_j\|_2]_+^2 \quad (13)$$

$$L_r = \frac{1}{I} \sum_{i=1}^I \|u_i\|_2^2 \quad (14)$$

2.7 网络参数

网络训练超参数设置如下:训练批量大小 batch size 为 16,初始学习率为 0.001,衰减率为 0.5,动量大小为 0.9,优化器为 Adam,迭代次数 epoch 为 80。本研究的所有实验均在同一台计算机完成,计算机环境为 AMD EPYC 7302 16-Core Processor CPU、主频 3.00 GHz, RTX 3090 GPU, Linux CentOS 8 系统,深度学习框架为 Pytorch 1.6.0。

3 实验分析

3.1 评估指标

为了评估植株点云分割网络 LGF-SegNet 的性能,本文对语义分割性能采用的评估指标为交并比(IoU)、精确率(Prec)和 F1 分数,其计算方法如下:

$$IoU = \frac{TP}{TP + FP + FN} \times 100\% \quad (15)$$

$$Prec = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

$$F1 = \frac{2 \times Prec \times Rec}{Prec + Rec} \times 100\% \quad (17)$$

对于实例分割,本文采用的评估指标为平均精确率(mPrec)、平均实例覆盖率(mCov)和平均加权实例覆盖率(mWCov)。其中 mCov 表示实例交并比的均值,计算如式(18)所示;mWCov 表示每个实例交并比和它的真值点数在全实例真值点数的比例相乘,计算如式(19)所示。

$$mCov(\mathbf{G}, \mathbf{P}) = \frac{1}{|I|} \sum_{j=1}^I \max(IoU(g, p)) \quad (18)$$

$$mWCov(\mathbf{G}, \mathbf{P}) = \sum_{j=1}^I w_j \max(IoU(g, p)) \quad (19)$$

式中: $\mathbf{G}$ 表示实例的预测点集; $\mathbf{P}$ 表示实例的标签点集; g 表示一个实例预测的点集; p 表示一个实例的标签点集; $|I|$ 为集合中元素数量。

3.2 语义分割效果对比

为评估 LGF-SegNet 对植株点云的语义分割性能,本

文将其与其他目前流行的点云深度学习语义分割网络进行对比。在评估指标为交并比、精确度和 F1 分数的基础上进行定量对比分析,结果如表 1~3 所示。部分植株点云的语义分割效果如图 5(a)所示。

表 1 本文方法与其他网络语义分割效果交并比对比 (%)

方法	均值	叶	茎	花盆
PointNet ^[23]	73.84	80.54	63.42	77.56
PointNet++ ^[24]	81.64	82.45	72.81	89.65
DGCNN ^[25]	77.73	83.18	64.53	85.49
JSNet ^[26]	75.31	77.23	66.32	82.39
PCT ^[27]	81.51	81.56	79.72	83.26
RPNet ^[28]	81.70	81.48	76.35	87.26
LGF-SegNet	85.76	84.85	80.34	92.09

表 2 本文方法与其他网络语义分割效果精确率对比 (%)

方法	均值	叶	茎	花盆
PointNet ^[23]	80.98	90.79	65.43	86.72
PointNet++ ^[24]	91.05	97.23	76.18	99.74
DGCNN ^[25]	86.20	95.14	66.05	97.40
JSNet ^[26]	85.65	90.23	71.64	95.08
PCT ^[27]	91.27	95.03	84.45	94.33
RPNet ^[28]	91.30	96.27	81.47	96.17
LGF-SegNet	93.18	97.03	84.42	98.11

表 3 本文方法与其他网络语义分割效果 F1 分数对比 (%)

方法	均值	叶	茎	花盆
PointNet ^[23]	83.76	91.35	70.60	89.33
PointNet++ ^[24]	90.67	98.14	76.04	97.84
DGCNN ^[25]	89.14	96.74	74.33	96.34
JSNet ^[26]	89.22	97.31	73.64	96.72
PCT ^[27]	88.15	95.64	72.36	96.45
RPNet ^[28]	89.74	97.29	74.06	97.86
LGF-SegNet	91.08	98.01	77.21	98.03

本文提出的网络模型在语义分割的效果上几乎在所有的指标都优于其他网络,并且 3 个评估指标上的平均值均优于其他网络。叶的分割效果优于茎,茎的分割效果明显低于另外两类,导致这个现象的主要原因是茎形状细长不像叶片一样宽大,所包含的点数比叶子部分更少,并且,茎的部分夹在花盆和叶子中间,涉及茎叶连接处和茎花盆连接处,两个连接处每个点的预测错误都会对茎的分割效果产生比另外两者更大的影响而导致分割指标下降即茎容易出现分割错误的点占茎部位包含的点的占比较大。而花盆是一个圆柱体,形状规则,且占据的点多,所以容易分割并且在花盆与茎的连接处分割错误的点对花盆整体

的分割指标影响较小,因此花盆部分的分割指标明显大于其他部分。

3.3 实例分割效果对比

植株器官的实例分割结果数据如表 4 所示。植株器官实例分割主要的难点在于,当植株叶片数较多而导致叶片点云重叠的时候,叶片之间点云相接的地方可能会被错误地分类为另一个叶片的点云,其次,新叶太小并且离其他叶片太近可能会导致该叶片被归类为相邻叶片。尽管如此,相比其他方法,本文取得了更优的结果且所有指标均达到 75%以上,3 个评估指标均高于其他分割网络。部分植株点云的实例分割结果如图 5(b)所示。

表 4 本文方法与其他网络实例分割效果对比 (%)			
方法	$mPrec$	$mCov$	$mWCov$
SGPN ^[29]	77.48	65.92	65.13
JSNet ^[26]	79.24	70.34	71.58
PCT ^[27]	84.33	77.52	78.82
SoftGroup ^[30]	81.62	75.26	76.59
LGF-SegNet	85.27	78.46	79.63




图 5 (a)语义分割效果;(b)实例分割效果

3.4 消融实验与分析

为了验证双权重注意力机制优于传统自注意力机制,局部特征与全局特征的融合使得网络具有更好地分割性能,本文设置了单独的消融实验来验证。在该实验中,在双权重自注意力不采用的时候使用的是传统自注意力机制;在不采用局部全局特征融合模块时候,分别单独使用局部特征提取支路和全局特征提取支路。语义分割消融实验结果如表 5 所示,实例分割消融实验结果如表 6 所示。

表 5 语义分割的消融实验结果 (%)					
方法			指标		
双权重自注意力	局部特征	全局特征	IoU	$Prec$	F1 分数
	✓	✓	84.22	92.03	89.45
✓	✓		82.06	92.35	89.56
✓		✓	83.51	91.96	90.07
✓	✓	✓	85.76	93.18	91.08

表 6 实例分割的消融实验结果 (%)					
方法			指标		
双权重自注意力	局部特征	全局特征	$mPrec$	$mCov$	$mWCov$
	✓	✓	83.35	76.63	77.42
✓	✓		82.06	75.43	76.12
✓		✓	81.33	76.05	77.45
✓	✓	✓	85.27	78.46	79.63

实验结果表明,双权重自注意力和特征融合的方法均对网络的分割效果有所提高。从表 5 和 6 可以发现,特征聚合模块的提出,在语义分割消融实验中,交并比、精确率和 F1 分数提高了 1%~3%;在实例分割消融实验中,平均精确率、平均实例覆盖率和平均加权实例覆盖率提高了 2%~4%。而双权重自注意力机制的加入,使语义分割的交并比、精确率和 F1 分数提高了 0.5%~2%,实例分割的平均精确率、平均实例覆盖率和平均加权实例覆盖率提高了 1%~3%。双权重自注意力机制使网络利用位置编码的输出可以关注到点云的几何特征,因而网络的性能有所提高;而将局部特征和全局特征融合,有利于网络学习到更丰富、更抽象的点云特征。

4 结 论

植株器官分割是实现植株表型参数自动化获取的关键技术。本文针对植株拍摄平台获取的若干张不同角度植株二维图像,进行三维点云重建并数据预处理得到实验所需的彩叶芋三维植株点云数据集。然后,本文提出一个植株器官分割网络 LGF-SegNet,其分为两个分支,分别得到对植株点云的语义分割和实例分割。最终实现一个植株点云自动化分割框架。

在 LGF-SegNet 中,本文提出了双权重注意力模块,结合位置编码模块的输出,有效增强植株点云几何特征信息的表达,解决了网络在浅层的时候,点云的几何信息丢

失而网络却还未学习到足够的点之间的相似性的,从而导致分割网络整体的分割性能下降的问题。双权重注意力模块有效地增加了该网络对植株点云的分割性能。在网络解码端,本文提出了一个特征聚合模块,将网络两个支路分别提取到的全局特征和局部特征融合,有效解决了由于网络变深丢失全局特征,带来的分割过拟合导致植株器官分割精度下降的问题,并且增强网络对抽象特征的学习和泛化性。对语义分割的交并比、精确率和 F1 分数的平均值分别达到 85.76%、93.18%、91.08%,对实例分割的平均精确率,平均实例覆盖率以及平均实例加权覆盖率达到 85.27%、78.46%、79.63%,实验结果表明,在该彩叶芋点云上的分割效果均优于近年来的经典分割植株点云分割网络。

此外,重叠的叶片和新生的小叶片往往无法被较好地分割,所以,下一步工作将重点关注如何有效地分割重叠或者新生的叶片。为推动农业科学研究,计划未来将引入其他种类的植株加入到数据集中,改进设计更具有泛化性的,适合植株点云的分割框架,为农业科学研究中表型参数自动化提取,植株生长预测奠定基础。

参考文献

- [1] 喻焱慎,云挺,杨绪兵. 基于激光点云数据的植物器官多维特征分割方法[J]. 数据采集与处理, 2015, 30(5): 1054-1061.
- [2] 彭程,李帅,苗艳龙,等. 基于三维点云的番茄植株茎叶分割与表型特征提取[J]. 农业工程学报, 2022, 38(9): 187-194.
- [3] 任彪,陆玲. 基于 PCL 三维点云花瓣分割与重建[J]. 现代电子技术, 2022, 45(12): 149-154.
- [4] 苏宝峰,刘易雪,王琮,等. 基于三维点云的叶面积估算方法[J]. 农业机械学报, 2019, 50(12): 240-254.
- [5] 杨琳,翟瑞芳,阳旭,等. 结合超体素和区域增长的植物器官点云分割[J]. 计算机工程与应用, 2019, 55(16): 197-203.
- [6] 赖亦斌,陆声链,钱婷婷,等. 植物三维点云分割[J]. 应用科学学报, 2021, 39(4): 660-671.
- [7] ELNASHEF B, FILIN S, LATI R N. Tensor-based classification and segmentation of three-dimensional point clouds for organ-level plant phenotyping and growth analysis[J]. Computers and Electronics in Agriculture, 2019, 156: 51-61.
- [8] LI D, CAO Y, TANG X, et al. Leaf segmentation on dense plant point clouds with facet region growing[J]. Sensors, 2018, 18(11): 3625.
- [9] 朱超,苗腾,许童羽,等. 基于骨架的玉米植株三维点云果穗分割与表型参数提取[J]. 农业工程学报, 2021, 37(6): 295-301.
- [10] 林承达,韩晶,谢良毅,等. 田间作物群体三维点云柱体空间分割方法[J]. 农业工程学报, 2021, 37(7): 175-182.
- [11] LI Y, LIU J, ZHANG B, et al. Three-dimensional reconstruction and phenotype measurement of maize seedlings based on multi-view image sequences[J]. Frontiers in Plant Science, 2022, 13: 974339.
- [12] 王丽欢,任雨,刘建,等. 基于 B-PointNet++ 的地下电缆工井点云语义分割模型[J]. 国外电子测量技术, 2023, 42(2): 88-94.
- [13] 殷宗琨,江明,柏受军,等. 基于 2D 预处理的点云分割和测量研究[J]. 电子测量与仪器学报, 2022, 36(9): 53-63.
- [14] GUO Y, WANG H, HU Q, et al. Deep learning for 3d point clouds: A survey[J]. IEEE transactions on pattern analysis and machine intelligence, 2020, 43(12): 4338-4364.
- [15] LI D, LI J, XIANG S, et al. PSegNet: Simultaneous semantic and instance segmentation for point clouds of plants[J]. Plant Phenomics, 2022, DOI:10.34133/2022/9787643.
- [16] NI X, LI C, JIANG H, et al. Three-dimensional photogrammetry with deep learning instance segmentation to extract berry fruit harvestability traits[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 171: 297-309.
- [17] SHI W, VAN DE ZEDDE R, JIANG H, et al. Plant-part segmentation using deep learning and multi-view vision[J]. Biosystems Engineering, 2019, 187: 81-95.
- [18] YU Q, YANG H, GAO Y, et al. LFPNet: Lightweight network on real point sets for fruit classification and segmentation[J]. Computers and Electronics in Agriculture, 2022, 194: 106691.
- [19] 陈睿星,吴军,赵雪梅,等. 顾及长尾分布的机载 LiDAR 点云 CNN 语义分割[J]. 仪器仪表学报, 2023, 44(7): 282-295.
- [20] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference. Springer, 2015: 234-241.
- [21] 彭宝江,钟若飞,孙海丽,等. 面向 DEM 构建的点云四叉树和 R 树混合索引研究[J]. 应用科学学报, 2018, 36(4): 644-654.
- [22] 胡平安,黎浩民,李光平,等. 基于几何仿射与注意力的三维激光点云分类[J]. 电子测量技术, 2023, 46(12): 163-171.
- [23] QI C R, SU H, MO K, et al. Pointnet: Deep

- learning on point sets for 3d classification and segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 652-660.
- [24] QI C R, YI L, SU H, et al. PointNet++: Deep hierarchical feature learning on point sets in a metric space [C]. Conference and Workshop on Neural Information Processing Systems, 2017.
- [25] WANG Y, SUN Y, LIU Z, et al. Dynamic graph CNN for learning on point clouds [J]. ACM Transactions on Graphics (tog), 2019, 38(5): 1-12.
- [26] ZHAO L, TAO W. JSNet: Joint instance and semantic segmentation of 3d point clouds [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12951-12958.
- [27] GUO M H, CAI J X, LIU Z N, et al. PCT: Point cloud transformer[J]. Computational Visual Media, 2021, 7(2): 187-199.
- [28] CHEN X, LOU X, BAI L, et al. Residual pyramid learning for single-shot semantic segmentation [J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(7): 2990-3000.
- [29] WANG W, YU R, HUANG Q, et al. SGPN: Similarity group proposal network for 3d point cloud instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 2569-2578.
- [30] VU T, KIM K, LUU T M, et al. Softgroup for 3d instance segmentation on point clouds [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 2708-2717.

作者简介

汤继锐, 硕士研究生, 主要研究方向为三维点云图像分割。

E-mail: 504891791@qq.com

刘立程(通信作者), 博士, 副教授, 主要研究方向为人工智能在图像处理方面的技术研究与应用。

E-mail: 361556773@qq.com