

基于点云深度学习的果树枝条实例分割算法

蒋心恺¹ 吴金涛² 王锐² 王明亮¹ 杨浩^{3,4}

JIANG Xinkai WU Jintao WANG Rui WANG Mingliang YANG Hao

摘要

果树枝条的实例分割对于探索果树表型至关重要。然而，在形态结构复杂、实例密度高的情况下，使用现有方法精确分割枝条仍具有挑战性。提出了一种结合局部相似性的新型三维深度学习方法，以实现果树枝条精确的语义和实例分割。所提出的方法首先利用 PointNet++ 网络模型对果树点云数据进行了高精度的语义分割，有效区分果树的主干、一级枝、二级枝和三级枝。随后，将提取的语义特征划分为多个局部区域，以降低计算复杂度，并为每个局部区域点生成一个相似性矩阵，以捕捉局部相似性信息。最后，使用双链损失函数对相似性矩阵进行优化，以完善实例分割结果。实验结果验证了此方法在准确分割果树枝条方面的有效性。实验结果表明此方法不仅省去了劳动密集型的实地测量，还为获取果树的表型参数提供了有价值的信息。

关键词

点云；枝条实例分割；三维深度学习；相似性矩阵

doi: 10.3969/j.issn.1672-9528.2024.04.002

0 引言

果树枝条是果树根系水分吸收和蒸腾作用的桥梁，是为树叶、芽、花及果实提供营养的主要器官^[1]。从单株尺度上来看，果树枝条的结构直接影响果树的光能截获量，进而影响果树进行光合作用的整个过程。从果园尺度上来看，果树枝条的结构直接影响果园表面的摩擦力（表面阻力），进而影响果园与大气圈、水圈和岩石圈之间进行物质和能量交换的整个过程。因此，及时、准确地获取果树枝条表型信息能够为果园的智能化管理提供重要的数据支持，对果园灌溉管理病害防治、增产及提高果品品质具有重要意义^[2]。作为果树管理与科学研究的基础数据，果树枝条表型参数主要包括枝条类别、数量、位置、直径、长度、夹角和体积等。目前获取这些表型参数的常规方法是人工测量与估算法，这些方法普遍存在主观性、低效性和破坏性，且人工成本较高^[3]。因此，有必要对果树表型参数的自动提取开展进一步的研究，为后期智慧果园的建立提供精确数据支撑。

近地遥感技术的发展为全面监测果园生产提供了有效手段，而果园生产被公认为是推进高产、高效、环保型现代农业实践的关键^[4-5]。三维激光扫描技术（即光探测与测距技术，LiDAR）能够快速获取数据，拥有高分辨率和强大的视觉解读能力等优势^[6]，为快速获取植物的三维轮廓数据提供了新方法，其在提取结构参数方面的优越性已通过大量成功案例得到证实^[7-11]，是获取果树枝条表型信息的理想方法^[12]。然而，果树形态结构的复杂性意味着果树的点云数据不可避免地包含不同类别的枝条，包括主干和各级枝条^[13]，从复杂点云数据中提取特定枝条的精确表型信息具有挑战性。

点云数据的非结构化特性使传统的数据分析和表示方法无法完全解决复杂而抽象的问题，如实例分割^[14]。近年深度学习技术的出现，为从高维、广泛的非结构化数据中提取复杂的结构信息提供了重要手段^[15-16]。目前，三维点云深度学习与激光雷达技术的结合已成为植物表型领域的突出研究重点^[17-18]，而在室外环境中精确获取结构形态复杂的果树表型信息仍是一项具有挑战性的工作，包括点云数据质量低、数据量大、枝条分布密集等问题^[19]。

大多数现有方法采用 mini-PointNet 网络模块来提取点云特征^[20]。这种方法利用多层感知机对邻域内离散点的特征进行编码，在提供精确的局部信息方面面临挑战。针对此问题，本文提出了一种基于局部相似性测量的果树枝条实例分割方法。该方法不仅能准确捕捉局部特征，还能将局部特征与全局特征结合，实现对复杂果树枝条的精确分割。

1. 南京信息工程大学计算机学院 江苏南京 210044

2. 南京信息工程大学软件学院 江苏南京 210044

3. 北京市农林科学院农业农村部农业遥感机理与定量遥感重点实验室 北京 100097

4. 国家农业信息化工程技术研究中心 北京 100097

[基金项目] 国家自然科学基金青年基金（62102188）；江苏省自然科学基金青年基金（BK20210647）；中国博士后科学基金（2021M700076）；江苏省高等学校自然科学研究项目（23KJB520020）

1 基本原理

本文研究的目標是以蘋果樹的三維點雲為輸入，預測每個點在枝條層面的實例標籤，然後根據每個實例提取樹枝的表型性狀，方法的工作流程如圖 1 所示。首先用受 PointNet^[21] 啟發的前向反饋特徵提取網絡處理點雲，提取語義特徵，再將輸入點雲劃分為多個局部區域（基於球查詢策略），並通過微小的 PointNet 框架提取這些區域的點特徵，將其與相應的語義特徵聯繫起來，形成局部區域點特徵。然後從每個局部區域抽取 n 個局部區域點特徵（基於最遠點採樣策略），形成相似性矩陣。最後，經過非極大值抑制（NMS）操作，合併相似組，並為每個點分配一個實例標籤。




圖 1 語義特徵學習模塊

1.1 語義特徵學習

具有不同語義標籤（主干 MT、一級枝 1st-B、二級枝 2nd-B、三級枝 3rd-B）的分支易被識別為不同的分支實例，因此，本文提出方法第一步就是提取語義特徵。本文將三維點雲輸入 PointNet++ 框架^[22]，以學習局部和全局特徵，然後通過多個多層感知器（MLP）和一個 Dropout 層防止過擬合，從而獲得語義特徵。這些語義特徵通過語義損失 L_{sem} （點交叉熵）^[23] 來學習，其有助於區分具有不同語義標籤的分支。該模塊的相關網絡細節如圖 1 所示，其中 N 是輸入點的數量， $N \times 3$ 表示每個點的輸入特徵，即三維坐標。通過該模塊，可獲得輸入點的語義特徵。

1.2 局部區域採樣

語義信息可用於識別分支順序，而無法直接用於區分同一類別的分支實例。與語義分割的重點不同，實例分割更側重同一類別中不同對象的標籤分配問題^[24]。由於果樹的生長特點，枝條實例分割的任務難度較大，尤其是數量大、密度高的二級枝和三級枝。

在果樹點雲中，相距較近的两个點比相距較遠的點更有可能屬於同一个實例。本文選取完整的果樹點雲 D 和二級枝點雲 S （其中 $S \subset D$ ），發現：

$$|D-S|/|D| > 99.23\% \quad (1)$$

$$\max(\{d \mid d = \|p_i - p_j\|_2, (p_i, p_j \in S)\}) / f < 0.4$$

式中： $||$ 計算列表中點的個數， $\|_2$ 表示兩點之間的距離， p_i 表示點雲中的點， f 是 D 中兩點之間的最遠距離。

通過上述統計，總結出枝條的實例分割問題中，考慮整棵樹會存在大量無意義的點。此外，同一實例中各點之間的距離較小，特別是二級枝和三級枝。在此基礎上，根據點的位置將輸入點雲劃分為多個局部區域，能為準確的實例分割提供有價值的數據。

按本文方法，首先從輸入點雲（ $B \times N \times 3$ ）中隨機採樣（訓練：隨機採樣，測試：最遠點採樣），再用查詢方法在採樣點周圍構建一組局部區域，其工作原理是在採樣點半徑 r 範圍內隨機選取 K 個點（本文中， r 和 K 分別設置為 0.45 和 1024）。除生成大小為 $(B \cdot d) \times K \times 3$ 的局部點集 C^l 之外，該層還有以下輸出。

(1) 局部語義特徵 F_{sem}^l （與 C^l 相對應），大小為 $(B \cdot d) \times K \times 64$ ，用於後續的特徵連接。

(2) 局部語義標籤 P_{sem}^l （與 C^l 相對應），大小為 $(B \cdot d) \times K \times 4$ ，用於計算損失值。

(3) 局部點索引 I^l （與 C^l 相對應），大小為 $(B \cdot d) \times K$ ，用於記錄點在局部區域的全局位置（該信息由球查詢自動生成）。

(4) 局部真實值（Ground Truth），包括語義標籤 G_{sem}^l 大小為 $(B \cdot d) \times K \times 4$ ，實例標籤 G_{ins}^l 大小為 $(B \cdot d) \times K$ ，用於計算損失值。

其中， B 是輸入的批量大小， d 是局部區域的數量， K 是局部區域的點數。

本文進一步對局部細化特徵提取層進行操作。輸入局部點集 C^l ，使用微小的 PointNet++ 架構提取局部區域的點特徵（表示為 F_p^l ）。如上所述，從這些離散的局部區域提取能代表整棵果樹語義信息的特徵較為困難，而語義特徵的損失將直接影響實例分割的準確性。因此，本文將點特徵 F_p^l 與相應的局部語義特徵 F_{sem}^l 相連接，通過單層感知器共同生成細化特徵。

經過上述兩層操作後，輸入點雲被劃分為多個局部區域。其好處是：局部區域中包含的實例數量遠少於輸入實例的數量，有利於降低實例分割的誤判率；局部區域中包含的點的数量遠少於輸入點的数量，有利於提高計算效率。

1.3 相似性矩陣

本節重點論述如何對局部區域內的分支進行實例分割，現有方法可分為兩類：基於檢測和無檢測的方法^[25]。

基於檢測的方法^[26-28]通過使用檢測模塊屏蔽不同的對象，能較好處理上述隨機實例標籤和不規則的實例數量。但當多個檢測框重疊時，其無法確定重疊區域中每個點的標籤。同時，未被任何檢測框覆蓋的點都會被視為背景點，造成枝條表型分析中的信息損失。

本文吸取無檢測方法的優點，提出了一個從特徵空間量

化点相似性的相似性矩阵 $\mathbf{S}$ 。一种衡量点间相似性的直接方法是计算每对点间的距离（特征空间中的欧氏距离）。例如，Wang 等人^[29]通过简单减去每一对点对应的特征向量并取 L_2 准则，生成了一个尺寸为 $N \times N$ (N 代表点数) 的相似性矩阵。然而，此方法耗费大量内存，且相似性矩阵的规模随点的数量呈指数增长，不利于后续处理。一般情况下，属于同一实例的点在三维空间中的位置相似，因此只计算“代表点”之间的距离，生成 n 个广泛分布的点作为“代表点”，大致代表树枝的形状。本文采用最远点采样完成该任务，计算采样点与其他各点之间的距离，并将距离最大的点加入采样集。

对 n 个点进行采样，计算每对关键点 $\{P_i, P_j\}$ 对应的细化特征向量，从而得到相似性矩阵 $\mathbf{S}$ ，即 $S_{ij} = \|F_{SM_i} - F_{SM_j}\|_2$ 。相似性矩阵 $\mathbf{S}$ 的维数为 $n \times n$ ，元素 S_{ij} 用于分类关键点 P_i 和 P_j 是否属于同一枝条实例。

此方法下的优化目标是相似关键点在特征空间中较近，无需精确回归细化特征的确切值。因此，本文借鉴 Wang 等人提出模型的优点，对相似性矩阵的双铰链损失定义为：

$$L_{sim} = \sum_i \sum_j l(i, j) \quad (2)$$

$$l(i, j) = \begin{cases} \|F'_i - F'_j\|_2 & R_{ij} = 1 \\ \alpha \max(0, T_{ins} - \|F'_i - F'_j\|_2) & R_{ij} = 2 \\ \max(0, T_{seg} - \|F'_i - F'_j\|_2) & R_{ij} = 3 \end{cases} \quad (3)$$

式中： R_{ij} 表示关键点 $\{P_i, P_j\}$ 之间的关系， $R_{ij} = 1$ 表示关键点对具有相同的枝条实例标签； $R_{ij} = 2$ 表示关键点对具有不同的枝条实例标签，但具有相同的语义标签； $R_{ij} = 3$ 表示关键点对具有不同的枝条语义标签； T_{ins} 、 T_{seg} 为常数 ($T_{seg} > T_{ins}$)，可使 $\mathbf{S}$ 的优化结果满足以下条件：当 $R_{ij} = 1$ 时， $S_{ij} < T_{ins}$ ；当 $R_{ij} = 2$ 时， $T_{ins} \leq S_{ij} \leq T_{seg}$ ；当 $R_{ij} = 3$ 时， $S_{ij} > T_{seg}$ ； α ($\alpha > 1$) 是一个惩罚因子，用于在 $R_{ij} = 2$ 的情况下增加损失权重，避免关键点对之间的距离过近。

通过额外 MLP 层对 $\mathbf{S}$ 进行反馈，以预测 $n \times 1$ 置信度图 CM，反映模型每个分组正确枝条实例的可信度。本文根据 Ground Truth 组 $\mathbf{G}$ 来回归置信度得分， $\mathbf{G}$ 表示为与 $\mathbf{S}$ 相同形式的 $n \times n$ 矩阵，其生成基于上文提到的 G_{ins}^i ，若关键点 P_i 和 P_j 属于同一枝条实例，则 $G_{ij} = G_{ji} = 1$ ，否则 $G_{ij} = G_{ji} = 0$ 。该任务可通过矩阵增强、转置和减法解决，无需逐点扫描，能迅速生成 $\mathbf{G}$ 。 $\mathbf{S}$ 每一行都可看作是一个拟分组的点集，其构成一个候选枝条实例。置信图中的真实值是预测组 $\mathbf{S}$ 中的点集与 Ground Truth 组 $\mathbf{G}$ 之间的交集。本文的损失 L_{CF} 是真实 CM 与预期 CM 之间的 L_2 损失。

在测试阶段，将相似度矩阵 $\mathbf{S}$ 中的值化为 0 和 1，其中相似度矩阵的元素值小于 T_{ins} 的视为 1，表示两个关键点来

自同一枝条实例，即相似性矩阵 $\mathbf{S}$ 可看作是任意两个关键点之间的相邻图表示，由此来自同一枝条实例的关键点的分组可看作是寻找图中所有连通成分的问题。本文利用矩阵的幂次解决此问题，计算相似性矩阵的 k 次幂，得到连接矩阵 CM，CM 每一行表示一个关键点和其他关键点是否在同一组中。通过计算所有点到每个关键点的距离，将局部区域中的点映射到不同的组中，形成多个局部区域片段。其中，局部区域段的置信度是其包含的关键点中置信度最高的一个。虽然由同一相似性矩阵生成的多个分段中不存在重复点，但一棵完整的果树包含多个局部区域（相似性矩阵），可能导致相邻局部区域之间的重叠。为确保后期枝条分割的唯一性，本文应用非极大抑制方法，将 IoU 大于 0.7 的枝条合并，进而将整棵树修剪成干净、无重叠的枝条信息。

2 分析与讨论

2.1 研究区域和数据采集

本文实验地点位于山东省栖霞市，实验基地占地约 0.4 公顷，苹果树株行距为 4 m × 4 m，每公顷种植密度约为 583 株。实验数据使用背负式激光雷达 (LiDAR) 系统和地面激光扫描仪 (TLS) 获取。本文使用 LiBackpack DG50 (STD 16E) 激光雷达设备，其扫描精度为 5 cm。利用波长为 903 nm 的激光，其最大激光扫描距离可达 100 m。该激光雷达系统的扫描频率为每秒 600 000 点。此外，LiBackpack DG50 的水平视场角从 0° 到 360° 不等，能够全面覆盖周围环境；垂直视场角从 -90° 到 90° 不等，便于从不同角度采集数据。为防止重复采集数据，在数据采集过程中采用了 U 型路径。

采集所得数据利用 LiDAR360 点云处理软件进行标记，训练深度学习模型建立可靠的 Ground Truth 数据集。本文从试验区内随机选取 8 棵苹果树，确保其完整的结构和高密度的点云枝条。为扩展数据集，对选定果树进行旋转变换，沿 Z 轴每 5° 旋转一次。对于数据集的划分，本文将 70% 的数据用于训练，剩余 30% 的数据用于测试训练后的模型。通过这种划分，可以评估模型在数据样本上的性能^[30]。

2.2 评价指标

本节重点介绍评估该方法语义分割和实例分割性能的评估方案。用于衡量分割性能的评价指标包括精确度 Precision、召回率 Recall、交并比 IoU、平均覆盖率 mCov 和平均加权覆盖率 mwCov^[31]。这些指标的计算方法为：

$$Precision = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (4)$$

$$Recall = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (5)$$

$$IoU = \frac{|P_b \cap G_b|}{|P_b \cup G_b|} \quad (6)$$

$$mCov(G, P) = \frac{1}{|G|} \sum_{g \in G} \max_{p \in P} IoU(g, p) \quad (7)$$

$$w_g = \frac{|g|}{\sum_{g' \in G} |g'|} \quad (8)$$

$$mwCov(G, P) = \frac{1}{|G|} \sum_{g \in G} w_g \max_{p \in P} IoU(g, p) \quad (9)$$

在评估指标中, N_{TP} 代表预测与实际均为正例的数量, N_{FP} 代表预测正例而实际负例的数量, N_{FN} 代表预测负例而实际正例的数量。符号 $||$ 表示集合中元素的基数或数量, G 表示由真实实例组成的 Ground Truth 集, G 中的每个实例都用符号 g 表示, P 表示从分割算法中获得的预测值集合, 每个预测实例用符号 p 表示。这些评估指标提供了分割性能的量化衡量标准, 有助于评估所提出的苹果树枝条语义分割和实例分割方法的准确性和可靠性^[32]。

2.3 实验结果

表 1 列出了利用三维点云数据对果树枝条进行语义分割的结果。用于评估分割性能的评价指标是精确度、召回率和交并比 IoU。

表 1 果树枝条的语义分割结果

Label	Precision		Recall		IoU	
	Mean	Max	Mean	Max	Mean	Max
Main Trunk, MT	0.93	0.98	0.91	0.96	0.89	0.92
First-Order Branch, 1 st -B	0.61	0.80	0.73	0.93	0.52	0.61
Second-Order Branch, 2 nd -B	0.71	0.78	0.52	0.63	0.43	0.60
Third-Order Branch, 3 rd -B	0.28	0.51	0.40	0.67	0.20	0.32

在表 1 中, 主干类别的平均精确度为 0.93, 表明对属于主干的点进行分类的精确度相对较高, 其最高精确度值可达 0.98, 在准确识别主干区域方面表现出色。主干的平均召回值为 0.91, 在检测实际主干点的能力较强, 其最大召回值同样体现高成功率。此外, 主干平均 IoU 为 0.89, 可得预测的主干区域与真实区域有很大重叠。


一级枝条的平均精确度为 0.61, 分类效果适中, 而最高精确度为 0.80, 能够在某些情况下实现精确分类。平均召回率 0.73 表明检测实际一级枝条点的能力较好, 而最大召回率为 0.93, 效果优秀。平均 IoU 为 0.52, 表明预测的一级枝条区域与真实的一级枝条区域之间存在中等程度的重叠, 而最大 IoU 值为 0.61, 保证部分情况能有较高的重叠。

对于二级枝条类别, 平均精确度值为 0.71 与最大精确度值 0.78 相差较小, 其在总体情况下均能较好识别。检测实际二阶枝条点的能力适中, 平均召回值仅为 0.52, 最大召回值仅为 0.63。预测的二级枝条区域与真实区域重叠略小, 平均 IoU 仅为 0.43, 而最大 IoU 值可达 0.60, 表明某些情况下能有较好性能。

三级枝条仅有 0.28 的平均精度值, 分类情况较差。平均召回值为 0.40, 实际三级枝条点的识别能力一般, 而最大召回值为 0.67, 能在部分情况准确检测。平均 IoU 为 0.20, 表明预测的三级枝条区域与真实区域之间的重叠程度相对较低。

结果表明, 使用三维点云数据对不同果树枝条类别进行语义分割的性能水平各不相同。主干类别获得了相对较高的精确度、召回率和 IoU, 分割准确且一致。然而, 低级枝条的三个值均有所下降, 表明在三维点云数据中准确分割更小、更复杂的枝条结构面临挑战。

图 2 展示了使用本文提出的方法获得的语义分割结果。左侧部分显示输入的果树点云, 中间部分显示本文方法生成的分割结果, 右侧部分是相应的真实数据注释。本文方法的分割结果显示令人满意的性能, 尤其是对主干和一级枝条的分割。但是, 三级枝条结构较为复杂精细, 同时存在背负式激光雷达的扫描误差, 其分割精度相对较低。尽管如此, 本文的方法依旧表现出良好的分割能力, 突出了其在准确划分果树枝条方面的成效。



(a) Inputs (b) Segmentation (c) Ground Truth

图 2 测试数据集分割结果的可视化展示

表 2、表 3 列出了对果树枝条进行实例分割的结果, 以精确度、召回率、平均覆盖率 mCov 和平均加权覆盖率 mwCov 作为评价指标来评估性能。

表 2 果树枝条实例分割的精确度、召回率

Label	Precision		Recall	
	Mean	Max	Mean	Max
Main Trunk, MT	0.96	0.99	0.89	0.97
First-Order Branch, 1st-B	0.59	0.78	0.65	0.87
Second-Order Branch, 2nd-B	0.60	0.80	0.44	0.54
Third-Order Branch, 3rd-B	0.48	0.93	0.54	0.74

表 3 果树枝条实例分割的平均覆盖率、平均加权覆盖率

Label	mCov		mwCov	
	Mean	Max	Mean	Max
Main Trunk, MT	0.92	0.98	0.92	0.98
First-Order Branch, 1st-B	0.47	0.66	0.51	0.68
Second-Order Branch, 2nd-B	0.31	0.42	0.33	0.44
Third-Order Branch, 3rd-B	0.16	0.24	0.17	0.28

整体评估方面,实验结果表明,本文在实例分割方面取得了较好的成效。主干类别的精确度高达 0.96,表明在正确识别主干实例方面具有很高的准确性。召回值为 0.89,表明该模型能够有效地检测到实际的主干实例。此外,mCov 和 mwCov 均为 0.92,表明预测实例和真实实例之间存在大量重叠和一致性。

同时,存在具体挑战,尤其是三级枝条的精确度值为 0.48,召回值为 0.54,表明很难准确区分不同的三级枝条实例。三级枝条的密度较高且错综复杂,给精确分割带来较大挑战。mCov 和 mwCov 值相对较低,仅为 0.16 左右,与其他枝条类别相比,其覆盖范围和一致性都有所减弱。

综上所述,本文模型在分割果树枝条方面表现出优秀的性能,尤其是在主干实例方面。然而,事实证明,分割更小、更复杂的枝条如三级枝条更具挑战性。针对这些局限性,还可进一步改进,以提高模型准确分割复杂枝条结构的能力。

3 结论

果树枝条的实例分割是探索果树表型的关键一步。然而,由于形态结构复杂、实例密度高,现有方法很难实现精确的实例分割^[33]。本文提出了一种基于三维点云数据、考虑局部相似性的度量学习方法,成功实现了果树枝条的语义和实例分割。本文采用 PointNet++ 网络对果树进行语义分割,将提取的语义特征划分为多个局部区域,以降低计算复杂度。随后,为每个局部空间点生成相似性矩阵,并使用双铰链损失函数进行优化。实验结果表明,所提出方法能够准确地对原始果树点云进行语义分割,区分主干、一级枝、二级枝和三级枝。此外,该方法通过有效区分枝条级别的不同实例,实现了精确的实例分割。

然而,该方法在准确分割较小的枝条如三级枝方面仍存在局限性。未来的工作重点是提高较小枝条的实例分割准确性,并压缩模型以部署在边缘设备上,降低能耗和延迟。

总之,本研究提出了一种利用三维点云数据对果树枝条进行精确语义和实例分割的新型度量学习方法。实验结果凸显了此方法在精确区分不同枝条实例方面的有效性,并为该领域的进一步研究提供了启示。

参考文献:

[1]WU J, YANG G, YANG H, et al. Extracting apple tree crown information from remote imagery using deep learning[J].

Computers and electronics in agriculture, 2020, 174: 105504.

[2]MU Y, FUJII Y, TAKATA D, et al. Characterization of peach tree crown by using high-resolution images from an unmanned aerial vehicle[J]. Horticulture research, 2018, 5(1):74.

[3]LI Z, GUO R, LI M, et al. A review of computer vision technologies for plant phenotyping[J]. Computers and electronics in agriculture, 2020, 176: 105672.

[4]MODICA G, MESSINA G, LUCA G, et al. Monitoring the vegetation vigor in heterogeneous citrus and olive orchards. a multiscale object-based approach to extract trees' crowns from UAV multispectral imagery[J]. Computers and electronics in agriculture, 2020, 175: 105500.

[5]FENG L, CHEN S, ZHANG C, et al. A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenotyping[J]. Computers and electronics in agriculture, 2021, 182: 106033.

[6]崔团团,李晓天.基于多特征融合和神经网络的机载 LiDAR 点云分类[J].信息技术与信息化,2020(9):37-39.

[7]YUN T, CAO L, AN F, et al. Simulation of multi-platform LiDAR for assessing total leaf area in tree crowns[J]. Agricultural and forest meteorology, 2019, 276: 107610.

[8]YUN T, JIANG K, LI G, et al. Individual tree crown segmentation from airborne LiDAR data using a novel gaussian filter and energy function minimization-based approach[J]. Remote sensing of environment, 2021, 256: 112307.

[9]JIN S, SU Y, WU F, et al. Stem-leaf segmentation and phenotypic trait extraction of individual maize using terrestrial LiDAR data[J]. IEEE transactions on geoscience and remote sensing, 2018, 57(3): 1336-1346.

[10]JIN S, SU Y, GAO S, et al. Separating the structural components of maize for field phenotyping using terrestrial LiDAR data and deep convolutional neural networks[J]. IEEE transactions on geoscience and remote sensing, 2019, 58(4): 2644-2658.

[11]LEI L, LI Z, WU J, et al. Extraction of maize leaf base and inclination angles using Terrestrial Laser Scanning (TLS) data[J]. IEEE transactions on geoscience and remote sensing, 2022,8:25-26.

[12]HUANG Y, REN Z, LI D, et al. Phenotypic techniques and applications in fruit trees: a review[J]. Plant methods, 2020, 16(1): 1-22.

[13]ITAKURA K, MIYATANI S, HOSOI F.Estimating tree structural parameters via automatic tree segmentation from

- LiDAR point cloud data[J].IEEE journal of selected topics in applied earth observations and remote sensing, 2022,15:555-564.
- [14]LIANG Z, YANG M, LI H, et al. 3D instance embedding learning with a structure-aware loss function for point cloud segmentation[J].IEEE robotics and automation letters, 2020,5:4915-4922.
- [15]ZHOU H, CHEN H, FENG Y, et al. Geometry and learning co-supported normal estimation for unstructured point cloud[C]//Proceedings of the IEEE/CVF Conference On Computer Vision and Pattern Recognition.Piscataway:IEEE, 2020: 13238-13247.
- [16]王可, 沈川贵, 罗孟华. 基于深度学习的图像语义分割方法综述 [J]. 信息技术与信息化, 2022(4):23-30.
- [17]JIN S, SU Y, ZHAO X, et al. A point-based fully convolutional neural network for airborne lidar ground point filtering in forested environments[J]. IEEE journal of selected topics in applied earth observations and remote sensing, 2020, 13: 3958-3974.
- [18]LI D, SHI G, LI J, et al. PlantNet: a dual-function point cloud segmentation network for multiple plant species[J]. ISPRS journal of photogrammetry and remote sensing, 2022, 184: 243-263.
- [19]JAVAHERI A, BRITES C, PEREIRA F, et al.Point cloud rendering after coding: impacts on subjective and objective quality[J].IEEE transactions on multimedia, 2021,23:4049-4064.
- [20]ZHANG F, FANG J, WAH B, et al. Deep fusionnet for point cloud semantic segmentation[C]//Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XXIV 16. Berlin:Springer International Publishing, 2020: 644-663.
- [21]QI C, 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(CVPR).Piscataway:IEEE, 2017: 652-660.
- [22]QI C, YI L, SU H, et al. Pointnet++: deep hierarchical feature learning on point sets in a metric space[J]. Advances in neural information processing systems, 2017, 30:5105-5114.
- [23]ZHAO L, ZHOU H, ZHU X, et al. LIF-Seg: LiDAR and camera image fusion for 3D LiDAR semantic segmentation[J]. IEEE transactions on multimedia, 2023,26:1158-1168.
- [24]JIANG L, ZHAO H, SHI S, et al. Pointgroup: dual-set point grouping for 3D instance segmentation[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition.Piscataway:IEEE,2020: 4867-4876.
- [25]ZHANG S, LI R, DONG X, et al. Pose2seg: Detection free human instance segmentation[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Piscataway:IEEE,2019: 889-898.
- [26]HE K, GKIOXARI G, DOLLAR P, et al. Girshick. Mask R-CNN[C]//IEEE International Conference on Computer Vision.Piscataway:IEEE, 2017:2980-2988.
- [27]HOU J, DAI A, MATTHIAS N. 3D-SIS: 3D semantic instance segmentation of RGB-D scans[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway:IEEE,2019:4421-4430.
- [28]LI Y, WANG Z, HE W, et al. GSPN: generative shape proposal network for 3D instance segmentation in point cloud[C]//IEEE Conference on Computer Vision and Pattern Recognition.Piscataway:IEEE,2019:3947-3956.
- [29]WANG W, YU R, HUANG Q, et al. Sgpn: Similarity group proposal network for 3D point cloud instance segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition.Piscataway:IEEE,2018:2569-2578.
- [30]WU J, YANG G, YANG X, et al. Automatic counting of in situ rice seedlings from UAV images based on a deep fully convolutional neural network[J]. Remote sensing, 2019, 11(6): 691.
- [31]WANG Z, WANG E, ZHU Y. Image segmentation evaluation: a survey of methods[J]. Artificial intelligence review, 2020, 53: 5637-5674.
- [32]LI D, LI J, XIANG S, et al. PSegNet: simultaneous semantic and instance segmentation for point clouds of plants[J]. Plant phenomics,2022,2022:9787643.
- [33]LE LOUËDEC J, CIELNIAK G. 3D shape sensing and deep learning-based segmentation of strawberries[J]. Computers and electronics in agriculture, 2021, 190: 106374.

【作者简介】

蒋心恺(2002—), 男, 江苏苏州人, 本科, 研究方向: 图像处理、深度学习技术。

吴金涛(1993—), 通信作者(email: wjt@nuist.edu.cn), 男, 安徽芜湖人, 博士, 研究方向: 农业遥感、服务计算、3D 点云。

王锐(2002—), 男, 江苏苏州人, 本科, 研究方向: 边缘智能, 服务缓存。

王明亮(1989—), 男, 江苏盐城人, 博士, 研究方向: 计算机视觉、医疗影像处理。

杨浩(1983—), 男, 湖北天门人, 博士, 研究方向: 农业遥感、智慧农业。

(收稿日期: 2024-02-18)