

基于动态图卷积网络的植物点云分割研究

钟旭升

广东工业大学, 计算机学院, 广东 广州

收稿日期: 2022年2月23日; 录用日期: 2022年3月22日; 发布日期: 2022年3月29日

摘要

叶片是植物进行光合作用和产生营养物质的重要器官, 准确、快速地获取植物叶片参数对于了解植物生长规律、提高产量具有重要意义。本文使用图卷积神经网络GCNN作为基本框架, 并在网络的各层更新图的构成。本文使用采集的864株植株点云数据作为数据集, 并用相同的设备在该数据集上验证本文的模型, 实验表明, 本文的方法与以往的点云分割模型相比具有较大的性能提升。

关键词

点云分割, 图卷积神经网络

Segmentation of Plant Point Cloud Segmentation Based on Dynamic Graph Convolution Network

Xusheng Zhong

School of Computer Science and Technology, Guangdong University of Technology, Guangzhou Guangdong

Received: Feb. 23rd, 2022; accepted: Mar. 22nd, 2022; published: Mar. 29th, 2022

Abstract

Leaf is an important organ for photosynthesis and nutrient production in plants. Accurate and rapid acquisition of plant leaf parameters is of great significance for understanding plant growth rules and improving yield. In this paper, graph convolution neural network (GCNN) is used as the basic framework and the graph composition is updated in each layer of the network. In this paper, the collected point cloud data of 864 plants are used as our data set, and the same equipment is used to verify the proposed model on the data set. Experiments show that the method we proposed has greater performance improvement than previous point cloud segmentation models.

Keywords

Point Cloud Segmentation, Graph Convolution Neural Network

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着计算机技术、传感器技术、计算机视觉技术的发展,人们可以快速获取具有三维坐标(x, y, z)和一定属性(颜色、反射强度等)海量的、不规则空间分布的三维点云,这种形式的点云数据能有效地刻画复杂的现实世界,点云数据在形式上呈离散分布,数据点的位置、间隔等在三维空间上呈不规则分布,同时,点云数据具有可测量性,可以直接在点云上获取距离、方位角、表面法向量,还可以计算得到点云所表达目标的表面积、体积等。目前已有多种方式获取三维点云数据,例如通过一些采集设备采集,如三维激光扫描系统,消费者级深度(RGB-D)相机等。还可以通过一些三维重建算法来获得点云数据,例如运动恢复结构(SFM)算法等。随着智慧城市、现代化农业、无人驾驶、高精度地图等新技术的不断发展,点云的应用迎来了良好的发展机遇,同时也面临着新的挑战。而点云分割作为三维点云处理中的重要分支,已成为导航定位、计算机视觉、测绘地理信息等多领域的重要研究方向。

点云分割是按照一定的规则对点云数据进行划分,通常是将具有相同特征的点标记为相同类的过程。点云分割实际上是对点云中的每个点进行分类。点云分割方法已经经历了较长时间的发展,出现了大量的传统经典分割算法,传统分割算法需要根据点云的一些基本特征如几何特征、颜色信息等设计特征描述子(Feature Descriptor),然后根据这些特征描述子建立特征滤波器进行分割,其中主要的分割方法有:基于边界的分割方法,基于面的分割方法,基于聚类的分割方法,基于机器学习的分割方法。虽然经过大量学者的研究改进,传统点云分割方法不断进步,分割精度不断提高。但是,传统点云分割方法需要手工设计特征描述子,这要求设计者具有丰富的先验知识,而且设计的特征描述子只对特定的任务分割效果较好,对其他任务的泛化能力较差。传统分割算法在点云分割过程中需要设定大量的阈值,十分复杂与繁琐。为了提高点云分割的自动化与智能化程度,基于深度学习(Deep Learning)的点云分割方法正在成为最新的研究热点与难点。

三维点云分割方法已经经历了较长时间的发展,主要分为传统分割算法和基于深度学习的分割方法。传统分割算法需要根据点云的一些基本特征如几何特征、颜色信息等设计特征描述子(Feature Descriptor),然后根据这些特征描述子建立特征滤波器进行分割,其中主要的分割方法有:基于边界的分割方法[1],基于面的分割方法[2],基于聚类的分割方法[3]。Franck 等人[4]采用基于面的方法对植株体素进行分割,得到了较好的分割结果。

虽然经过大量学者的研究改进,传统点云分割方法不断进步,分割精度不断提高。但是传统点云分割方法需要手工设计特征描述子,这要求设计者具有丰富的先验知识,而且设计的特征描述子只对特定的任务分割效果好,对其他任务的泛化能力较差。传统分割算法在点云分割过程中需要设定大量的阈值,十分复杂与繁琐。为了提高点云分割的自动化与智能化程度,基于深度学习(Deep Learning)的点云分割方法正在成为最新的研究热点与难点。对以点云作为输入的神经网络,斯坦福大学 Charles 团队[5]提出了 PointNet,利用对称函数解决了点云的无序性问题,成为一个将点云数据直接作为神经网络的输入

的模型，取得了不错的识别与分割精度。然而该网络只能学习到点云全局特征，忽略了局部特征，针对该问题 Charles 团队进行了改进提出了 PointNet++ [6]，该网络通过层级结构利用局部区域信息学习特征，网络结构更有效更鲁棒。Yang Yanli [7]等人在 Pointnet 的基础上提出改进，提出 PointCNN 网络结构模型，该模型通过对点云特性的分析，提出一种从点云中学习得到的 X 变换矩阵，然后将其与点关联的输入特征进行卷积将它们重新排列成潜在隐含的规范顺序。Jiang M 等[8]提出了 PointSIFT 网络，该方法借鉴在二维图像上使用较为广泛的 sift 算子，对三维点云在不同方向上的信息进行编码，并且也具有尺度不变性。J. Li 等人[9]在 PointNet++的基础上，提出 SO-Net 以及 Behl [10]等提出的 PointFlowNet 等网络模型均取得了较好的效果。Wang Y 等[11]将图神经网络应用于点云数据上，提出动态图的构造方法，取得了不错的分类和分割效果。这些网络的出现为后来基于深度学习的点云分割方法指引了方向，具有重要价值。鉴于直接以点云为输入的网络模型结构在点云分割上取得的较好效果，越来越多的研究者开始对这类方法进行研究 with 改进。本文将自主采集的真实植株幼苗经过三维重建、预处理等操作后作为数据集，然后通过提出的 GCNN 模型进行特征提取，完成植物点云分割任务，最后通过消融实验证实了模型的有效性。

2. 相关工作

2.1. 多层感知机

多层感知机属于前馈神经网络，是一种最常见的神经网络结构。感知机是一个主要解决二分类问题的线性网络结构，多层感知机除输入输出层之外，中间包含多个隐藏层。最简单的多层感知机只含有一个隐藏层，如图 1 所示。




Figure 1. The three-layer structure of multilayer perceptron
图 1. 多层感知机的三层结构

多层感知机相邻两层是相互连接的。 w 代表权重系数， b 代表偏置，其中权重系数 w 和偏置 b 经网络反向传播学习得到， a 代表隐藏层输出，第一层隐藏层输出为 $f(w_1 + b_1)$ ， f 为激活函数，常用的激活函数为 sigmoid 函数或 tanh 函数，其线性输出公式如下：

$$\hat{y} = \sum_i^N w_i x_i + b \quad (1)$$

2.2. 图卷积神经网络

图卷积网络将卷积运算(例如图像)推广到图数据，即非结构化数据。现实中有很多非结构化的数据，例如社交网络、知识图谱等，近年来兴起的点云数据是非结构化数据的一种。这类数据每个顶点的邻居节点不相同，因此不能直接使用传统卷积神经网络提取特征。

以点云数据为例, 只需以点云作为顶点, 以 KNN 聚类算法为基准, 求出邻居顶点后构成边, 从而形成完整的点云图结构, 直接作用于图卷积神经网络 GCN 中实现特征提取, 如图 2 所示。




Figure 2. Learning process of point cloud graph feature

图 2. 点云图特征学习过程

3. 本文方法

受 PointNet 和图神经网络启发, 本文提出一种动态图神经网络模型 GCNN, GCNN 总体架构如图 3 所示。PointNet 将点云直接经过 mlp 提取特征, 所得特征缺乏点与点之间的联系, 不能很好的反应点云的几何信息。本文将植株点云经过图卷积 GraphConv 提取特征, GCNN 总体结构如图 3 所示。对输入植株点云经过 GraphConv 提取特征, 并将每个 GraphConv 提取的特征聚合起来, 经过对称操作 max pooling 后形成一维的全局特征描述子, 用于生成最后的 p 类分割分数。图构建后并不是固定的, 而是在网络的各层不断更新。

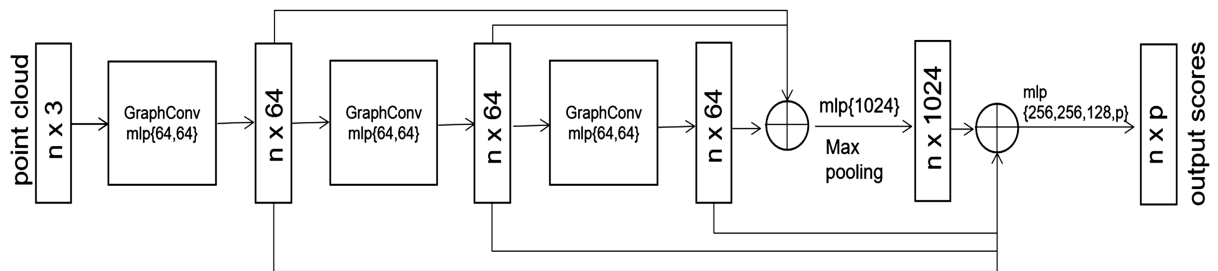


Figure 3. Architecture of GCNN

图 3. GCNN 架构图

3.1. 图卷积 GraphConv

定义图 G 为 (V, E) , 其中 $V = \{v_1, v_2, \dots, v_n\}$ 为顶点集, $E \in V \times V$ 是边集。 F 维点云含有 n 个点, 表示为 $X = \{x_1, x_2, \dots, x_n\} \subseteq \mathbb{R}^F$, 每个点包含坐标信息 xyz , 即 $x_i = (x_i, y_i, z_i)$, 点云同时也可含有颜色, 法向量等信息。对点云中的 x_i , 取其在点集 X 中的 k 近邻点来构建图, 其中每个顶点的近邻点也可包含本身。定义特征 $e_{ij} = h(x_i, x_j)$, 其中 h 为多层感知机 mlp, 将特征空间升维。最后用对称操作 \odot 聚合图中每条边的特征得到点 x_i 最终特征 x'_i , 本文采用的对称操作为 maxpooling。GraphConv 过程如图 4 所示。

3.2. 动态构图策略

在模型 GCNN 中图的构建并不是固定的, 而是在网络的每层逐层更新。第 0 层的图由点云坐标根据 3.1 节中的方法建图, 图中的顶点即为原始点云中的点, 所得图包含着点云中每个点周围的几何领域信息。

在随后的网络层中,根据上一层所得的特征 e_{ij} 寻找 k 近邻,并用找到的 k 近邻特征 e_{ij} 作为顶点进行建图,图所包含的信息不再仅有几何领域信息,同时包含语义信息。后续实验证明逐层更新的策略有利于对点云特征提取,提高了分割准确率。

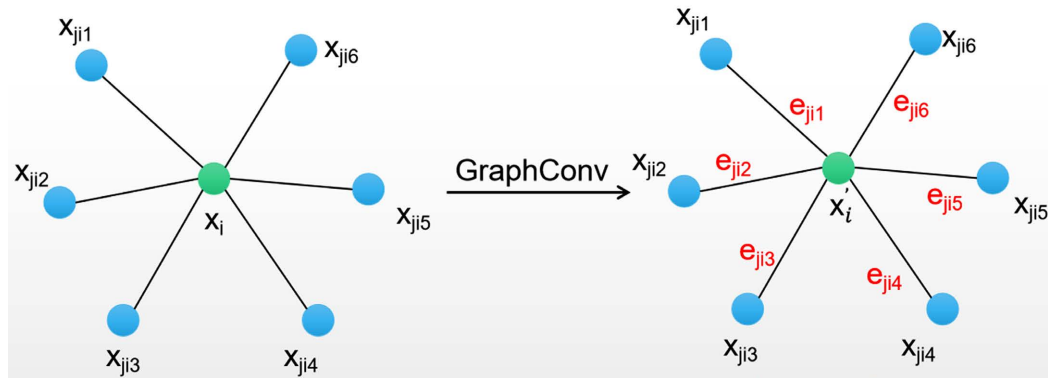


Figure 4. Process of GraphConv
图 4. GraphConv 过程

4. 实验

4.1. 实验数据集

本文数据集为 864 株同种类植物幼苗点云数据,通过幼苗二维图像采集平台逐株拍摄多角度二维图像,再经过点云三维重建 SFM (structure from motion)算法重建出植株点云数据。对重建出的点云数据进行滤波去除噪声后,利用 CloudCompare 软件对所有数据进行标注。部分数据如图 5 所示,其中绿色为植株叶子类,蓝色为非叶子类。




Figure 5. Part of plant point cloud data
图 5. 部分植物点云数据

4.2. 评价指标

在点云分割中，常用的评价指标有 IoU 和 Dice 两种，本文实验主要是采用平均交并比(mIoU)作为评价指标，平均交并比 mIoU 是衡量物体分割准确程度的重要标准之一，其计算方法如公式(2)所示：

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (2)$$

4.3. 实验结果分析

为验证模型有效性，使用植株数据集在同一台设备上消融实验。实验结果如表 1 所示。

Table 1. Result data of experiment

表 1. 实验结果

模型	mIoU
PointNet	79.3
PointNet++	81.6
PointCNN	82.1
fixed-GCNN	80.5
GCNN (本文方法)	83.3

实验结果表明，本文的 GCNN 模型在植株点云数据集上有着一定的效果，同时，采用动态构图策略充分结合几何和语义信息对模型的泛化能力有着一定提升。

5. 总结

本文针对植物点云分割提出了 GCNN 模型。模型通过图卷积加强对点云特征的提取，并采用动态构图的策略，在网络的每层更新图的构成，使模型所得特征既包含点云的几何信息又包含一定的语义信息，经过与多个模型的对比实验，说明本文的 GCNN 模型在植物点云数据集上具有一定的效果。

参考文献

- [1] Himmelsbach, M., Luettel, T. and Wuensche, H. (2009) Real-Time Object Classification in 3D Point Clouds Using Point Feature Histograms. *IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS 2009*, St. Louis, 10-15 October 2009, 994-1000. <https://doi.org/10.1109/IROS.2009.5354493>
- [2] 姜媛媛. 基于超体素区域增长的点云分割算法研究[D]: [硕士学位论文]. 西安: 西安电子科技大学, 2005.
- [3] 孙红岩, 孙晓鹏, 李华. 基于 K-means 聚类方法的三维点云模型分割[J]. *计算机工程与应用*, 2006(10): 42-45.
- [4] Golbach, F., Kootstra, G., Damjanovic, S., et al. (2016) Validation of Plant Part Measurements Using a 3D Reconstruction Method Suitable for High-Throughput Seedling Phenotyping. *Machine Vision & Applications*, **27**, 663-680. <https://doi.org/10.1007/s00138-015-0727-5>
- [5] Qi, C.R., Su, H., Mo, K. and Guibas, L.J. (2017) Pointnet: Deep Learning on Point Sets for 3d Classification and Segmentation. arXiv:1612.00593 [cs.CV]
- [6] Qi, C.R., Yi, L., Su, H. and Guibas, L.J. (2017) Pointnet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space. In: *Advances in Neural Information Processing Systems*, 5105-5114.
- [7] Li, Y., Bu, R., Sun, M., Wu, W., Di, X. and Chen, B. (2018) PointCNN: Convolution on X-Transformed Points. In: *Advances in Neural Information Processing Systems*, 820-830.
- [8] Jiang, M., Wu, Y., Zhao, T., et al. (2018) PointSIFT: A SIFT-Like Network Module for 3D Point Cloud Semantic Segmentation. arXiv:1807.00652 [cs.CV]

- [9] Li, J., Chen, B.M. and Lee, G.H. (2018) SO-Net: Self-Organizing Network for Point Cloud Analysis. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, 18-23 June 2018, Article ID: 00979. <https://doi.org/10.1109/CVPR.2018.00979>
- [10] Behl, A., Paschalidou, D., Donne, S., *et al.* (2019) PointFlowNet: Learning Representations for Rigid Motion Estimation from Point Clouds. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, CA, 15-20 June 2019, Article ID: 00815. <https://doi.org/10.1109/CVPR.2019.00815>
- [11] Wang, Y., Sun, Y., Liu, Z., *et al.* (2018) Dynamic Graph CNN for Learning on Point Clouds. *ACM Transactions on Graphics*, **38**, 1-12. <https://doi.org/10.1145/3326362>