

doi:10.6041/j.issn.1000-1298.2021.01.016

基于MRE - PointNet + AE的绿萝叶片外形参数估测算法

王浩云¹ 肖海鸿¹ 马仕航² 陈玲¹ 王江波³ 徐焕良¹

(1. 南京农业大学人工智能学院, 南京 210095; 2. 中国移动通讯集团上海有限公司, 上海 200060;

3. 塔里木大学植物科学学院, 阿拉尔 843300)

摘要: 为了准确、高效、自动获取植物叶片外形参数, 提出一种基于多分辨率编码点云深度学习网络(MRE - PointNet)和自编码器模型的绿萝叶片外形参数估测算法。使用 Kinect V2 相机以垂直姿态获取绿萝叶片点云数据, 采用直通滤波、分割、点云精简算法对数据进行预处理, 通过测定的叶片外形参数反演绿萝叶片几何模型, 并计算几何模型的叶长、叶宽、叶面积。将不同参数组合构建的几何模型离散成点云数据输入 MRE - PointNet 网络, 得到几何模型叶片外形参数估测的预训练模型。针对拍摄过程中存在的叶片部分遮挡和噪声问题, 采用自编码器网络对点云数据进行二次处理, 以几何模型离散的点云数据作为输入, 经过编码-解码运算得到自编码器的预训练模型, 提升了 MRE - PointNet 网络在遮挡情况下对叶片外形参数估测的鲁棒性。试验共采集 300 片绿萝叶片点云数据, 按照 2:1 比例进行划分, 以其中 200 片点云数据作为训练集, 对预训练模型 MRE - PointNet 做模型迁移的参数微调, 以剩下的 100 片点云数据作为测试集, 评估模型对绿萝叶片外形参数的估测能力。采用本文算法将外形参数估测值和真实值进行数学统计与线性回归分析, 得出叶长、叶宽和叶面积估测的 R^2 和 RMSE 分别为 0.900 5 和 0.417 0 cm、0.913 1 和 0.316 4 cm、0.944 7 和 3.883 4 cm²。试验表明, 基于 MRE - PointNet 和自编码器模型的绿萝叶片外形参数估测算法具有较高的精确度和实用性。

关键词: 绿萝; 叶片外形参数估测; 多分辨率编码; 模型迁移; 深度学习; 自编码器

中图分类号: TP391; S126 文献标识码: A 文章编号: 1000-1298(2021)01-0146-08

OSID:



Estimation Algorithm of Leaf Shape Parameters of *Scirpus sibiricum* Based on MRE - PointNet and Autoencoder Model

WANG Haoyun¹ XIAO Haihong¹ MA Shihang² CHEN Ling¹ WANG Jiangbo³ XU Huanliang¹

(1. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210095, China

2. China Mobile Communications Group Shanghai Co., Shanghai 200060, China

3. College of Plant Sciences, Tarim University, Aral 843300, China)

Abstract: In order to obtain the leaf shape parameters of plant leaves efficiently, accurately and automatically, a multi-resolution coded point cloud deep learning network (MRE - PointNet) and autoencoder model based on the *Scirpus sibiricum* leaf shape parameter estimation algorithm was proposed. The Kinect V2 camera was used to acquire the point cloud data of *Scirpus sibiricum* leaves in vertical attitude, and the data was pre-processed by straight-pass filtering, segmentation and point cloud simplification algorithm. The geometric model constructed with different parameter combinations was discretized into point cloud data and input into MRE - PointNet network to obtain the pre-training model of the geometric model shape parameter estimation. In order to solve the problem of partial occlusion and noise of the leaves in the filming process, an autoencoder network with secondary processing of the point cloud data was used to obtain the autoencoder pre-training model by taking the discrete point cloud data of the geometric model as input and encoding-decoding operation, which improved the robustness of the MRE - PointNet network in estimating the shape parameters of the occluded data. A total of 300 point

收稿日期: 2020-09-20 修回日期: 2020-11-05

基金项目: 南京农业大学-塔里木大学教师开放科研联合基金项目(NNLH202006)、中央高校基本科研业务费专项资金项目(KYLH202006、KYZ201914)、新疆生产建设兵团南疆重点产业支撑计划项目(2017DB006)和国家自然科学基金项目(31601545)

作者简介: 王浩云(1981—),男,副教授,博士,主要从事作物表型参数测量研究,E-mail: wanghy@njau.edu.cn

通信作者: 徐焕良(1963—),男,教授,博士生导师,主要从事作物表型参数测量研究,E-mail: huanliangxu@njau.edu.cn

clouds of *Scirpus sibiricum* leaves were collected. With the ratio of 2:1, totally 200 slices of point cloud data were used as the training set to fine-tune for model transfer to the pre-training model MRE-PointNet, and the remaining 100 slices of point cloud data were used as the test set. By the algorithm, the mathematical statistics and linear regression analysis were performed to compare the estimated and real values of the shape parameters. The experiment results showed that the estimated R^2 and RMSE of leaf length were 0.900 5 and 0.417 0 cm, leaf width was 0.913 1 and 0.316 4 cm, and leaf area was 0.944 7 and 3.883 4 cm^2 , respectively, based on the MRE-PointNet and the self-training model. The encoder model algorithm for estimating the shape parameters of *scirpus sibiricum* leaves had high precision and practicality.

Key words: *Scirpus sibiricum*; leaves shape parameters estimation; multi-resolution encoding; model transfer; deep learning; autoencoder

0 引言

植物表型是指受基因和环境决定或影响的复杂植物性状,包括生长、发育、耐性、抗性、生理、结构和产量等^[1]。植物叶片是植物外在形态的重要组成部分,同时也是植物进行生理功能运作的主要器官^[2]。叶片几何参数不仅是植物生长发育、产量形成和品种特性的重要指标,也是对作物进行合理栽培管理以及病虫害发生检测的重要依据^[3]。因此,准确测量叶片的长、宽、叶面积等几何参数,对了解作物生长状况和指导作物育种、栽培等具有重要意义。

传统的接触式手工测量方法存在操作繁琐、效率低、误差较大的缺点^[4]。随着硬件技术的不断进步,非接触式测量方法研究,如基于图像的表型特征提取方法和基于点云的三维建模和测量方法等受到越来越多的关注。文献[5]采用非接触式的视觉图像处理技术对大枣的表型参数进行提取。文献[6]采用双目立体视觉技术,以图像方法重建玉米果穗三维造型,并进行可视化输出,对果穗三维形态进行测量比较,但人工进行相机标定比较复杂。文献[7]采用运动恢复结构(Structure from motion, SFM)和多视角立体视觉(Multiple view stereo, MVS)相结合,基于多角度图像序列对生长前期的植株进行三维重建,对植株叶片进行建模分析,并进行三维测量。该方法根据图像序列之间的约束关系建立物体点三维坐标、摄像机参数、图像匹配点之间的大型非线性系统,虽然能够进行相机的自动标定,但是进行迭代求解时计算量较大。文献[8]采用图像分割方法实现簸箕柳与背景的分割,结合运动恢复结构算法对分割的二维图像生成三维点云,并利用棋盘格进行坐标系间的距离转换,从而提取簸箕柳的株高、基径、叶面积、分枝数等表型参数。文献[9]采用三维重建的方法对甜菜根型进行表型数字化处理,并根据提取的表型参数采用支持向量机、决策树、随机森林

等预测模型进行根系分类。

以上方法可以对植株的外部表型参数进行较为准确的估测,但是无论是相机标定还是迭代计算,亦或是多角度拍摄均耗时费力。文献[10]通过构建番茄果实表型性状对应的数学模型,开发了可以半自动精确测量番茄果实表型性状的分析系统。文献[11]提出了第 1 个直接作用于点云数据的深度学习框架 PointNet,可以实现点云物体的分类、分割和语义分割,但是,深度学习对数据的数量要求更高。目前利用深度学习对植株表型参数估测的研究尚未见报道。

本文以长藤绿萝为研究对象,使用 Kinect V2 相机从单一角度拍摄,获取点云数据,采用直通滤波、分割、点云精简算法对数据进行预处理,采用参数方程构建绿萝叶片几何模型,并计算几何模型的叶长、叶宽、叶面积。将几何模型离散的点云数据输入多分辨率点云深度学习网络(MRE-PointNet),得到预训练模型,针对叶片遮挡和噪声问题,通过自编码器的预训练模型对输入点云数据进行二次处理,用测得的绿萝叶片外形参数标签对预训练模型(MRE-PointNet)进行参数微调,从而完成绿萝叶片外形参数的估测。

1 材料与方法

1.1 试验材料

绿萝是阴性植物,喜湿热环境,在温度高于 10℃ 的环境下适宜生长。试验绿萝品种为长藤大叶绿萝,选取培育 4 个月且生长状况良好的 10 盆大叶绿萝作为试验对象。植株冠层直径为 28 ~ 32 cm,冠层高度 8 ~ 12 cm,冠层内叶片数量相近,均长势良好。为了减少冠层表面叶片对下层叶片的遮挡影响,根据冠层高度将其平均划分为 3 个区间层进行叶片数据采集,每层采集 8 ~ 12 片数据,共采集 300 片绿萝叶片数据。

1.2 数据采集

试验数据采集主要分为两部分:先对绿萝进行

无损点云数据采集,然后再对叶片进行离体有损的外部表型参数真实值采集。Kinect V2 相机是微软公司推出的二代 Kinect 相机,精度为 2~4 mm,分辨率为 512 像素×424 像素,使用 Kinect V2 相机对绿萝进行拍摄,将相机倒挂于装有横臂、水平仪的三脚架上,以垂直试验台姿态固定高度 75 cm 对绿萝冠层表面进行拍摄,获取点云数据,然后将冠层表面叶片离体进行外部表型参数真实值数据采集,并准备进行下一层绿萝叶片的数据采集。

使用 Kinect for Windows SDK 2.0 中的 Kinect Fusion Explorer 进行点云数据采集,保存为 ply 格式。使用 Matlab 工具箱中的 calibration 工具对数据进行标定,通过获取镜头畸变参数得到校正矩阵。

将从每一次冠层表面离体的叶片平铺于 A4 白纸上,借助游标卡尺测量叶长和叶宽,测量精度

为 0.01 mm,采用 Kinect V2 相机从 75 cm 高度获取叶片彩色图像并进行标定与校正,通过图像分割提取叶片区域与 A4 纸区域的二值图像进行像素点统计,按照比例求取绿萝叶片的叶面积。

1.3 点云数据预处理

通过 Kinect V2 相机获取绿萝叶片点云数据,如图 1a 所示,点云数据包含空间坐标 X 、 Y 、 Z 位置信息和与之对应的 RGB 颜色信息,点云数据的三维坐标系以 Kinect 深度相机为原点,精确度是 0.001 m,获得的绿萝点云原始数据包括背景台等冗余信息,采用直通滤波法^[12]去除背景数据,得到绿萝冠层的表面叶片数据,如图 1b 所示。并采用区域增长分割算法将绿萝冠层表面分割成单片叶片,结果如图 1c 所示。对分割的单片叶片点云采用包围盒算法^[13]和迭代最远点采样算法 (IFPS)^[14]进行精简,如图 1d 所示。

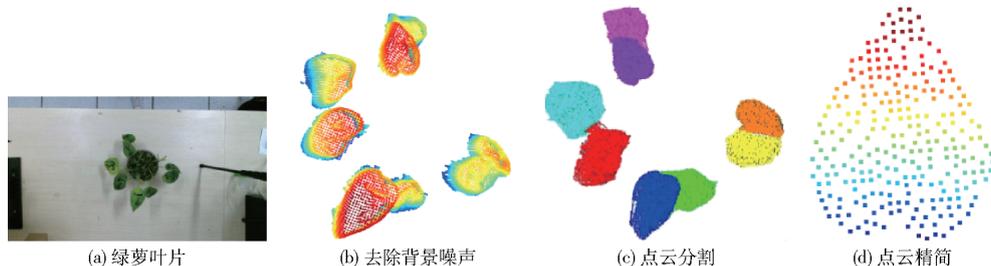


图 1 点云数据分割与处理

Fig. 1 Point cloud data segmentation and processing

1.4 叶片几何模型构建与外部表型参数测量

1.4.1 基于曲面参数方程的叶片几何模型构建

绿萝叶片的造型只包含一个曲面,形状较规则,可以采用相应参数曲面方程变形来进行构造,用参数方程表示有较好的稳定性。绿萝叶片的外形呈上窄下宽的卵圆形,根据果实造型和植物叶片的造型研究^[15-16],叶片外形由叶形、叶尖、叶基和叶缘的边界轮廓组成。由于叶片厚度较小,构建几何模型时可以忽略不计,采用参数曲面方程 $Q(u, v)$ 构建一个长方形平面,然后添加合适的干扰函数将长方形平面变形为叶片外形造型,最终得到叶片外形的参数方程^[17]为

$$\begin{cases} x_Q = bu + t_{x1} & (-0.5 \leq u \leq 0.5) \\ y_Q = hv + t_{y1} + t_{y2} + t_{y3} & (0 \leq v \leq 1) \\ z_Q = x_t b \sin(0.25x_Q \pi/b + \pi/2) + y_b \sin(0.25\pi y_Q/h) \end{cases} \quad (1)$$

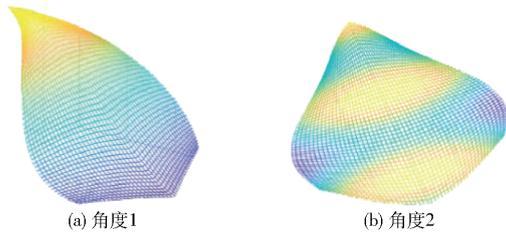
其中

$$\begin{cases} t_{x1} = 2ua_x \sin(\pi v + d_y) \\ t_{y1} = va_t \sin(\pi(u + 0.5)) - (1 - v)a_b \sin(\pi(u + 0.5)) \\ t_{y2} = v(bu_t - \text{abs}(bu))u_t \\ t_{y3} = -(1 - v)(bu_t - \text{abs}(bu))u_b \end{cases} \quad (2)$$

式中 t_{x1} —— X 方向上叶形干扰函数
 t_{y1} —— Y 方向上叶基正弦变形函数
 t_{y2} 、 t_{y3} —— Y 方向上叶尖两侧线性变形函数
 x_Q —— X 方向上的参数方程
 y_Q —— Y 方向上的参数方程
 z_Q —— Z 方向上的参数方程
 h ——长度系数 b ——宽度系数
 a_x ——叶形变形指数,主要是对叶宽造成影响
 d_y ——比例造型指数,影响叶片最宽点位置
 a_t ——叶尖变形指数,控制叶尖部分长度变化
 a_b ——叶基变形指数,控制叶基部分长度变化
 u_t ——叶尖造型指数,控制叶尖部分宽高比
 u_b ——叶基造型指数,控制叶基部分宽高比
 x_b ——叶片沿 X 方向在 Z 轴的弯曲幅度
 y_b ——叶片沿 Y 方向在 Z 轴的弯曲幅度
 u 、 v ——自变量参数

其中 h 、 b 、 a_x 、 d_y 、 a_t 、 a_b 、 u_t 、 u_b 、 x_b 、 y_b 为参数方程 10 个内部模型参数。

根据该参数方程构建的叶片模型从不同的角度查看如图 2 所示。并通过控制参数方程的自变量参数取值得到包括 12 743 个模型数据的模型库。



(a) 角度1 (b) 角度2

图 2 叶片几何模型

Fig. 2 Leaf geometric model

1.4.2 叶片几何模型的外部表型参数测量

通过固定 10 个模型参数值,改变 u, v 两个系统参数值,找到 Y 轴方向上的最高点 L_1 与最低点 L_2 , 这两点在 Y 轴方向上的差值即为叶长 L 。以同样的方法,找到 X 轴方向上的最高点 W_1 与最低点 W_2 ,

这两点在 X 轴方向上的差值即为叶宽 W 。固定 10 个模型参数值,按 0.05 的步长改变 u, v 得到 400 个单位矩形顶点,三角网格化后,通过海伦公式计算每个小三角形的面积,累加得到叶面积 S 。

1.5 基于 MRE - PointNet 和自编码器模型的叶片外形参数估测算法

通过 Kinect 相机从单一角度获取的叶片点云数据存在残缺和噪声问题,通过预训练好的自编码器模型对预处理的点云数据进行二次降噪处理。通过多分辨率点云深度学习网络对输入的叶片点云数据进行特征捕捉,输出叶片外部表型参数。为了更准确地输出叶片外部表型参数,通过基于真实值的模型参数微调,提升网络对真实叶片外部表型参数估测的准确率。基于 MRE - PointNet 和自编码器模型算法的绿萝叶片外形参数估测流程如图 3 所示。

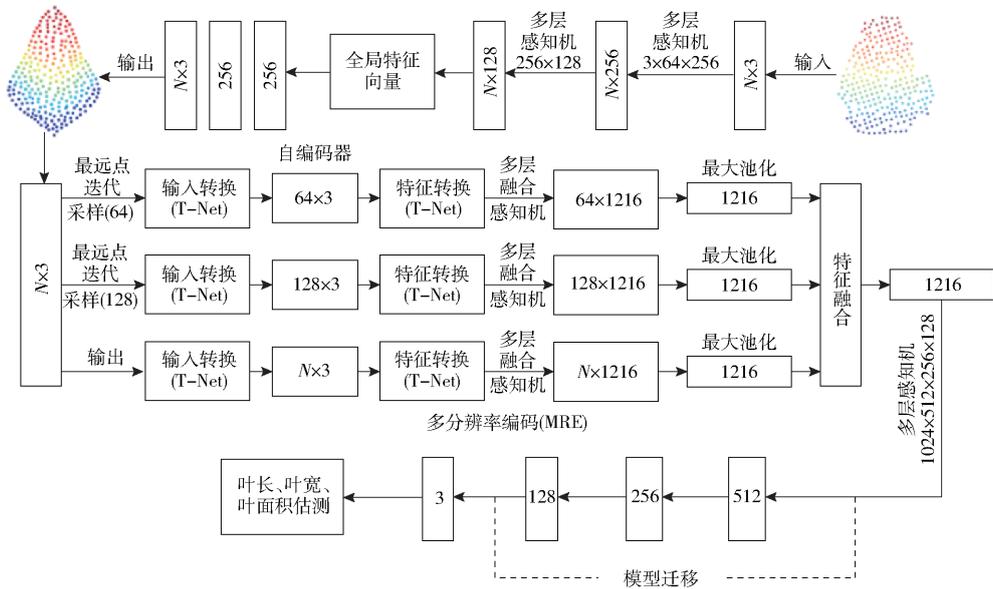


图 3 基于 MRE - PointNet 和自编码器模型算法的绿萝叶片外形参数估测流程图

Fig. 3 Flow chart of MRE - PointNet and autoencoder model algorithm based on estimation of leaf shape parameters of *Scirpus sibiricum*

1.5.1 基于几何模型点云数据训练的 MRE - PointNet 模型

多分辨率编码点云深度学习网络 (MRE - PointNet) 是基于 PointNet 特征最大池化结构并结合多分辨率采样特征提取融合叶片外形指标估测回归网络,该网络的主要目的是通过数据训练得到可以直接用于几何模型叶片外形参数估测的预训练模型。在网络前面的特征提取模块,借鉴 PointNet 点云数据特征提取思想,将输入点云 ($N \times 3$) 输入可训练的空间转换网络 (Transfer Net, T - Net) (3×3), 经 T - Net 网络训练得到的空间转换矩阵进行坐标对齐,得到点云 ($N \times 3$), 目的是为了得到一个更好进行特征提取的角度,从而更利于最终外形参数估

测的准确。然后再通过多层感知机 (Multi-layer perceptron, MLP) [18] 对点云升维至 $N \times 64$, 对升维后的数据 $N \times 64$ 输入可训练的空间转换网络 T - Net (64×64), 升维数据经 T - Net 网络训练得到的空间转换矩阵进行特征对齐得到数据 $N \times 64$, 即在特征层面上对点云进行矩阵变换,目的是对升维特征进行对齐,更好地进行特征提取。然后再通过 MLP 升维至 1024 维 ($N \times 1024$), 做全局特征池化 (1024), 从而解决了点云的空间无序性问题,但是特征的最大池化也忽略了点云的局部信息,为了更好地捕捉到点云数据的局部特征,提出了多分辨率特征提取网络编码器 (Multi-resolution encoder, MRE), 用 IFPS 采样 64、128、256 个点, 分别进行点云数据特征编

码。同时相比于原网络结构的单层MLP($N \times 1024$),本文提出了多层深度特征融合结构(Concat multi-layer perceptron, CMLP)($N \times 1216$),通过不同层次的深度特征进行融合,从而更好地进行叶片点云局部特征的捕捉。MRE-PointNet网络是基于叶片外部参数估测的回归网络,采用均方差(Mean square error, MSE)损失函数度量真实值和估测值的误差。最后通过将11467条几何模型点云数据作为训练集,1276条几何模型点云数据作为验证集,得到几何模型外部参数指标估测的预训练模型。

1.5.2 基于几何模型点云数据训练的自编码器模型

基于点云数据训练的自编码器(Autoencoder, AE)网络是一种将点云数据进行低维编码并通过解码器解码成与输入点云相同维度的无监督神经网络。它主要由两部分构成,编码器主要将输入的点云($N \times 3$)编码成128维的全局特征向量(Global feature vector, GFV),进行特征的有效提取。解码器主要将编码之后的GFV恢复为与原来输入维度相同的点云数据。自编码器不仅能够很好地对输入点云数据进行去噪,还能对一定程度的残缺点云数据进行有效的补全,具有一定的鲁棒性,在结果分析中,将结合自编码器模型进行数据残缺的鲁棒性结果分析。训练AE时,采用反向传播法减少输入和输出点云之间的距离,可以用地球移动距离(Earth movers distance, EMD)^[19]或倒角距离(Chamfer distance, CD)^[20-21]作为对输入点云和输出点云之间的误差衡量,本文采用更加有效的倒角距离作为自编码器网络训练的损失函数。倒角距离函数为

$$d_{CH}(P_1, P_2) = \sum_{a \in P_1} \min_{b \in P_2} \|a - b\|_2^2 + \sum_{a \in P_2} \min_{a \in P_1} \|a - b\|_2^2 \quad (3)$$

式中 P_1, P_2 ——输入点云和解码器解码出来的点云中点的数目

a, b ——点云 P_1, P_2 中的点

d_{CH} 能够衡量解码之后的点云形状与输入点云形状之间的差异,数值越小,表示两个点云之间的相似程度越高,其中 d_{CH} 的单位为 cm^2 。

最后将11467条几何模型点云数据作为自编码器网络的训练集,1276条几何模型点云数据作为验证集,得到自编码器的预训练模型。

1.5.3 基于真实数据MRE-PointNet预训练模型的模型迁移参数微调

预训练模型能很好地对几何模型绿萝叶片外形参数进行估测,但是从单一角度得到的真实叶片点云数据存在遮挡情况。尽管可以通过自编码器模型对预处理的点云数据进行二次降噪和点云补全,从

而减小一些异常点和被遮挡数据的影响,但是经过自编码器模型二次处理之后的真实点云数据还是会和几何模型离散点云数据存在较小的差异性。因此通过模型迁移(Model transfer)^[22]方法,对MRE-PointNet预训练模型的特征提取层参数进行固定,对最后3层多层感知机做参数微调,训练得到适用于真实叶片外形参数估测的模型。模型微调流程如图4所示。

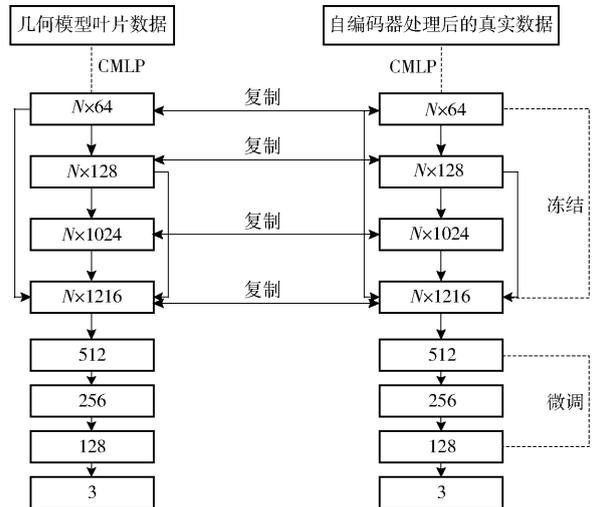


图4 迁移学习模型微调流程图

Fig. 4 Flow chart of fine-tuning of transfer learning model

试验将采集得到的300片绿萝叶片点云数据按照2:1比例进行划分,其中200片数据作为对模型微调的训练集,100片数据作为测试集,评估模型对绿萝叶片外形参数估测的能力。

2 结果与分析

2.1 叶片外部表型参数实际测量结果统计

试验共采集了300片绿萝长藤绿萝点云数据,并测得对应叶片的叶长、叶宽、叶面积外形参数。其中200片叶片数据作为模型微调的训练集,100片数据作为测试集,评估模型对绿萝叶片外形参数的估测能力。以测试集的100片绿萝叶片点云数据作为试验结果分析对象。表1为测试集100片绿萝叶片外部表型参数实测结果统计,从表1可知,绿萝叶片的叶长、叶宽、叶面积分布范围分别为6.86~13.93 cm、4.03~10.1 cm、19.67~96.7 cm^2 ,试验所用绿萝叶片外形参数分布范围较广,避免了样本数

表1 绿萝叶片实测参数统计结果

Tab. 1 Statistics result of measured parameters of *Scirpus sibiricum* leaves

外部表型参数	平均值	最大值	最小值
叶长/cm	9.94	13.93	6.86
叶宽/cm	6.31	10.10	4.03
叶面积/ cm^2	42.58	96.70	19.67

据分布的单一性,试验结果可靠。

2.2 基于 MRE - PointNet 和自编码器模型算法的叶片外形参数估测结果与分析

试验将测试集的 100 片绿萝叶片点云数据经过预处理之后作为输入,分别估测其对应的绿萝叶片外形参数指标(叶长 L 、叶宽 W 、叶面积 S)。并将其估测值和实际测得值进行线性回归分析,如图 5 所示。图中真实值为人工测量的绿萝叶片外形参数值,估测值为基于 MRE - PointNet 和自编码器模型

算法估测的叶片外形参数指标; R^2 表示回归直线对观测值的拟合程度,最大值为 1,其值越接近 1,表示拟合程度越好;均方根误差 (RMSE) 反映估测值与真实值之间的偏差。分析图 5 可知,通过该算法估测的绿萝叶片外形参数值和真实值具有较高的相关性,其线性回归拟合的 R^2 均高于 0.90, RMSE 均在误差允许范围内,证明该算法在对从单一角度获取的点云数据进行外形参数估测时,具有较高的精确度,并具有一定的高效性和稳定性。

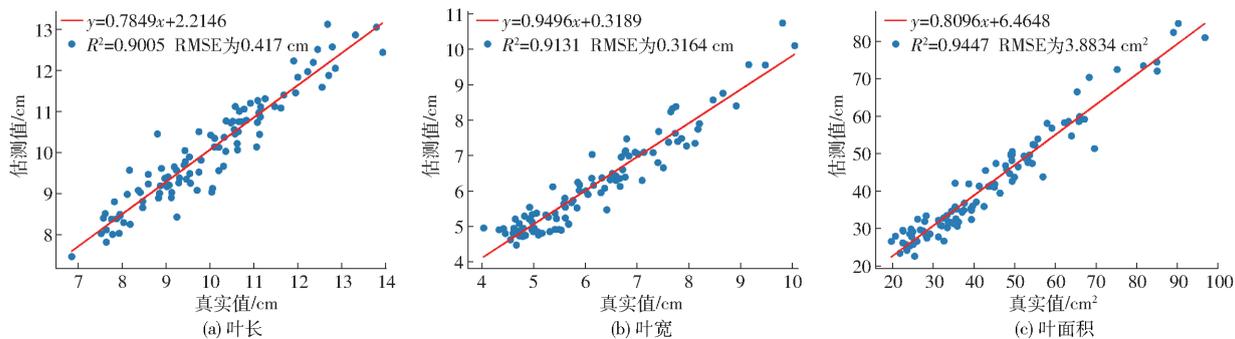


图 5 绿萝叶片外形参数估测结果

Fig. 5 Results of leaf shape parameter estimation

2.3 不同网络模型对叶片外形参数的估测结果对比

对比多分辨率特征编码网络 (MRE - PointNet - CMLP)、单层特征编码网络 (Single - PointNet - MLP)、多层特征融合的单层编码网络 (Single - PointNet - CMLP)、边卷积 (EdgeConv) 操作的动态图卷积神经网络 (Dynamic graph CNN, DGCNN) [23] 对几何模型叶片外形参数的估测能力,以 DGCNN 作为参照。通过控制几何模型参数方程的自变量取

值获得包含 12 743 个模型数据的模型库,并将其离散成点云数据,其中的 11 467 条数据作为训练集,1 276 条数据作为验证集,并分析 4 种网络模型对叶片几何模型外形参数估测的结果。图 6 为训练集数据的决定系数 R^2 及均方根误差 RMSE 变化曲线,其中学习率为 0.01,批尺寸为 30,迭代次数为 101。分析图 6 可知,在设置相同的超参数训练情况下,4 组对比网络模型都具有较快的收敛性,表明 4 组网络

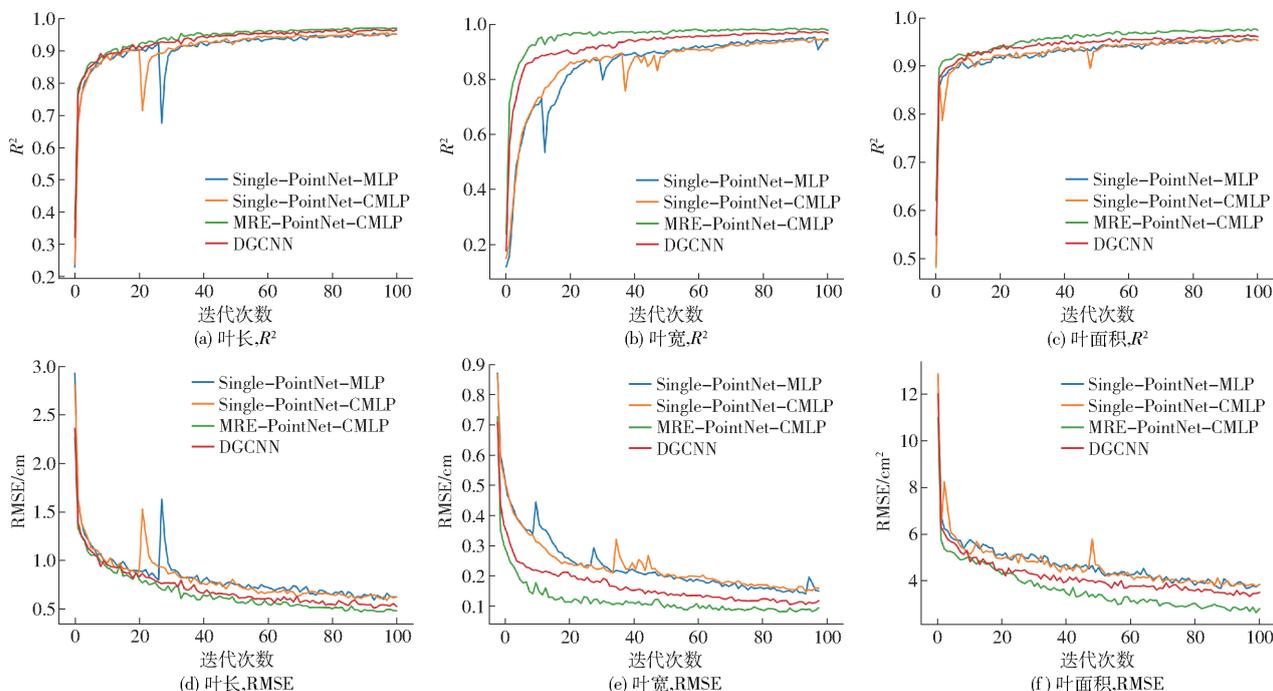


图 6 不同网络模型训练结果对比

Fig. 6 Comparison of training results of different network models

模型结构都能很好地提取到叶片点云特征。从模型训练过程中叶长、叶宽、叶面积的决定系数 R^2 和 RMSE 的变化曲线来看, Single - PointNet - CMLP 训练的 RMSE 略低于 Single - PointNet - MLP, 决定系数 R^2 略高于 Single - PointNet - MLP, MRE - PointNet - CMLP 网络模型和 DGCNN 网络模型训练误差相比于另两种模型的曲线更加稳定, 决定系数 R^2 更高且上升趋势比较稳定, 但是 MRE - PointNet - CMLP 网络的 RMSE 更低, R^2 明显更接近于 1, 所以性能更优。试验证明 MRE - PointNet 网络能更好地捕捉叶片点云特征从而更好地估测叶片外形参数。

2.4 基于 MRE - PointNet 和自编码器模型算法的鲁棒性分析

对比分析 MRE - PointNet 结合自编码器模型对几何模型点云数据不同残缺比例下的外形参数估测结果。试验以验证集的 1 276 条几何模型点云数据作为试验对象, 分别按照残缺比例 20%、30%、40% 进行随机残缺, 残缺效果可通过 open3d^[24-25] 进行可视化, 如图 7 所示。分别通过自动编码器去噪补全, 之后输入多分辨率点云深度学习网络 (MRE - PointNet) 的预训练模型, 得到补全之后的几何模型叶片外形指标估测值, 并将其估测值和几何模型真实值进行回归分析, 得到叶长、叶宽、叶面积的 R^2 和 RMSE, 如表 2 所示。从整体结果来看, 叶面积和叶宽的估测结果相比较于叶长的估测结果更好, 原因

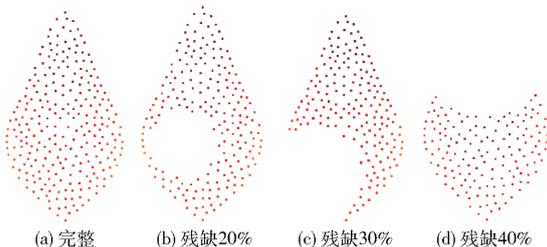


图 7 open3d 可视化点云数据

Fig. 7 open3d visualization point cloud data

表 2 叶片几何模型参数估测鲁棒性结果统计

Tab. 2 Robustness results statistics for blade geometry model parameter estimation

叶片形态	评价指标	叶长	叶宽	叶面积
完整	R^2	0.971 8	0.978 8	0.975 6
	RMSE	0.481 3 cm	0.189 4 cm	2.797 4 cm ²
残缺 20%	R^2	0.878 1	0.925 9	0.948 5
	RMSE	1.003 2 cm	0.357 2 cm	4.046 8 cm ²
残缺 30%	R^2	0.776 6	0.853 6	0.906 5
	RMSE	1.352 3 cm	0.501 8 cm	5.462 7 cm ²
残缺 40%	R^2	0.644 1	0.746 9	0.831 2
	RMSE	1.716 6 cm	0.659 2 cm	7.307 1 cm ²

主要是在拍摄过程中绿萝叶片存在一定的弯曲姿态, 影响了叶长的估测结果。通过试验可知, 数据在残缺 20% 的情况下, 外形参数估测的性能和完整情况下估测的差距不大。而在残缺 40% 的情况下, 外形参数估测的性能比较差, 相较于残缺 30% 的情况, 估测性能下降趋势更加明显。试验表明, 即使在点云数据存在一定残缺的情况下, 网络依然具有较好的估测结果, 证明网络在叶片遮挡情况下具有一定的鲁棒性。

2.5 基于模型迁移前后叶片外形参数估测结果与分析

试验主要对比模型迁移前后的绿萝叶片外形参数估测效果。以实拍的 200 片绿萝叶片点云数据作为训练集对模型进行微调, 其余 100 片绿萝叶片点云数据作为测试集, 并记录测试数据输入模型微调前后的决定系数 R^2 和 RMSE, 如表 3 所示。试验结果说明基于真实数据做模型迁移能有效提高估测精度, 叶长、叶宽、叶面积线性回归估测 R^2 均提高 10% 以上, 其 RMSE 均有明显下降, 证明了基于真实数据做模型迁移的必要性和有效性。

表 3 模型迁移前后叶片参数估测效果对比

Tab. 3 Comparison of effect of blade parameter estimation before and after model transfer

评价 指标	叶片外形参数			
	叶长	叶宽	叶面积	
模型迁移前	R^2	0.748 6	0.774 8	0.823 7
	RMSE	0.764 8 cm	0.675 6 cm	6.815 3 cm ²
模型迁移后	R^2	0.900 5	0.913 1	0.944 7
	RMSE	0.417 0 cm	0.316 4 cm	3.883 4 cm ²

3 结论

(1) 采用提出的基于 MRE - PointNet 和自编码器模型算法, 估测的 100 片绿萝叶片外形指数结果与真实值具有较高的相关性, 其线性回归分析的 R^2 均大于 0.90, 叶长 RMSE 为 0.417 0 cm, 叶宽 RMSE 为 0.316 4 cm, 叶面积 RMSE 为 3.883 4 cm²。估测结果误差较小, 均在允许的误差范围内, 表明本文算法准确率较高, 具有一定的实用性。

(2) 通过曲面参数方程构建绿萝叶片几何模型库, 并与多组网络模型进行对比, 结果表明, MRE - PointNet 网络具有更强的特征提取能力和更加准确的叶片外形参数估测能力。试验还进行了遮挡情况下的残缺模拟试验和网络鲁棒性分析, 结果表明, 基于 MRE - PointNet 和自编码器模型的网络结构对一定遮挡程度下叶片的外形参数估测具有较强的鲁棒性。

参 考 文 献

- [1] 张慧春,周宏平,郑加强,等.植物表型平台与图像分析技术研究进展与展望[J/OL].农业机械学报,2020,51(3):1-17. ZHANG Huichun, ZHOU Hongping, ZHENG Jiaqiang, et al. Research progress and prospect in plant phenotyping platform and image analysis technology[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(3): 1-17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200301&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.03.001. (in Chinese)
- [2] 孙智慧,陆声链,郭新宇,等.基于点云数据的植物叶片曲面重构方法[J].农业工程学报,2012,28(3):184-190. SUN Zhihui, LU Shenglian, GUO Xinyu, et al. Surfaces reconstruction of plant leaves based on point cloud data[J]. Transactions of the CSAE, 2012, 28(3): 184-190. (in Chinese)
- [3] 徐义鑫,李凤菊,王建春,等.基于OpenCV的Android手机植物叶片几何参数测量系统[J].中国农学通报,2015,31(35):236-244. XU Yixin, LI Fengju, WANG Jianchun, et al. OpenCV-based measurement system for plant leaf geometry parameters using Android mobile phone[J]. Chinese Agricultural Science Bulletin, 2015, 31(35): 236-244. (in Chinese)
- [4] 冯冬霞,施生锦.叶面积测定方法的研究效果初报[J].中国农学通报,2005,21(6):150-152,155. FENG Dongxia, SHI Shengjin. Research on night measurement methods of leaf area[J]. Chinese Agricultural Science Bulletin, 2005, 21(6): 150-152, 155. (in Chinese)
- [5] 文怀兴,王春普,黄正祥.基于机器视觉的温室大枣表型特征测量[J].江苏农业科学,2018,46(6):182-184. WEN Huaixing, WANG Chunpu, HUANG Zhengxiang. Phenotypic characterization of greenhouse dates based on machine vision[J]. Jiangsu Agricultural Sciences, 2018, 46(6): 182-184. (in Chinese)
- [6] 王传宇,郭新宇,吴升,等.基于计算机视觉的玉米果穗三维重建方法[J/OL].农业机械学报,2014,45(9):274-279,253. WANG Chuanyu, GUO Xinyu, WU Sheng, et al. Three dimensional reconstruction of maize ear based on computer vision[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(9): 274-279, 253. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20140944&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2014.09.044. (in Chinese)
- [7] 胡鹏程,郭焱,李保国,等.基于多视角立体视觉的植株三维重建与精度评估[J].农业工程学报,2015,31(11):209-214. HU Pengcheng, GUO Yan, LI Baoguo, et al. Three-dimensional reconstruction and its precision evaluation of plant architecture based on multiple view stereo method[J]. Transactions of the CSAE, 2015, 31(11): 209-214. (in Chinese)
- [8] 李杨先,张慧春,杨畅.一种基于图像处理技术的植物形态表型参数获取方法[J].林业工程学报,2020,5(6):128-136. LI Yangxian, ZHANG Huichun, YANG Yang. An image-processing-based method for obtaining morphological phenotypic parameters of plants[J]. Journal of Forestry Engineering, 2020, 5(6): 128-136. (in Chinese)
- [9] 柴宏红,邵科,于超,等.基于三维点云的甜菜根表型参数提取与根型判别[J].农业工程学报,2020,36(10):181-188. CHAI Honghong, SHAO Ke, YU Chao, et al. Extraction of phenotypic parameters and discrimination of beet root types based on 3D point cloud[J]. Transactions of the CSAE, 2020, 36(10): 181-188. (in Chinese)
- [10] NANKAR A N, TRINGOVSKA I, GROZEVA S, et al. Application of high-throughput phenotyping tool tomato analyzer to characterize balkan capsicum fruit diversity[J]. Scientia Horticulturae, 2020, 260: 108862-108874.
- [11] 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.
- [12] LI L, MIAO Z, LIANG M. 3D reconstruction based on Kinect[C]//2014 12th International Conference on Signal Processing (ICSP), 2014: 1247-1250.
- [13] 麻卫峰,周兴华,徐文学,等.一种基于局部曲率特征的点云精简算法[J].测绘工程,2015,24(11):13-16. MA Weifeng, ZHOU Xinghua, XU Wenxue, et al. A point cloud streamlining algorithm based on local curvature features [J]. Journal of Surveying and Mapping Engineering, 2015, 24(11): 13-16. (in Chinese)
- [14] QI C R, YI L, SU H, et al. Pointnet ++: deep hierarchical feature learning on point sets in a metric space[C]//Advances in Neural Information Processing Systems, 2017: 5099-5108.
- [15] 周南.基于变形的三维植物叶片可视化造型研究[D].南昌:东华理工大学,2013. ZHOU Nan. Deformation-based visualization and modeling of three-dimensional plant leaves [D]. Nanchang: East China University of Technology, 2013. (in Chinese)
- [16] 陆玲,李丽华,宋文琳,等.计算机图形学[M].北京:机械工业出版社,2017:213-225.
- [17] 徐焕良,马仕航,王浩云,等.基于几何模型的绿萝叶片外部表型参数三维估测[J/OL].农业机械学报,2020,51(12):220-228. XU Huanliang, MA Shihang, WANG Haoyun, et al. Three-dimensional estimation of money plant leaf external phenotypic parameters based on geometric model [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 220-228. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20201224&flag=1. DOI: 10.6041/j.issn.1000-1298.2020.12.024. (in Chinese)
- [18] MITRA S, PAL S K. Fuzzy multi-layer perceptron, inferencing and rule generation[J]. IEEE Transactions on Neural Networks, 1995, 6(1): 51-63.
- [19] RUBNER Y, TOMASI C, GUIBAS L J. The earth mover's distance as a metric for image retrieval[J]. International Journal of Computer Vision, 2000, 40(2): 99-121.
- [20] SARMAD M, LEE H J, KIM Y M. Rlganet: a reinforcement learning agent controlled gan network for real-time point cloud shape completion[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 5898-5907.
- [21] FAN H, SU H, GUIBAS L J. A point set generation network for 3D object reconstruction from a single image[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 605-613.
- [22] AYTAR Y, ZISSERMAN A. Tabula rasa: model transfer for object category detection[C]//2011 International Conference on Computer Vision. IEEE, 2011: 2252-2259.
- [23] 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.
- [24] SKIPETROV S E, VAN TIGGELEN B A. Dynamics of Anderson localization in open 3D media[J]. Physical Review Letters, 2006, 96(4): 043902.
- [25] TOSCO P, BALLE T. Open3DQ SAR: a new open-source software aimed at high-throughput chemometric analysis of molecular interaction fields[J]. Journal of Molecular Modeling, 2011, 17(1):201-208.