



孙珂,徐焕良,任守纲,等. 基于 CGRSNet 的残缺油桃外形点云补全方法[J]. 南京农业大学学报,2024,47(2):383-391.

SUN Ke, XU Huanliang, REN Shougang, et al. A point cloud completion method based on CGRSNet for incomplete nectarine shape[J]. Journal of Nanjing Agricultural University, 2024, 47(2): 383-391.

基于 CGRSNet 的残缺油桃外形点云补全方法

孙珂,徐焕良,任守纲,单美轩,王浩云*

(南京农业大学人工智能学院,江苏南京 210095)

摘要: [目的] 利用深度相机采集到的油桃数据在进行三维重建时,存在摄像头视野限制,导致油桃点云出现缺失的现象,严重影响油桃表型分析的准确度。为了提高油桃分级分类的准确率和工作效率,提出一种基于三维重建的油桃片外形参数估测方法。 [方法] 提出了一种基于真实结构的粗粒度点云生成网络 (coarse-grained realistic structure with point cloud generation network, CGRSNet)。该网络首先通过编码、解码机制构建点云补全网络,通过新的采样算法对原始点云提取不同维度下的特征信息,提升油桃表型的特征提取能力,然后自解码器自上而下进行多维度点云补全,最终得到完整的油桃形状,最后用模型的参数预估模块预估油桃体积。利用多组参数构建的油桃几何模型离散成点云数据输入 CGRSNet 网络,得到油桃几何模型外形补全的预训练模型,再利用真实油桃点云数据对预训练模型 CGRSNet 做模型迁移的参数微调。 [结果] 该补全网络对油桃数据集补全结果的倒角距离为 0.196 cm。经线性回归分析,得出体积估测的 RMSE 和 R^2 分数为 2.47 cm^3 和 0.94,相较于 PF-Net 的 RMSE 和 R^2 分数提升约 0.88 cm^3 和 0.01。 [结论] 本文提出的基于 CGRSNet 的油桃外形参数估测算法具有较好的实用性和精确度。

关键词: 三维图形;点云补全;模型迁移;深度学习;油桃表型;体积预估

中图分类号: TP391.41

文献标志码: A

文章编号: 1000-2030(2024)02-0383-09

A point cloud completion method based on CGRSNet for incomplete nectarine shape

SUN Ke, XU Huanliang, REN Shougang, SHAN Meixuan, WANG Haoyun*

(College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210095, China)

Abstract: [Objectives] Because of the limit of camera field, the walnut point cloud suffers from missing points, which detrimentally affects the accuracy of walnut phenotype analysis. To enhance the accuracy and expedite the efficiency of walnut grading and classification, this paper proposed a walnut external parameter estimation approach with three-dimensional reconstruction. [Methods] We introduced a coarse-grained realistic structure with the point cloud generation network (CGRSNet) to form a point cloud completion network with an encoding-decoding mechanism. Firstly, a new sampling algorithm was implemented to extract feature information of the original point cloud in different dimensions and thereby increased the feature extraction effectiveness of walnut phenotype. Afterward, the autoencoder was utilized to reconstruct the point cloud in multiple dimensions, and a complete walnut shape was eventually obtained. In the end, the parameters of the model were applied to estimate the volume of walnut. The walnut geometry model generated by multiple parameters was digitized into the point cloud data to feed CGRSNet and get a pre-trained walnut geometry model through shape completion. A fine-tuning process was then conducted with the real walnut point cloud data. [Results] The chamfer distance of the completion network for walnut data set was 0.196 cm. According to the linear regression analysis, the RMSE and R^2 score of the volume estimation were 2.47 cm^3 and 0.94, respectively, which were 0.88 cm^3 and 0.01 higher than those of PF-Net, respectively. [Conclusions] The walnut external parameter estimation algorithm based on CGRSNet proposed in this paper presents satisfactory practicability and accuracy.

Keywords: three-dimensional graphics; point cloud completion; model migration; deep learning; nectarine phenotype; volume estimation

果实分级是水果商品化处理的重要环节,对提高我国水果的市场价格和市场竞争能力有重要意义^[1],其中水果的体尺参数是水果分级的重要依据。水果品质由外部表观和内部特性决定。形状、大小、颜色和其他外观决定基本外部表观^[2]。目前主要采用人工和传统机械识别模式对油桃品质层次进行划分,比较浪费时间。因此,亟需采用智能化设备代替传统的划分模式,快速准确测量油桃体积和质量等几何参数,

收稿日期:2023-05-06

*通信作者:王浩云,副教授,博士,主要从事作物表型参数测量, E-mail: wanghy@njau.edu.cn.

保障农户产出的油桃能快速出售,获得更高的经济效益^[3]。

水果行业的盈利能力取决于水果产量和水果大小。因此通过测量果实的二维关键尺寸(例如长度以及最大和最小直径),建立果实尺寸与果实体积或质量之间的关系^[4]。近年来,基于点云的三维建模和测量方法以及基于三维图像的表型特征提取方法等受到越来越多的关注。彭孝东等^[5]将 Kinect 的彩色点云与激光点云融合、配准,将彩色点云的颜色融合到激光雷达点云中,实现对三维目标的重建并提升该目标三维数据信息的精准度。陈庆光等^[6]与陈辉等^[7]通过三维点云数据计算研究对象的外形参数。Charles 等^[8]、Shu 等^[9]、Huang 等^[10]采用深度学习的方法实现三维点云场景内的语义分割,增强了特征的代表能力,预测研究对象中缺失的点云。Zhao 等^[11]、刘心溥等^[12]在经典网络中增加了 Transformer 注意力模块,提升了在点云点特征提取和全局特征提取中的准确率。肖海鸿等^[13]提出了一种基于 MSF-PPD 网络,该网络通过金字塔解码器对残缺绿萝叶片进行多维度、多阶段的补全。陈龙等^[14]提出一种利用迁移学习和深度学习网络结合,在小样本下也能准确预测苹果表型参数的估测方法。

本文以油桃为研究对象,使用 Kinect V2 相机在研究对象顶部垂直拍摄,获取部分油桃点云数据。为了得到真实完整的油桃点云数据,本文采用直通滤波^[15]算法和最小密度采样(minimum density sampling, MDS)^[16]算法进行点云精简,并利用点云三点配准^[15]算法对精简后的点云数据进行配准,得到真实完整的油桃点云数据。本研究采用参数方程构建油桃外形几何模型,并计算几何模型的体积,将几何模型离散化的点云数据输入真实结构的粗粒度点云生成网络(coarse-grained realistic structure with point cloud generation network, CGRSNet)中,得到预训练模型,最后使用真实的油桃点云数据和体积数据对预训练模型进行微调,从而完成油桃体积参数的估测,以期油桃的分级提供重要依据。

1 材料与方法

1.1 试验材料

选取‘早红珠’油桃(下文统称油桃)作为试验对象,总共选取 153 颗油桃,选取的油桃高度为 54~72 mm,半径最大处直径 56~76 mm,尽可能保证油桃的生长状态良好。

1.2 试验数据采集

采集油桃的体积、质量、高度、半径等外部表型参数和油桃无损点云数据。采集点云数据前先使用游标卡尺测量油桃的高度、油桃腰部直径最大处的直径、油桃底部凹陷的深度、油桃底部开始凹陷处圆的直径,使用电子秤称量油桃的质量,利用排水法测量油桃的体积。

使用微软公司推出的二代体感相机 Kinect V2 对油桃进行无损点云数据采集。如图 1 所示,保持相机水平且稳定,以垂直且距离实验台 80 cm 姿态对油桃表面进行拍摄。拍摄时针对油桃不同的角度采集 6 张点云数据,分别是顶部 1 张,底部 1 张,腰部按顺时针旋转 90°直到旋转 360°共采集 4 张。

1.3 点云数据预处理

如图 2 所示,通过 Kinect V2 相机拍摄获取到的油桃点云数据,包含多条离散点数据,其中每条点云数据中包含该点的 X、Y、Z 空间坐标信息和 RGB 颜色信息。获得的油桃点云原始数据除油桃外还包括实验台、地面、三脚架等冗余信息,如图 2-A 所示。采用直通滤波法^[15]点去除冗余信息,获得油桃朝向相机的上半部表面数据,如图 2-B 所示。对滤波后的半个油桃点云数据进行下采样,保留 1 024 条点云数据,并将油桃的重心移动至坐标轴原点,预处理后的油桃点云数据如图 2-C 所示。

在此基础上,利用点云三点配准^[17]算法,将不同角度的油桃真实点云数据配准成完整的真实油桃点云数据。




图 1 油桃数据获取平台

Fig. 1 Platform for nectarine data acquisition

1. Kinect V2 相机 Kinect V2 camera; 2. 油桃 Nectarine; 3. 实验台 Experiment table; 4. 三脚架 Tripod.




图 2 油桃点云数据预处理

Fig. 2 Preprocessing of nectarine point cloud data

A.拍摄后的油桃 Nectarine after shooting; B.去除背景噪声 Remove background noise; C.预处理后的点云 Point cloud after preprocessing.

1.4 油桃几何模型库构建

1.4.1 基于曲面参数方程的油桃几何模型构建 油桃的形状类似于一个椭球体,油桃几何模型的构造方法是对椭球体增加凹凸纹理,使椭球体形状变形,最后趋近油桃的外形。油桃的外形近似上下高度略矮的椭球体,对其添加合适的干扰函数 $d(u, v)$ 后使椭球体增加下端凹陷、上端凸起、腰部缝合线的形变,使其趋近油桃的物体外形^[18-19]。中心在原点的三维椭球面参数方程表示如下:

$$\begin{cases} x_p(u, v) = r_x \cos(u) \cos(v) + d(u, v) a(u, v) \\ y_p(u, v) = r_y \sin(u) + d(u, v) b(u, v) \\ z_p(u, v) = r_z \cos(u) \sin(v) + d(u, v) c(u, v) \end{cases} \quad (1)$$

式中: $\left(-\frac{\pi}{2} \leq u \leq \frac{\pi}{2}, 0 \leq v \leq 2\pi\right)$, $r_x = r_y = 1.5r_z$, $(a(u, v), b(u, v), c(u, v))$ 为椭球表面上任意一点 (u, v) 处单位法矢量,干扰函数 $d(u, v) = d_1(u) + d_2(u) + d_3(u, v)$, 且

$$\begin{cases} d_1(u) = -p_1 e^{-2u} \\ d_2(u) = p_2 e^{2u} \\ d_3(u, v) = p_3 \sin\left(\frac{v}{2}\right) |\cos(u) e^{|v-\pi|}| \end{cases} \quad (2)$$

式中: u, v 为自变量参数; r_x 为 X 方向上的参数; r_y 为 Y 方向上的参数; r_z 为 Z 方向上的参数; p_1 为控制油桃底端凹陷程度; p_2 为控制油桃顶端凸起程度; p_3 为控制油桃缝合线凹凸程度。其中 $r_x, r_y, r_z, p_1, p_2, p_3$ 为参数方程 6 个内部模型参数。

通过在一定范围内改变参数方程自变量的方法获得包含 18 602 个仿真模型数据的模型库,根据该参数方程构建的油桃模型从不同角度展示的效果如图 3 所示。

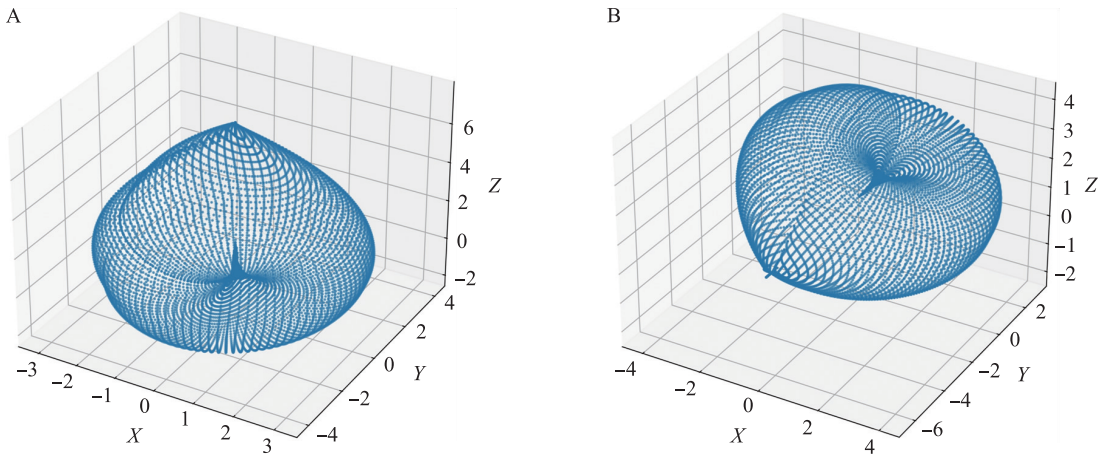


图 3 油桃几何模型

Fig. 3 Nectarine geometric model

A.视角 1 First perspective; B.角度 2 Second perspective.

1.4.2 油桃几何模型的体积参数测量 先利用 alpha shapes^[20]算法,将参数方程构建的油桃离散点云模型进行曲面重建,所有点与点之间形成三角形网格,整个油桃形成封闭网络空间。然后利用四面体法^[21],随机选择封闭网络空间内的任意一点,该点和油桃表面任意一个三角形网格均构成四面体,计算所有四面体的体积再进行累加,可计算出封闭油桃的体积 v 。

1.4.3 最小密度采样 由于图 3 中模拟点云的密度不同,例如油桃顶部和底部凹陷处的点云相对于油桃侧面的点云密度要大,因此点云可能分布不均匀。为了避免高密度部分数据影响模型最终结果,模拟油桃的点云数据应尽可能均匀分布。

最小密度采样(MDS)使用高斯权重的总和来估计点的密度。用 p_i 表示第 i 个采样的点,采样点所在的点集合 $P_i = \{p_j | 1 \leq j \leq i\}$,最小密度采样每次会返回与点集合 P_i 形成具有最小密度的点:

$$p_i = \operatorname{argmin}_{x \notin P_{i-1}} \sum_{p_j \in P_{i-1}} \exp\left(\frac{\|x - p_j\|^2}{2\sigma^2}\right) \quad (3)$$

式中: σ 是一个正常数,表示一定邻域的范围; p_j 表示已采集点集中的点。

如图 4 所示,对左区域 100 点和右区域 400 点的空间使用 3 种采样算法进行 200 个点的下采样。采样后,使用随机采样后左侧区域剩余的 44 个点,使用最远点采样^[20]后左侧区域剩余的 70 个点,使用最小密度采样后左侧区域剩余的 85 个点,最小密度采样输出得到的左右两端点云数量相较于随机采样和最远点采样更加接近,故最小密度采样输出的全局点云分布比随机采样和最远点采样更均匀。




图 4 200 点采样结果

Fig. 4 The results of sampling 200 points

使用最小密度采样算法对包含图 3 所示的模拟油桃数据的仿真模型数据模型库进行 2 048 个点的下采样,使用最小密度采样后的仿真油桃结果如图 5 所示。

1.5 基于 CGRSNet 网络的油桃外形参数估测算法

1.5.1 CGRSNet 网络框架 图 6 是本文提出的基于真实结构的粗粒度点云生成网络(CGRSNet)模型整体框架。该网络由特征提取模块 E、金字塔点云生成模块 D 和参数估测模块 T 三部分构成,整体采用编码器-解码器结构。

CGRSNet 的输入为 3 个不同尺度的原始点云,然后分别送入注意力多层感知机(attentionive multi-layer perceptron, AMLP)中,得到潜在特征向量 F 。对 3 个不同尺度的潜在特征向量进行拼接,获得潜在特征图 M 。特征提取模块 E 最终生成原始点云的特征向量 V 。将该特征向量 V 作为金字塔点云生成模块 D 的输入,依次通过 3 个全连接层,分别输出 3 个尺度的粗粒度点云。随后将生成的最大尺度的油桃点云数据送入参数估测模块 T 中,输出为模拟油桃的体积参数值。

1.5.2 特征提取模块 E 特征提取模块 E 的输入由原始点云及对其进行执行下采样率为 2 和 4 的下采样后共 3 种不同尺度的点云,其点云点数分别为 $[N, N/2, N/4]$,其中 N 为初始点云数, $N/2, N/4$ 点云数由初始点云通过最小密度采样(MDS)得到。然后分别依次输入 AMLP 中,输出对应尺度的潜在特征向量 F ,将不同尺度的潜在特征向量进行拼接,得到潜在特征图 M ,最后通过多层感知机(multi-layer perceptron, MLP)得到特征向量 V ,这样得到的特征向量 V 会放大细节特征,在一定程度上避免了特征提取时细节丢失的情况。




图 5 采样后的油桃几何模型

Fig. 5 The nectarine geometric model after sampling

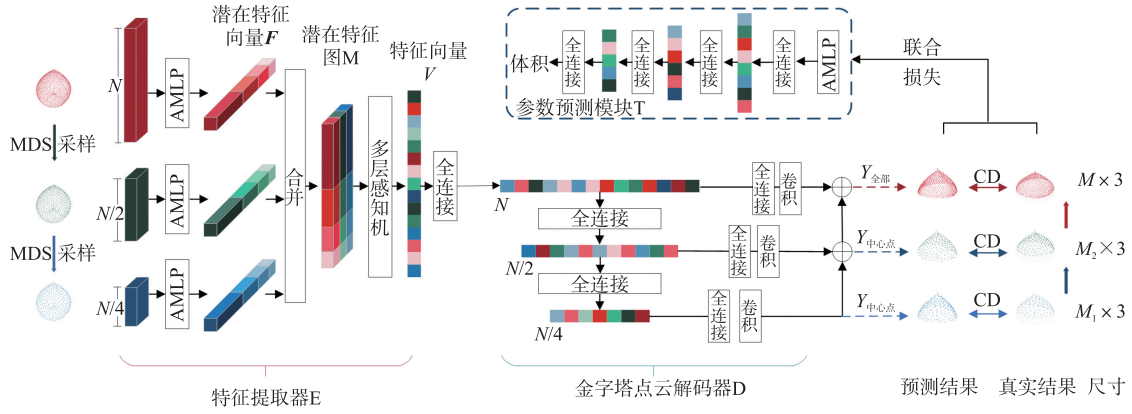


图 6 粗粒度点云生成网络 (CGRSNet) 网络架构

Fig. 6 The framework of coarse-grained realistic structure with point cloud generation network (CGRSNet)

AMLP 的结构如图 7-A 所示,使用单一的 MLP 提取特征,仅仅是通过池化最后一层提取特征向量,易忽略低层和中层包含的部分信息。组合多层感知机 (combined multi-layer perceptron, CMLP) 在多个 MLP 层上池化获得特征向量,通过拼接,得到不同层次的综合特征。AMLP 网络在 CMLP 基础上增加注意力块 (level attention block, LAB),增强了网络提取物局部特征信息的能力。将池化后的多层次特征在拼接成潜在特征向量前先输入到 LAB 模块 (图 7-B) 中。LAB 将池化得到的特征向量 C 经过 2 个全连接层训练得到权重 W ,最后与原始向量 C 运算,得到加强后的特征向量 C' :

$$C' = C + W * C \tag{4}$$

再将每个加强后的 C' 连接,然后通过全连接层输出得到最后的潜在特征向量 F :

$$F = FC(Concat(C'_1, C'_2, \dots, C'_n)) \tag{5}$$

将每个潜在特征向量 F 连接,获得潜在特征图 M ,最后通过全连接层,最终得到从原始多分辨率点云中提取到特征向量 V 。

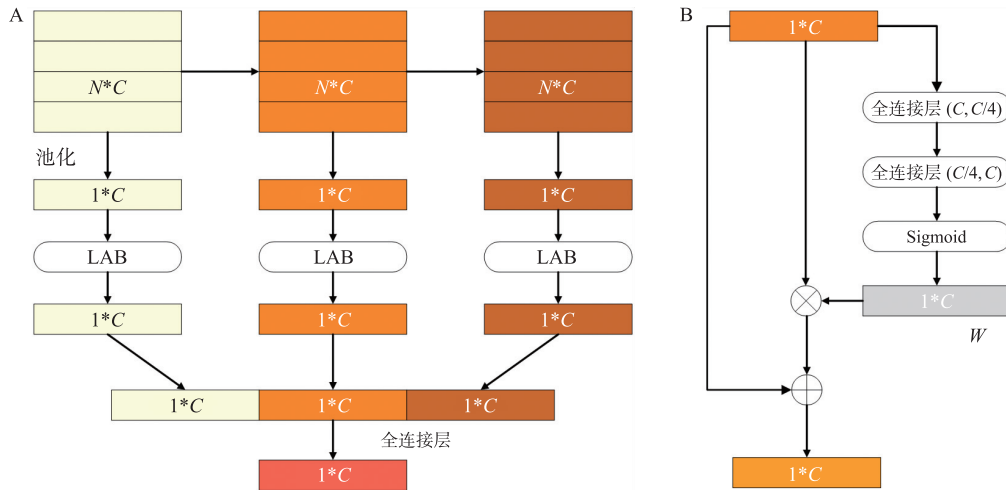


图 7 注意力多层感知机 (AMLP) 结构图

Fig. 7 The framework of attentive multi-layer perceptron (AMLP)

A. AMLP 模块 AMLP module; B. LAB 模块 LAB module.

1.5.3 金字塔点云生成模块 D 本文借鉴了 PF-Net^[10] 中的点云金字塔解码器 (PPD) 分层生成缺失点云的思想,由粗略到精细逐层提取的特征,逐步完成补全。特征提取模块 E 输出的特征向量 V 作为金字塔点云生成模块 D 的输入,然后通过全连接层输出 $[N, N/8, N/16]$ 共 3 种长度的向量,再分别对 3 种长度的向量进行卷积,每种不同长度向量对应生成不同尺度的粗略预测点云。最低尺度分辨率点云针对一定空间范围内的中心点进行预测, $N/8$ 尺度分辨率点云针对围绕中心点预测次级中心点的相对坐标,同理,最大尺度分辨率点云围绕次级中心点进行预测,最终将 3 种分辨率的点云数据合并获得完整预测点云数据 p_{pre} 。该多尺度生成体系结构,有利于低分辨率的特征点的几何信息传递到高分辨率。

1.5.4 参数估测模块 T 参数估测模块 T 采用自编码器的结构,该模块采用由 AMLP 和全连接层组成自

编码器的特征提取器。将金字塔点云生成模块 D 最终生成结果 p_{pre} 作为参数估测模块 T 的输入,经 AMLP 提取特征后输出维度为 N 的特征向量,随后通过连续的全连接层(维度为: $[N-512-256-64-1]$)最终输出油桃的体积参数。

1.5.5 损失函数 CGRSNet 算法的损失函数主要由生成损失和对抗损失 2 部分加权组成。生成损失用来优化金字塔点云生成模块 D 的点云补全过程,减少预测结果与真实点云之间的差异,使得生成点云看起来更贴近真实点云。对抗损失用来衡量参数估测模块 T 的估测结果和真实值之间的差异程度。

对于比较无序的点云,用地球移动距离(earth movers distance, EMD)^[22]或倒角距离(chamfer distance, CD)^[23]作为度量指标,用于比较点云之间差异程度。由于 CD 较 EMD 计算量小,本文选择 CD 作为生成损失的度量指标。CD 的计算公式为:

$$d_{CD}(P_1, P_{gt}) = \frac{1}{P_1} \sum_{x \in P_1} \min_{y \in P_{gt}} \|x - y\|_2^2 + \frac{1}{P_{gt}} \sum_{y \in P_{gt}} \min_{x \in P_1} \|y - x\|_2^2 \quad (6)$$

式中: P_1 为预测点云; P_{gt} 为真实点云。

金字塔点云生成模块 D 在补全过程中有 3 个不同尺度的阶段,每个阶段都有对应的损失,所以,总的生成损失也由 3 部分构成。 d_{CD1} 、 d_{CD2} 、 d_{CD3} 分别计算了真实点云与之对应的生成点云之间的 CD 值,生成损失的总表达式为:

$$L_{com} = d_{CD1}(P_1, P_{gt1}) + \alpha d_{CD2}(P_2, P_{gt2}) + 2\alpha d_{CD3}(P_3, P_{gt3}) \quad (7)$$

式中: P_i 和 P_{gti} 分别属于不同尺度的阶段生成点云和真实点云; α 为超参数,用于动态调整低尺度点云的损失占比,从而更好地关注低尺度的特征点。

对抗损失的表达式为:

$$L_{adv} = \sum \log(T(P_{mis})) + \sum \log(1 - T(D(E(P_{inc})))) \quad (8)$$

式中: P_{mis} 为缺失点云; P_{inc} 为预测点云; D 为金字塔点云生成模块; T 为参数估测模块; E 为特征提取模块。

由式(7)和(8)可得联合损失函数:

$$L = \beta L_{com} + (1 - \beta) L_{adv} \quad (9)$$

式中: β 为生成损失和对抗损失的权重。

1.5.6 基于迁移学习的参数微调 由于实际样本数量有限,为提升拟合程度和增强泛化能力,先在较大数据集上训练网络模型,再根据目标实际数据,通过迁移学习方法对参数微调。迁移学习的目的是从源域和源域任务中获得知识,从而提高目标域中任务的准确率,迁移学习的原理^[24]为:

$$S = \begin{cases} D_s = \{ \{x_i, y_i\} \}, & i = 1, 2, \dots, n \\ T_s & \end{cases} \quad (10)$$

$$T = \begin{cases} D_t = \{ \{x_i, y_i\} \}, & i = 1, 2, \dots, m \\ T_t & \end{cases} \quad (11)$$

式中: D_s 为源域; T_s 为源域任务; D_t 为目标域; T_t 为目标域任务。

从垂直角度得到的油桃点云数据存在底部信息丢失情况,尽管可以通过 CGRSNet 的金字塔点云生成模块对预处理后的残缺油桃点云数据进行补全,从而减小丢失点对外形参数估测的影响,但是经过金字塔点云生成模块补全之后的点云数据会和真实的点云数据之间存在较小的差异。因此通过模型迁移^[25]的方法,基于真实数据对 CGRSNet 预训练模型进行微调,训练得到适用于真实油桃外形参数估测的模型(图 8)。

2 结果与分析

2.1 评价标准

为了度量回归任务中的估测值和真实值之间的差异程度,采用决定系数(coefficient of determination, R^2)

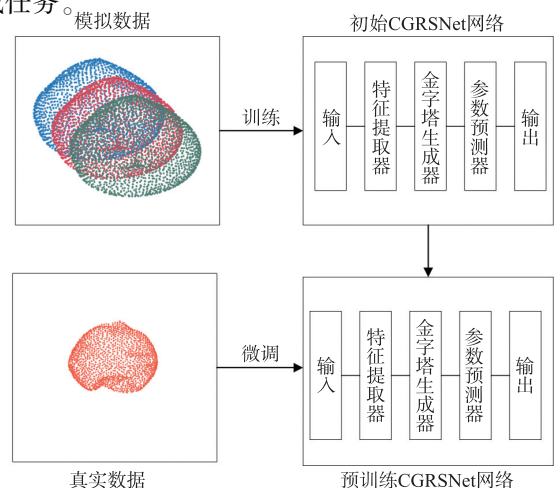


图 8 模型迁移框图

Fig. 8 Block diagram of model migration

和均方根误差(root mean square error, RMSE)评估模型的估测性能。其中 R^2 的值越接近于 1,表示拟合程度越好;RMSE 的值越低,表明模型估测能力越好。

2.2 数据集和试验参数设置

将拥有 18 602 个油桃点云仿真数据的模型库按 4:1 的比例划分为训练集和验证集,其中 14 882 个仿真数据作为原始网络模型的训练集,剩下 3 720 个仿真数据作为衡量模型对模拟数据补全性能的验证集,每个完整的仿真样本均采样 2 048 个点。不完整的点云通过在完整点云上随机取一个点作为中心点,将中心点及周围一定半径范围内共 1 024 个点删除,保留另外 1 024 个点。共采集 153 颗真实油桃点云数据和对应的外形参数。表 1 为采集到真实油桃外部表型参数实测结果统计,从表 1 可知,油桃的直径、高度、体积分别为 5.599~7.585 cm、5.403~7.440 cm、110.0~245.0 cm³。所用油桃外形参数分布范围较广,避免了样本的单一性和重复性,试验结果可靠。

使用 Pytorch 框架作为深度学习平台,使用 Adam 作为优化器,学习率设置为 0.000 1,迭代次数设置为 200,批次数设置为 32,调整公式(9)中 β 的值,选择最优结果的 β 值作为联合损失函数的权重。表 2 为不同 β 值 CGRSNet 对仿真数据预测结果。

表 1 油桃实测参数统计结果

外部表型参数 External phenotype parameters	平均值 Mean	最大值 Max	最小值 Min
直径/cm	6.381	7.585	5.599
高度/cm	6.153	7.440	5.403
体积/cm ³	149.3	245.0	110.0

表 2 不同 β 值结果对比

β	RMSE/cm ³	收敛轮次 Convergence times
0.85	23.47	60
0.90	1.42	90
0.95	2.90	130
0.98	6.74	150

由表 2 可知,当 β 为 0.90 时,模型训练过程中的误差 RMSE 最低,收敛轮次虽然相较于 β 为 0.85 较大,但 β 为 0.85 时误差 RMSE 较大。故网络的联合损失函数 β 为 0.9 时,网络估测性能最优。此时 CGRSNet 的损失函数(L)为:

$$L = 0.9L_{\text{com}} + 0.1L_{\text{adv}} \quad (12)$$

式中: L_{com} 和 L_{adv} 如式(7)和(8)所示。

2.3 油桃外形参数结果

2.3.1 仿真油桃外形参数估测结果对比分析 分析本文提出的 CGRSNet 网络、点云分形网络 PF-Net^[10]、点云修补网络 PCN^[26]以及基于 PointNet^[8]增加霍夫投票机制的 VoteNet^[27] 4 种网络模型对仿真油桃外形参数估测的结果。从表 3 可知,4 种网络模型生成的点云与之对应的真实点云之间的 CD 均较小,表明 4 种网络模型都能较准确提取到油桃点云特征。从模型训练过程中的误差 RMSE 和决定系数 R^2 的结果来看,PF-Net 网络模型和 CGRSNet 网络模型训练误差 RMSE 相比于另 2 种模型更低,决定系数 R^2 的值更高,所以 CGRSNet 网络的性能更优。验证了 CGRSNet 网络能有效捕捉油桃点云特征且较准确估测油桃体积。

表 3 不同网络模型对仿真油桃几何模型体积估测的结果

网络模型 Network model	CD/cm	RMSE/cm ³	R^2	网络模型 Network model	CD/cm	RMSE/cm ³	R^2
VoteNet	0.329	4.39	0.92	PF-Net	0.197	1.70	0.96
PCN	0.223	2.96	0.94	CGRSNet	0.184	1.42	0.98

2.3.2 迁移学习前后油桃外形参数估测结果对比分析 以实拍的 115 颗真实油桃点云数据作为训练集,38 颗真实油桃点云数据作为测试集,对 2.2 节的由 18 602 个油桃点云仿真数据训练的模型进行微调,对比实拍数据输入模型前后得到的误差 RMSE 和决定系数 R^2 ,结果如表 4 所示。在模型迁移前,基于 CGRSNet 网络模型对 115 颗真实油桃估测的体积的 R^2 为 0.90, RMSE 为 6.81 cm³。在模型迁移后,网络模型对测试集油桃估测的体积的 R^2 为 0.94, RMSE 为 2.47 cm³,倒角距离为 0.196 cm。说明基于真实油桃点云数据做模型迁移能有效提高原始网络体积估测的精度,其 RMSE 明显下降且线性回归估测 R^2 提高约 0.04,证明了基于真实数据做模型迁移的必要性和有效性。

表4 模型迁移前后油桃体积估测效果对比

Table 4 Comparison of the nectarine volume estimation before and after model migration

处理 Treatment	指标 Item	VoteNet	PCN	PF-Net	CGRSNet
模型迁移前	RMSE	20.32	12.77	8.76	6.81
Before model migration	R^2	0.81	0.85	0.88	0.90
模型迁移后	RMSE	6.03	4.25	3.35	2.47
After model migration	R^2	0.90	0.92	0.93	0.94

3 结论

本文以‘早红珠’油桃作为研究对象,提出了一种基于模拟数据和 CGRSNet 的缺失油桃外形补全和外形参数估测方法,最后基于模型迁移参数微调得到真实油桃外形参数。CGRSNet 是一种新的点云补全框架,将 AMLP 模块引入点云特征提取及外形估测中,增强了网络提取几何信息的能力。通过曲面参数方程构建油桃几何模型库,并与多组网络模型进行对比,结果表明,CGRSNet 网络具有更准确的外形补全能力和外形参数估测能力。CGRSNet 模型算法经过迁移学习后,估测的实测油桃体积的 RMSE 为 2.47 cm^3 , 体积线性回归分析的 R^2 为 0.94, 估测结果误差较小, 体积预测结果与真实值具有较高的相关性。表明 CGRSNet 模型算法准确率和拟合程度较高, 具有很好的实用性。在未来的研究中, 可改善参数估测模块, 使网络预测收敛速度更快且更准确。

参考文献 References:

- [1] 杨松夏, 陆华忠, 吕恩利, 等. 球形水果机械式大小分级技术研究现状[J]. 农机化研究, 2012, 34(8): 235-239.
Yang S X, Lu H Z, Lü E L, et al. Research status on spherical fruits mechanical grader[J]. Journal of Agricultural Mechanization Research, 2012, 34(8): 235-239 (in Chinese with English abstract).
- [2] Abasi S, Minaei S, Jamshidi B, et al. Dedicated non-destructive devices for food quality measurement: a review[J]. Trends in Food Science & Technology, 2018, 78: 197-205.
- [3] 杨再雄, 吴恋, 左建, 等. 基于人工智能的农产水果分级检测技术综述[J]. 科技创新与应用, 2021, 11(22): 41-43.
Yang Z X, Wu L, Zuo J, et al. Summary of grading detection technology of agricultural fruits based on artificial intelligence[J]. Technology Innovation and Application, 2021, 11(22): 41-43 (in Chinese).
- [4] Yuan H, Martin P, Fullerton C, et al. Refining the estimation of kiwifruit size from linear fruit dimensions[J]. Scientia Horticulturae, 2020, 262: 108878.
- [5] 彭孝东, 何静, 时磊, 等. 基于激光雷达和 Kinect 相机点云融合的单木三维重建[J]. 华中农业大学学报, 2023, 42(2): 224-232.
Peng X D, He J, Shi L, et al. Single wood 3D reconstruction based on point cloud fusion of lidar and Kinect camera[J]. Journal of Huazhong Agricultural University, 2023, 42(2): 224-232 (in Chinese with English abstract).
- [6] 陈庆光, 刘强, 张竞成, 等. 多视角三维视觉成像的苹果果形测量与分类[J]. 杭州电子科技大学学报(自然科学版), 2022, 42(4): 34-41, 56.
Chen Q G, Liu Q, Zhang J C, et al. Measurement and classification of apple shape based on multi-view three-dimensional vision imaging[J]. Journal of Hangzhou Dianzi University (Natural Sciences), 2022, 42(4): 34-41, 56 (in Chinese with English abstract).
- [7] 陈辉, 吴红艳, 杨宁, 等. 基于自适应双向切片的橙子外形主动结构光三维点云测量方法[J]. 激光与光电子学进展, 2023, 60(9): 410-419.
Chen H, Wu H Y, Yang N, et al. An active structured light 3D point cloud measurement for orange shape based on adaptive co-opposite-direction slicing method[J]. Laser & Optoelectronics Progress, 2023, 60(9): 410-419 (in Chinese with English abstract).
- [8] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 77-85.
- [9] Shu D, Park S W, Kwon J. 3D point cloud generative adversarial network based on tree structured graph convolutions[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2020: 3858-3867.
- [10] Huang Z T, Yu Y K, Xu J W, et al. PF-net: point fractal network for 3D point cloud completion[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 7659-7667.
- [11] Zhao H S, Jiang L, Jia J Y, et al. Point transformer[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). October 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 16239-16248.
- [12] 刘心溥, 马燕新, 许可, 等. 嵌入 Transformer 结构的多尺度点云补全[J]. 中国图象图形学报, 2022, 27(2): 538-549.
Liu X P, Ma Y X, Xu K, et al. Multi-scale transformer based point cloud completion network[J]. Journal of Image and Graphics, 2022, 27(2): 538-549 (in Chinese with English abstract).
- [13] 肖海鸿, 徐焕良, 马仕航, 等. 遮挡条件下基于 MSF-PPD 网络的绿萝叶片点云补全方法[J]. 农业机械学报, 2021, 52(9): 141-148.

- Xiao H H, Xu H L, Ma S H, et al. Point cloud complementation method of *Epipremnum aureum* leaves under occlusion conditions based on MSF-PPD network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(9):141-148 (in Chinese with English abstract).
- [14] 陈龙,王浩云,季呈明,等. 基于 Pointnet 和迁移学习的苹果表型参数估算研究[J]. 南京农业大学学报, 2021, 44(6):1209-1216. DOI: 10.7685/jnau.202012030.
- Chen L, Wang H Y, Ji C M, et al. Estimation algorithm of apple phenotypic parameters based on Pointnet and transfer learning[J]. Journal of Nanjing Agricultural University, 2021, 44(6):1209-1216 (in Chinese with English abstract).
- [15] Li L, Miao Z J, Liang M G. 3D reconstruction based on Kinect[C]//2014 12th International Conference on Signal Processing(ICSP). October 19-23, 2014, Hangzhou, China. IEEE, 2015:1247-1250.
- [16] Liu M H, Sheng L, Yang S, et al. Morphing and sampling network for dense point cloud completion[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7):11596-11603.
- [17] Segal A, Haehnel D, Thrun S. Generalized-ICP[C]//Robotics: Science and Systems V. Robotics: Science and Systems Foundation, 2009:435.
- [18] 陆玲, 杨勇. 计算机图形学[M]. 北京: 科学出版社, 2006:206-208.
- Lu L, Yang Y. Computer Graphics[M]. Beijing: Science Press, 2006:206-208 (in Chinese).
- [19] 陆玲, 周书民. 植物果实的几何造型及可视化研究[J]. 系统仿真学报, 2007, 19(8):1739-1741.
- Lu L, Zhou S M. Study on geometry model and visualization of plant fruit[J]. Journal of System Simulation, 2007, 19(8):1739-1741 (in Chinese with English abstract).
- [20] Edelsbrunner H, Mücke E P. Three-dimensional alpha shapes[J]. ACM Transactions on Graphics, 1994, 13(1):43-72.
- [21] Zhang C, Chen T. Efficient feature extraction for 2D/3D objects in mesh representation[C]//Proceedings 2001 International Conference on Image Processing (Cat. No.01CH37205). October 7-10, 2001, Thessaloniki, Greece. IEEE, 2002:935-938.
- [22] 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.
- [23] Fan H Q, Su H, Guibas L. A point set generation network for 3D object reconstruction from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017:2463-2471.
- [24] Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning[J]. Journal of Big Data, 2016, 3(1):1-40.
- [25] Aytar Y, Zisserman A. Tabula rasa: model transfer for object category detection[C]//2011 International Conference on Computer Vision. November 6-13, 2011, Barcelona, Spain. IEEE, 2012:2252-2259.
- [26] Yuan W T, Khot T, Held D, et al. PCN: point completion network[C]//2018 International Conference on 3D Vision (3DV). September 5-8, 2018, Verona, Italy. IEEE, 2018:728-737.
- [27] Qi C R, Litany O, He K M, et al. Deep Hough voting for 3D object detection in point clouds[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2020:9276-9285.

责任编辑: 沈 波