

基于自适应半径滤波的农业导航激光点云去噪方法研究

毕松 王宇豪

(北方工业大学电气与控制工程学院, 北京 100041)

摘要: 针对点云数据去噪操作易损失点云细节信息问题, 提出了动态半径滤波器, 该方法可在保留场景细节信息的同时获得良好去噪效果。此外, 提出基于深度卷积神经网络的种植模式判定器, 该方法可实时识别当前种植模式, 并读取相应的去噪参数。在苹果种植园、白杨树林和旱柳树林完成去噪试验, 试验结果表明, 本文方法能去除多尺度点云噪声, 有效抑制稀疏离群点、目标周围的逸出值和密集噪声, 单帧点云(6 400 点)去噪平均耗时为 43.2 ms。经自适应半径滤波去噪后, 密度聚类的平均精确率为 94.3%, 平均召回率为 78.9%, 与原始数据相比, 分别提升了 40.4%、33.9%。自适应半径滤波具有较高的实时性、通用性和鲁棒性, 能较明显地提升聚类效果, 为点云后续处理奠定良好基础。

关键词: 激光雷达; 导航; 点云去噪; 自适应半径滤波; 深度卷积神经网络

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2021)11-0234-10

OSID:



LiDAR Point Cloud Denoising Method Based on Adaptive Radius Filter

BI Song WANG Yuhao

(College of Electrical and Control Engineering, North China University of Technology, Beijing 100041, China)

Abstract: LiDAR was one of the basic sensors for agricultural robot navigation in forests. However, due to the interference of the outdoor environment, obvious noise appeared in the LiDAR data, which reduced the navigation performance. To solve the problem that point cloud details are easily lost in point cloud denoising, an denoising algorithm was proposed based on dynamic filter radii, and the denoising parameters were automatically determined. Besides, a convolutional neural network classifier was proposed, which was used to identify the planting pattern. By way of preset denoising parameters, it avoided the cumbersome parameter adjustment process and could be directly applied to dense planting and sparse planting scenarios. These approaches reduced the impact of point cloud density differences on noise removal, thereby achieving efficient denoising in large scenes. The denoising experiments in apple plantations, poplar forests and dry willow forests were completed. The results showed that the proposed method effectively removed multi-scale point cloud noise, and significantly reduced sparse outliers, dense noise, and noise around the target. It took 43.2 ms to remove the noise of a single frame point cloud (6 400 points). After denoising by the method, the accuracy rate of density clustering was 94.3%, and the recall rate was 78.9%. Compared with the original data, they were improved by 40.4% and 33.9%, respectively. The method had high real-time, versatility and robustness, and significantly improved the clustering effect.

Key words: LiDAR; navigation; point cloud denoising; adaptive radius filter; deep convolutional neural network

0 引言

激光雷达具有测量精度高、探测距离远、实时性高、受光照等外界环境因素影响小等优点, 能够提供

大范围、高分辨率的实时距离信息, 在农业机械自动导航研究中得到广泛应用^[1-2]。激光雷达在农业种植园工作时, 容易受到失落信息和逸出值干扰^[3], 从而使激光雷达输出的原始点云数据存在与实际数

据不一致的噪声数据。由失落信息和逸出值导致的噪声将降低点云特征提取和特征匹配的精度^[4],从而降低目标感知和生成导航路径的可靠性。因此对原始点云去噪是保证点云后续处理的必要也是关键的步骤,同时去噪的效果直接影响了点云数据分析的准确性^[5]。

点云去噪受到国内外学者关注,提出了基于点云数据特征、基于图像分析以及基于邻域分析等的去噪方法^[6-16]。已有研究成果对特定环境或模型具有较好的适应性,但种植园机器人工作环境相对复杂,需探测的尺度变化较大,使得点云密度整体差异较大,导致以上算法均有不适用之处^[17-18]。

种植园机器人工作场景可分为密集种植环境和非密集种植环境,此场景相对复杂多变且规模庞大。在密集种植场景中,激光点云呈连续立面状;在非密集种植场景中,激光数据表现为若干点云簇。对于不同种植模式,其点云簇形态差异较大,单一去噪参数难以适应不同种植模式中的点云去噪要求,而相同种植模式下去噪参数相似。因此,需通过判定种植模式从而选择合适的去噪参数。在上述场景中,激光点云具有密度差异大、噪声随机性强等特点^[19-20],其噪声主要来自无目标处产生的失落信息,以及目标边缘带来的逸出值。同时,农业机器人的激光雷达数据分析结果用于机器人的导航、避障等实时任务,因此点云去噪算法应具有较高的计算效率。

因此,本文提出自适应半径滤波的激光点云去噪方法,该方法主要由种植模式判定器和动态半径滤波器组成。种植模式判定器用于识别种植方式,并将场景类别信息传递至动态半径滤波器。滤波器先根据场景类别读取相应的去噪参数;然后,根据目标点到原点的欧氏距离设计该点的滤波半径;最后,处理完成所有信息点后输出去噪结果。

1 自适应半径滤波器结构

本文提出的自适应半径滤波器由点云图像转换器、种植模式判定器和动态半径滤波器组成。由于激光点云通常呈无序排列,其处理速度相对较慢,而图像数据通常为多维矩阵,处理方法更加多样且高效,更适用于场景分类。滤波器结构如图 1 所示。

如图 1 所示,自适应半径滤波器首先利用点云图像转换器将从激光雷达中获取的原始点云数据转换为二值图像。其次,场景判定层根据二值图像判断当前种植模式,并将场景类别信息传递至下一层。最后,点云去噪层将根据点云密度去噪,当处理完所有信息点,输出去噪结果。自适应半径滤波器周期

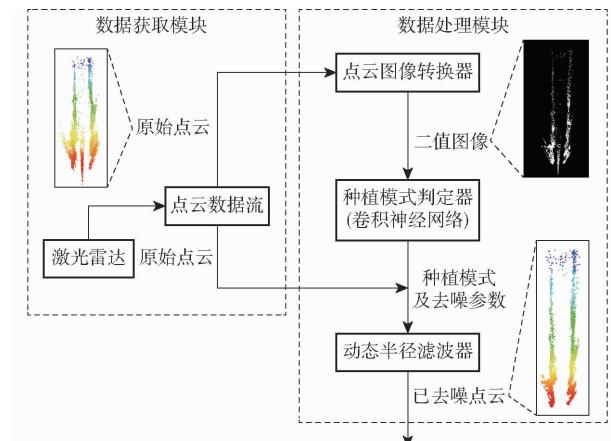


图 1 自适应半径滤波器结构图

Fig. 1 Schematic of adaptive radius filter

运行,从而使该模型对种植模式变化的场景具有良好的适应性。

2 种植模式判定器

种植园机器人运行过程中,数据采集角度和位置均具有较大的不确定性,且各种植园的株距行距不尽相同,导致激光雷达可探测的范围不同。机器人在上述条件作业时,激光点云及其二值图的特征变化明显,难以用单一特征判别种植模式。

目前,大部分传统的特征提取方法提取的特征相对较浅,如 HOG 特征、SIFT 特征、颜色特征、局部二值特征等,基于传统特征的分类器适用于某些特定场景。在复杂多变的场景中,表现并不理想,难以满足种植模式的分类需求。

深度卷积神经网络具有模型层次深、特征表达能力强的特点,能自适应地从大规模数据集中学习当前任务所需要的特征表达,广泛应用于图像分类问题。因此,本文采用深度卷积神经网络作为种植模式判别器。卷积神经网络以转换后的二值图像为输入,判断并输出其种植模式。

由于该方法应用于实时性较高的场景,所以,在轻量化模型 MobileNetV2^[21] 的基础上,本文重新调整并精简了瓶颈层(Bottleneck)结构和卷积核数量,网络结构如图 2 所示。

图 2 中,Conv3BN 为 3×3 卷积正则化层,Conv1BN 为 1×1 卷积正则化层,DWConv3BN 为深度可分离卷积正则化层,卷积核尺寸为 3,深度可分离卷积能显著降低参数量和运算量,在轻量化网络中广泛使用^[23]。首先,二值图经过卷积正则化层提取 3 幅尺寸为 112×112 的特征图,之后经过瓶颈层和瓶颈残差层^[21] 提取更高维特征。为使网络更加高效,在网络中主要使用深度可分离卷积提取特征。此外,在网络中加入残差模块,此方法可有效抑制梯

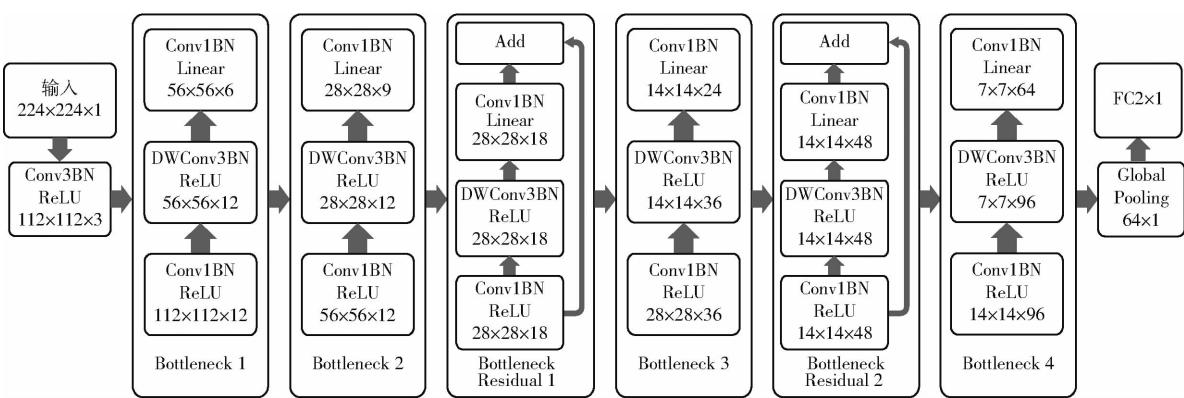


图 2 网络模型示意图

Fig. 2 Schematic of network model

度消失和梯度爆炸问题。在网络末端,将 64 幅 7×7 特征图进行全局池化,转换为特征向量,由于共有密集种植和非密集种植两个类别,因此,经全连接层变换为含有两个元素的一维向量。

本文在训练阶段利用 Softmax 分类器将预测类别与标签类别比较得到其交叉熵损失,进而使用适应性矩估计算法(Adaptive moment estimation algorithm, Adam)优化损失函数使其收敛。在推理阶段,神经网络输出当前图像所属标签,即当前种植模式,读取预置的去噪参数后,将两类信息传递至动态半径滤波算法,从而有针对性地抑制不同种植模式下的点云噪声。

3 点云去噪方法

基于半径滤波的点云去噪方法具有处理速度快、通用性强、去噪效果稳定的优点而得到广泛应用^[22],但该类方法对于密度差异较大的点云数据,存在去噪不完全或者细节损失较严重的缺点,从而限制了该类方法在户外点云去噪的应用。由于目标点距离和点云密度存在相关关系,本文根据目标点到原点的欧氏距离设计该点的滤波半径,从而实现与密度相适应的动态半径滤波器。

3.1 半径滤波

半径滤波的基本原理是考察点云中以某个点为中心的指定半径空间范围内相邻点的数量作为判断该点是否为孤立点的依据^[12-13]。若相邻点数量大于等于指定阈值,则该点为非孤立点并予以保留,反之为孤立点予以去除。半径滤波示意图如图 3 所示,图中点云密度相对一致,设定近邻数量为 N ,数据点 A_i 为中心、 r 为半径的邻域内的实际近邻数目为 n_i 。当 $n_i \geq N$ 时,保留数据点 A_i ;反之,则删除该点。

图 3 中,当指定至少有 2 个近邻,即 $N = 2$ 时,只有点 A_1 被删除;如果指定 $N = 3$ 时,则 A_1 和 A_3 都被删除。

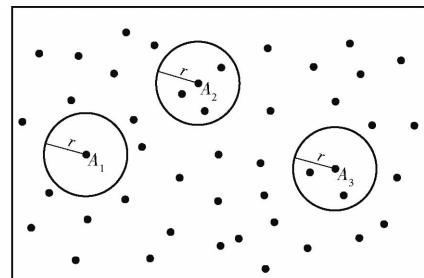


图 3 半径滤波示意图

Fig. 3 Two-dimensional schematic of radius filtering

3.2 动态半径滤波

半径滤波方法的效果与选取的半径参数相关,而半径参数与区域点云密度相关。若探测范围内点云密度相对均匀,则根据点云密度可选取适当的半径参数;若点云密度差异较大,则应根据点云密度动态改变去噪操作的半径。

单位矩形内的点云平均间距是衡量点云密度的重要指标,平均距离越大,点云密度越低;点云间的平均间距越小,点云密度越高。单位矩形 T 中,点云数量、平均间距和点云密度计算公式为

$$m = \frac{2 \arctan \frac{h}{2l}}{r_h} \frac{2 \arctan \frac{w}{2l}}{r_v} \quad (1)$$

$$s = \sqrt{\frac{hw}{m}} \quad (2)$$

$$\rho = -s + c \quad (3)$$

式中 m —单位矩形的点云数量,个

s —点云的几何平均间距,m

ρ —点云密度,m

h —单位矩形高,m

w —单位矩形宽,m

l —激光雷达与单位矩形的距离,m

r_h —水平方向激光雷达的角分辨率,(°)

r_v —垂直方向激光雷达的角分辨率,(°)

c —点云的单位间距,几何意义为单位面积内仅有单个点云时的平均间距,m

计算方法对应示意图如图 4 所示。

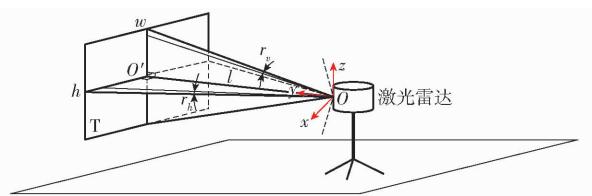


图 4 点云平均间距计算方法示意图

Fig. 4 Schematic of calculation method of average point cloud distance

基于公式(1)~(3),研究变量 r_h 、 r_v 、 l 和点云间距 s 、点云密度 ρ 之间的关系,文中采用等边单位矩形,即 h 、 w 相同。单位矩形垂直于激光雷达中心 O 与 y 轴的延长线上,且矩形中心 O' 与 Oy 共线,四者关系如图 5~7 所示。

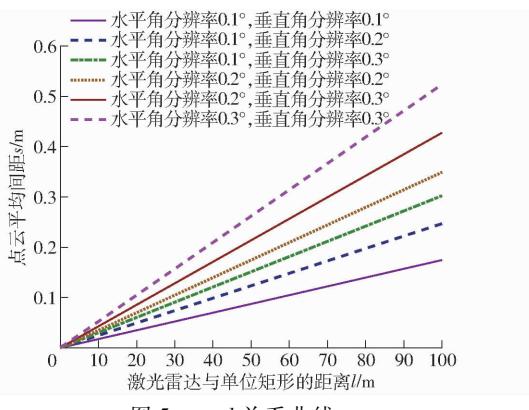


图 5 $s - l$ 关系曲线

Fig. 5 $s - l$ relationship curves

由图 5~7 可知,平均间距 s 随距离 l 增加而增加,点云密度 ρ 随之降低,在近距离区域,点云密度 ρ 加速降低,其他区域的点云密度 ρ 与距离 l 呈近似线性负相关。

经理论分析可知:理想条件下,当单位矩形与激光雷达的距离为 0 时,点云密度达到最大值,即 $\rho = 1 \text{ m}$;当点云密度等于 0 时,单位矩形内的点云处于

$$\rho'(l) = -\frac{\frac{h^2 w r_h r_v}{8l^2 \arctan\left(\frac{h}{2l}\right)^2 \arctan\left(\frac{w}{2l}\left(\frac{h^2}{4l^2} + 1\right)\right)} + \frac{h w^2 r_h r_v}{8l^2 \arctan\frac{h}{2l} \arctan\left(\left(\frac{w}{2l}\right)^2 \left(\frac{w^2}{4l^2} + 1\right)\right)}}{\sqrt{\frac{h w r_h r_v}{\arctan\frac{h}{2l} \arctan\frac{w}{2l}}}}$$
(4)

$\rho'(l)$ 与 l 的关系曲线如图 8 所示。

分析图 7、8 可知,在激光雷达附近区域(半径 1.5 m 内)的点云密度变化率 $\rho'(l)$ 逐渐减小,点云密度缓慢降低(图 7);在半径 1.5 m 以外区域,点云密度变化率 $\rho'(l)$ 无明显变化,近似为常数,点云密度 $\rho(l)$ 与距离 l 可近似为线性负相关。

综合以上分析,除激光雷达附近的点云外,其他区域的点云密度近似线性减小。激光雷达常用于较

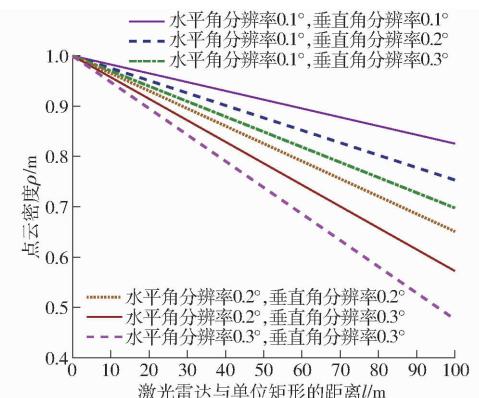


图 6 $\rho - l$ 关系曲线

Fig. 6 $\rho - l$ relationship curves

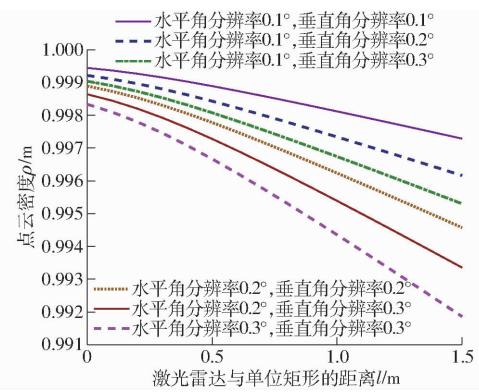


图 7 $\rho - l$ 关系曲线(近距离区域)

Fig. 7 $\rho - l$ relationship curves(close range)

消失的临界。

距离 l 相同的条件下,激光线越密集,分辨率越高,角分辨率 r_v 、 r_h 数值越小,平均间距 s 越小,表明具有更高的点云密度 ρ 。由于等边矩形的 h 、 w 相同,根据式(1)、(2)可知,此条件下的 r_v 、 r_h 具有对称性,例如, $r_v = 0.1^\circ$ 、 $r_h = 0.2^\circ$ 与 $r_v = 0.2^\circ$ 、 $r_h = 0.1^\circ$ 两种条件下的点云密度 ρ 一致。为进一步研究点云密度与距离的关系,对式(3)进行求导,点云密度变化率的计算公式为

$$\rho'(l) = -\frac{\frac{h^2 w r_h r_v}{8l^2 \arctan\left(\frac{h}{2l}\right)^2 \arctan\left(\frac{w}{2l}\left(\frac{h^2}{4l^2} + 1\right)\right)} + \frac{h w^2 r_h r_v}{8l^2 \arctan\frac{h}{2l} \arctan\left(\left(\frac{w}{2l}\right)^2 \left(\frac{w^2}{4l^2} + 1\right)\right)}}{\sqrt{\frac{h w r_h r_v}{\arctan\frac{h}{2l} \arctan\frac{w}{2l}}}}$$
(4)

远距离点云信息的获取,点云密度非线性变化的区域集中在激光雷达附近,所占比重较低,而且本文所用激光雷达的探测范围为 0.4~28 m,在此区域点云密度近似线性变化。

激光雷达输出点云密度随目标点距离增大而减小,其点云密度分布示意图如图 9 所示。

由图 9 可知,近距离区域和远距离区域的点云密度差异较大,点云密度与探测距离近似线性负相

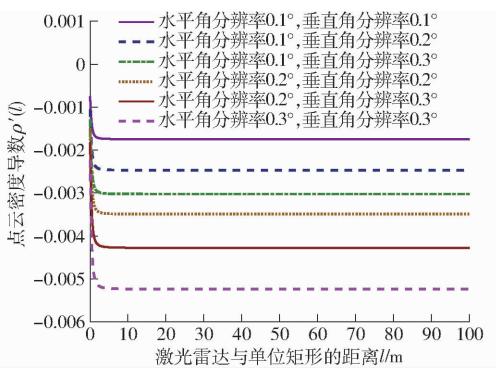
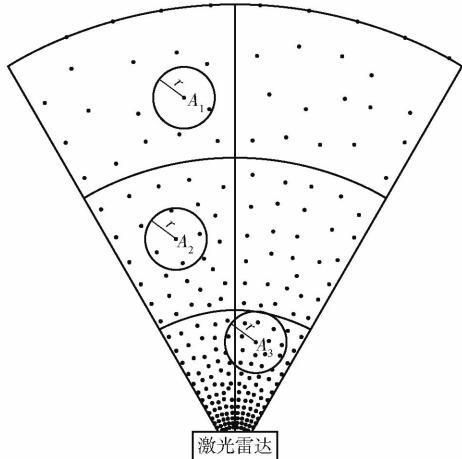
图 8 $\rho'(l)-l$ 关系曲线Fig. 8 $\rho'(l)-l$ relationship curves

图 9 激光雷达点云密度分布示意图

Fig. 9 Schematic of LiDAR point cloud density distribution

关,点云噪声密度分布同样符合以上特性, A_1 、 A_2 、 A_3 以 r 为半径的邻域内分别具有 1、4、15 个近邻,其数量差异明显,由于半径滤波参数固定,在场景中,容易出现过度去噪或噪声残留问题,实际效果并不理想。

降低点云密度变化的影响是提高去噪准确性的关键方法之一。点云距离激光雷达越远,其密度越稀疏,滤波半径应增大。本文根据目标点到原点的欧氏距离设计该点的滤波半径,从而有效地避免了密度对滤波过程的影响,为降低算法时间和空间复杂度,将滤波半径与探测距离视作线性相关,滤波半径计算公式为

$$r_i = Kd_i \quad (5)$$

其中 $d_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$ (6)

式中 r_i ——滤波半径

d_i ——目标点与原点的欧氏距离,本文中激光雷达所在位置为原点

K ——滤波半径相关系数

x_i, y_i, z_i ——目标点的欧氏坐标

动态半径滤波的具体步骤如下:①根据场景类别初始化滤波参数:滤波半径相关系数 K 和近邻点数量 N ,其中, K 为目标点欧氏距离的缩小比例, K

越大,则滤波半径越大, K 越小,则滤波半径随之减小; N 为近邻数量,当邻域内的点云数目小于 N 时,删除该点;反之,则保留数据点。②依据式(5)、(6)计算某目标点去噪参数:欧氏距离 d_i 和滤波半径 r_i 。③统计滤波半径 r_i 内的近邻点数 n_i ,若 n_i 小于近邻点数量 N ,则该点为离群点,删除该点;否则予以保留。当按上述步骤遍历所有目标点后,完成当前数据帧处理。

本文提出的噪声去除方法的伪代码如下:

Algorithm 自适应半径滤波方法

Input: 原始点云

Output: 去噪后的点云

while 接收到完整点云数据帧 do

 转换 原始点云 为 二值图;

 场景类别 \leftarrow 改进 MobileNetV2 (二值图);

 if 场景类别 = “密集种植” then

 动态半径滤波器 (K_1, N_1 , 原始点云);

 else

 动态半径滤波器 (K_2, N_2 , 原始点云);

end

function 动态半径滤波器 (K, N , 原始点云)

 for $i \leftarrow 1$ to 点云数量 do

$d_i \leftarrow \sqrt{x_i^2 + y_i^2 + z_i^2}$

$r_i \leftarrow Kd_i$

 if 以 p_i 为圆心、 r_i 为半径的邻域内的点云数量小于 N then

 删除该点;

 else

 保留该点;

 end

 end

4 试验

4.1 试验设计

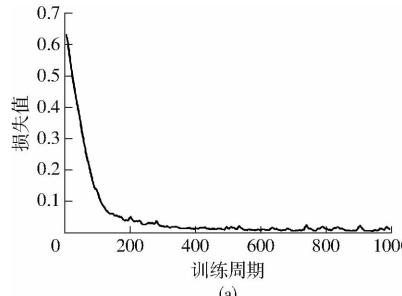
为保证数据集能够较好地反映自然条件下树林的真实特点,分别在苹果种植园、白杨树林和旱柳树林进行试验,点云采集设备为北醒光子 CE30-D 固态面阵激光雷达,其固有参数为:探测范围 0.4 ~ 28 m,视场角 $60^\circ \times 4^\circ$,分辨率 320 像素 \times 20 像素。此类场景中,激光雷达主要受到两类噪声的干扰:天空、树行尽头等无目标处产生的失落信息;树干、树枝等目标边缘产生的逸出值。试验场景及其噪声来源具有较强的代表性,且包含的信息复杂程度与农业自动导航机器人的一般工作环境相似。

同时,为验证算法有效性,将本文去噪方法与点云库(PCL)中的统计滤波、半径滤波进行对比测试,

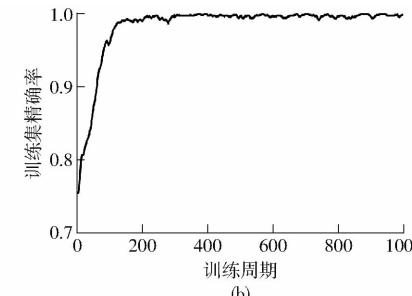
试验平台为 Intel(R) Core(TM) i7-6850K CPU, 3.60 GHz, NVIDIA 1080Ti × 4 GPU, 32 GB RAM, 500 GB SSD。

4.2 种植模式判定器

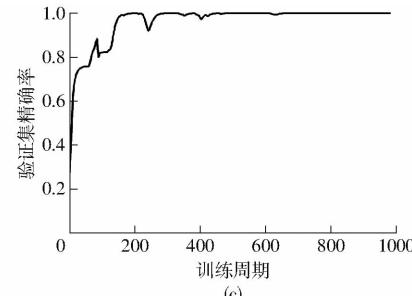
本文共收集 1 083 幅点云数据, 其中, 477 幅来自采用密集矮化种植的苹果园, 在胸高位置, 密集种植的植株间不存在明显间隙; 285 幅来自非密集种植的白杨树林, 321 幅来自非密集种植的旱柳树林, 在此种植条件下, 植株间在胸高位置存在明显间隙。



(a)



(b)



(c)

图 10 损失值和精确率随训练过程的变化曲线

Fig. 10 Curves of loss value and accuracy rate with training process

由于训练集和验证集存在差异性, 且训练初期的模型参数变化明显, 因此, 验证集精确率呈波动上升趋势, 如图 10c 所示。本文为抑制模型过拟合现象, 在训练时随机旋转数据集角度, 增加训练数据的复杂性和多样性, 提高训练集和验证集的差异, 导致验证集准确率曲线波动更加明显。随着训练周期的增加, 模型参数逐渐收敛, 分类能力趋于稳定。

训练至 702 周期时, 分类器在训练集的精确率为 0.99, 验证集的精确率为 0.98, 综合效果较好, 仅使用 CPU 的条件下, 推理速度平均为每帧 7.51 ms; 如果使用 GPU, 推理速度为每帧 7.04 ms。测试结果如图 11 所示。

4.3 去噪性能评价

本文从去噪耗时、聚类精确率、聚类召回率和 F1 分数 4 个维度评价算法性能。将去噪后的点云进行密度聚类 (Density-based spatial clustering of applications with noise, DBSCAN), 聚类结果包含 3 类信息: 噪声点云簇、目标点云簇和未被聚类点云。将聚类结果的精确率 (Precision)、召回率 (Recall) 和 F1 分数作为去噪效果的评估指标。

由于苹果种植园采用密集矮化的种植方法, 点云数据呈连续的立面状, 不适合采用聚类分析方法, 因此, 本文采用结合图像分析算法的分析方法。

4.4 去噪结果分析

点云去噪不仅应准确去除远处、近处和物体边缘的噪声, 而且目标点云簇的细节和特征应被充分保留, 为聚类、识别和融合等操作奠定基础。由于点

训练神经网络时, 先将点云数据转换成俯视视角的二值图像, 点云转二值图平均耗时为每幅图像 0.312 ms。数据集的 60% 作为训练集, 20% 作为验证集, 20% 作为测试集。

配置网络超参数如下: 批处理量为 128 幅, 学习率为 0.05, Adam 优化器, 同时, 模型训练过程中, 使用随机旋转的方法增强数据。采用边训练边评估的方式, 共训练 1 000 周期, 过程的平均损失值、训练集精确率和验证集精确率如图 10 所示。

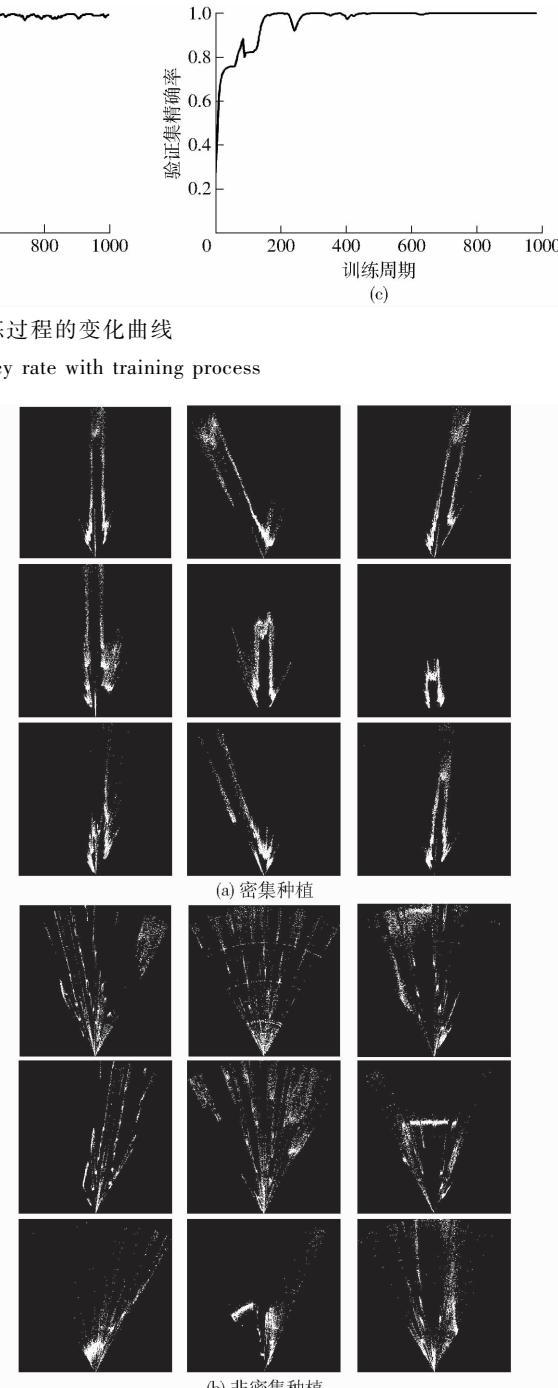


图 11 模型测试结果

Fig. 11 Model test results

云去噪为不可逆操作, 因此本文在整定去噪参数时,

以保留充足的信息量为原则,兼顾去噪效果和目标细节。

经过试验分析,3种方法去噪效果较好的参数设置如表1所示。

表1 去噪参数设置

Tab. 1 Denoising parameters setting

滤波方法	参数	密集种植	非密集种植
		场景	场景
半径滤波	近邻数量/个	6	30
	滤波半径/m	0.3	0.8
统计滤波	近邻数量/个	30	30
	标准差倍数	2	0.5
本文方法	近邻数量/个	11	30
	滤波半径相关系数	0.072	0.066

4.4.1 苹果种植园试验结果

试验地点为北京市昌平区苹果种植园,该果园采用矮化密植的种植模式,株行距为1 m × 3 m,如图12所示。



图12 苹果种植园试验场景

Fig. 12 Apple plantation test scene

在图12所示的场景中,点云噪声主要来自两方面:枝叶边缘带来的逸出值,如图13a的虚线框所示;部分激光束穿过枝叶间隙到达无目标处,带来失落信息,表现为近距离密集噪声,如图13a的实线框所示。去噪方法应有效抑制目标边缘的逸出值和近距离密集噪声,且保留丰富的点云信息。

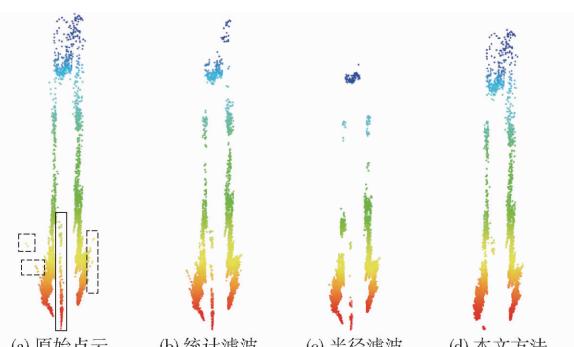


图13 苹果种植园试验结果

Fig. 13 Apple plantation test results

图13b为统计滤波结果,近距离区域存在大量密集噪声;在远距离区域内,行两侧的点云细节有所

丢失。图13c为半径滤波结果,稀疏离群点被有效去除,但近距离区域存在较多密集噪声,而且两侧的点云信息损失严重。图13d为本文提出的自适应半径滤波试验结果,稀疏离群点、密集噪声被有效去除,激光雷达前方几乎不存在密集噪声,两侧点云细节保留完整。

综合比较以上去噪结果,本文提出的自适应半径滤波不仅去除了更多密集噪声,而且细节更丰富。

4.4.2 白杨树林试验结果

试验地点为山西省太原市尖草坪区的白杨树林,株行距为3 m × 3 m,如图14所示。



图14 白杨树林试验场景

Fig. 14 Poplar forest test scene

在图14所示的场景中,噪声主要来自两方面:分布在树干边缘的逸出值;林间无目标处的失落信息,表现为近距离密集噪声,两种噪声均应被算法明显抑制。逸出值和密集噪声原始点云数据如图15a所示,图15中一种颜色代表一个经DBSCAN聚类的点云簇,黑色点云为未能聚类的点。

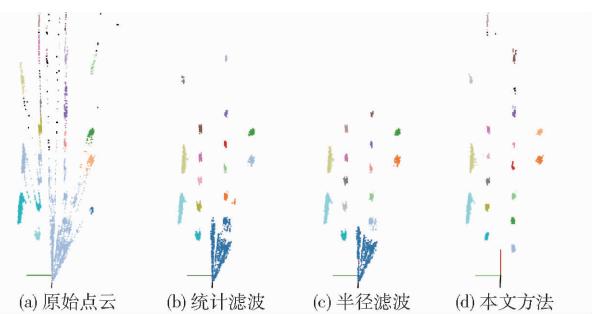


图15 白杨树林试验结果

Fig. 15 Poplar forest test results

图15b和图15c为统计滤波和半径滤波试验结果,两种方法均可有效抑制离群噪声和拖点,但近距离区域内存在大量密集噪声。图15d为本文提出的自适应半径滤波试验结果,稀疏离群点、密集噪声和目标周围的拖点被有效去除,在远距离区域,目标细节和数量保留较完整。

综合比较以上去噪结果,半径滤波和统计滤波能有效去除明显离群点和少量密集噪声,但对于密度差异较大的长距离激光点云,噪声去除率较低。本文方法可有效抑制不同密度中的噪声,且目标特征保留较完好。

4.4.3 旱柳树林试验结果

试验地点为山西省太原市尖草坪区旱柳树林,株行距为 $3.5\text{ m} \times 3.5\text{ m}$, 如图 16 所示。



图 16 旱柳树林试验场景

Fig. 16 Dry willow forest test scene

图 16 所示的场景中均匀种植着旱柳树,与白杨树相比,此树种的胸径较细,更容易损失目标信息,去噪难度相对更大。图 17a 为原始点云,噪声来源与白杨树林一致,但由于树木分布更加稀疏,林间无目标处的失落信息更多,算法应有效去除散布在树木周边的逸出值和近距离的密集噪声。

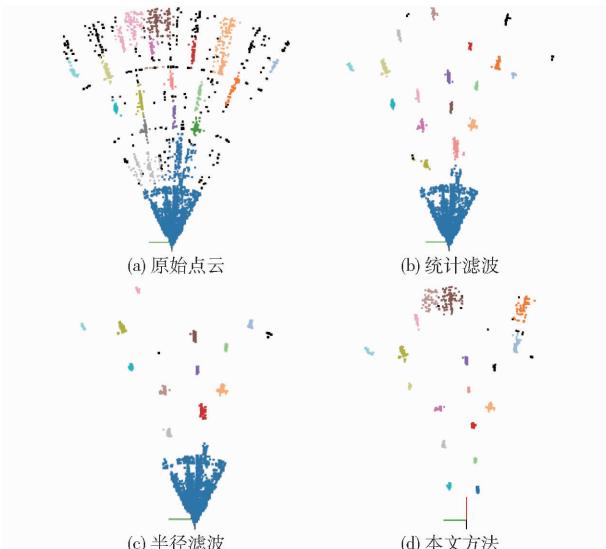


图 17 旱柳树林试验结果

Fig. 17 Dry willow forest test results

图 17b 和图 17c 为统计滤波和半径滤波试验结果,两种方法均可有效抑制离群噪声和拖点,但近距离区域内存在大量密集噪声,半径滤波在远距离区域目标数量和细节相对更少。图 17d 为本文提出的自适应半径滤波试验结果,稀疏离群点、密集噪声和目标周围的拖点被有效抑制,目标数量和细节损失更少。

综合比较 3 种去噪方法,由于半径滤波和统计滤波参数固定,容易出现细节损失和噪声残留的问题,本文方法根据点云密度动态调整去噪参数,可有效抑制不同点云密度中的噪声,且目标特征保留相对完整。

4.4.4 量化分析

点云的噪声数量直接影响聚类或识别的精度,经过去噪的点云有利于提升聚类的精确率和召回率。首先,对原始数据依次用统计滤波、半径滤波和本文提出的自适应半径滤波进行去噪,并统计去噪时间,本文方法的去噪时间由 3 部分组成:点云转换图像、神经网络推理和自适应半径滤波;其次,针对白杨树林和旱柳树林原始数据和滤波结果,依次进行 DBSCAN 聚类,计算其精确率、召回率和 F1 分数。由于苹果种植园采用密集种植方法,点云呈连续的立面状,不适合做聚类分析。白杨树林和旱柳树林的聚类真值如图 18 所示。

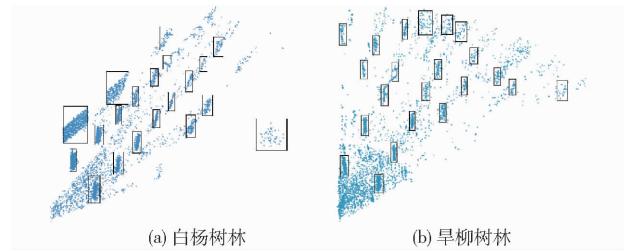


图 18 DBSCAN 聚类真值

Fig. 18 Ground truth of DBSCAN

图 18 中的矩形框中为目标点云簇,白杨树林和旱柳树林的聚类真值分别为 20 和 22,其余部分为点云噪声或信息量很少的点云。结合图 15 和图 17 中的聚类信息,计算精确率、召回率和 F1 分数,结果如表 2 所示。

表 2 不同方法的去噪结果

Tab. 2 Denoising results of different method

评价指标	原始数据	统计滤波	半径滤波	本文方法
精确率/%	白杨树林	50.0	87.5	93.3
	旱柳树林	57.9	93.8	92.3
	平均值	53.9	90.6	92.8
召回率/%	白杨树林	40.0	70.0	70.0
	旱柳树林	50.0	68.2	54.5
	平均值	45.0	69.1	62.3
F1 分数/%	白杨树林	44.4	77.8	80.0
	旱柳树林	53.7	78.9	68.6
	平均值	49.1	78.4	74.3
去噪耗时/ms	苹果种植园		36.1	35.4
	白杨树林		52.1	51.9
	旱柳树林		48.5	47.4
	平均值		45.6	44.9

综合比较统计滤波、半径滤波和本文提出的自适应半径滤波 3 种点云去噪方法,由表 2 可知,本文方法可显著提升 DBSCAN 聚类精确率和召回率。表明基于目标点距离,设置动态滤波半径的方法有效,不仅更加有效地抑制噪声,而且保留了更丰富的

目标信息,可明显提高聚类效果,为点云的后续处理提供了更有效的数据。

此外,与点云库中的半径滤波和统计滤波相比,本文方法的去噪时间(已包含神经网络分类时间)并未明显增加。一方面,由于以上算法均基于邻域分析,去除邻域中点云的数量越多,算法迭代次数越少,耗时越短,本文方法的噪声去除率更高,因此,去噪耗时更短。另一方面,本文优化了神经网络模型,使网络模型更加符合使用条件,通过合理地裁剪卷积层、广泛使用深度可分离卷积、减少池化层等方式,不仅取得了较高的算法效率,而且保证了网络的分类精度。

4.4.5 综合分析

在苹果种植园、白杨树林和旱柳树林等大场景中,点云密度相差较大,本文中的数据点间平均距离相差约70倍,而半径滤波、统计滤波的参数固定,不能根据点云密度动态调整,去噪效果容易受到点云密度、数据点间距的影响,实际效果并不理想。

经分析,在密集种植和非密集种植场景中,激光点云的形态特点差异较大,通常需要采用多组去噪参数,本文通过提前预置参数并使用神经网络分类器的方式,有效地提升了方法的适应性。

本文提出动态半径滤波器,利用点云密度与探测距离近似负相关的特性,根据目标点到原点的欧氏距离,有针对性地设计该点的滤波半径,从而有效地避免了点云密度差异对去噪的影响,实现有效抑制噪声的同时,保留更加丰富的场景细节。

该方法共有2个参数:近邻数量和滤波半径相关系数。近邻数量相同时,增大滤波半径相关系数,噪声去除能力有所减弱;在滤波半径相关系数一定

时,适当增大最小近邻数可提升滤波效果。经试验:在密集种植场景,点云呈连续面状,选择较多的近邻数量和较大的滤波半径相关系数有利于保持点云特征并提高去噪效果;而在非密集种植场景,激光数据表现为若干点云簇,近邻数量较多且滤波半径相关系数较大时,目标信息损失较少,噪声抑制效果更加显著。

综上所述,本文提出的自适应半径滤波不仅能有效去除稀疏离群噪声,而且对密集噪声、目标周围的噪声同样有较明显的抑制效果。此外,与半径滤波和统计滤波相比,耗时基本一致,具有较高的实时性,可适用于密集种植、非密集种植场景。自适应半径滤波保留了更加丰富的目标信息,较明显地提升了聚类精确率和召回率,有利于提升后续点云处理的效果。

5 结论

(1)提出一种种植模式判定器,用于识别当前所处种植环境,通过预置去噪参数的方式,避免了繁琐的调参过程,可直接应用于密集种植和非密集种植场景。

(2)提出动态半径滤波器,根据目标点到原点的欧氏距离设计该点的滤波半径,从而实现滤波半径与点云密度相适应,可有效去除不同尺度噪声并保留丰富的目标点云簇,较明显地提升聚类精确率和召回率,为点云的后续操作提供良好基础。

(3)本文提出的自适应半径滤波耗时较短,不依赖有序点云和反射信息,在密集种植和非密集种植场景中,能够明显抑制多尺度点云噪声,具有较强的通用性、鲁棒性和实用性。

参考文献

- [1] 张漫,季宇寒,李世超,等.农业机械导航技术研究进展[J/OL].农业机械学报,2020,51(4):1-18.
ZHANG Man, JI Yuhuan, LI Shichao, et al. Research progress of agricultural machinery navigation technology [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (4): 1 - 18. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200401&flag=1. DOI:10.6041/j. issn. 1000-1298. 2020. 04. 001. (in Chinese)
- [2] 牛润新,张向阳,王杰,等.基于激光雷达的农业机器人果园树干检测算法[J/OL].农业机械学报,2020,51(11):21-27.
NIU Runxin, ZHANG Xiangyang, WANG Jie, et al. Orchard trunk detection algorithm for agricultural robot based on laser radar [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51 (11): 21 - 27. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20201102&flag=1. DOI: 10.6041/j. issn. 1000-1298. 2020. 11. 002. (in Chinese)
- [3] 李琦,王永珍,王骐,等.相干激光雷达距离像的噪声抑制算法研究[J].光学学报,2005,25(5):581-584.
LI Qi, WANG Yongzhen, WANG Qi, et al. Noise suppression algorithm of coherent ladar range image [J]. Acta Optica Sinica, 2005, 25 (5): 581 - 584. (in Chinese)
- [4] 李自勤,王骐,李琦,等.相干激光雷达距离像噪声机理及距离反常抑制[J].中国激光,2005,32(3):356-360.
LI Ziqin, WANG Qi, LI Qi, et al. Noises mechanism of range image in coherent laser radar and the range anomalies suppression [J]. Chinese Journal of Lasers, 2005, 32 (3): 356 - 360. (in Chinese)
- [5] 赵凯,徐友春,李永乐,等.基于VG-DBSCAN算法的大场景散乱点云去噪[J].光学学报,2018,38(10):362-367.
ZHAO Kai, XU Youchun, LI Yongle, et al. Large-scale scattered point-cloud denoising based on VG-DBSCAN algorithm [J].

- Acta Optica Sinica, 2018, 38(10): 362–367. (in Chinese)
- [6] 曹爽, 岳建平, 马文. 基于特征选择的双边滤波点云去噪算法[J]. 东南大学学报(自然科学版), 2013, 43(增刊2): 351–354.
CAO Shuang, YUE Jianping, MA Wen. Bilateral filtering denoise algorithm for point cloud based on feature selection [J]. Journal of Southeast University(Natural Science Edition), 2013, 43(Supp. 2): 351–354. (in Chinese)
- [7] GU X Y, LIU Y S, WU Q. A filtering algorithm for scattered point cloud based on curvature features classification[J]. Journal of Information and Computational Science, 2015, 12(2): 525–532.
- [8] 吴禄慎, 史皓良, 陈华伟. 基于特征信息分类的三维点数据去噪[J]. 光学精密工程, 2016, 24(6): 1465–1473.
WU Lushen, SHI Haoliang, CHEN Huawei. Denoising of three-dimensional point data based on classification of feature information[J]. Optics and Precision Engineering, 2016, 24(6): 1465–1473. (in Chinese)
- [9] 崔鑫, 闫秀天, 李世鹏. 保持特征的散乱点云数据去噪[J]. 光学精密工程, 2017, 25(12): 3169–3178.
CUI Xin, YAN Xiutian, LI Shipeng. Feature-preserving scattered point cloud denoising[J]. Optics and Precision Engineering, 2017, 25(12): 3169–3178. (in Chinese)
- [10] ROSMAN G, DUBROVINA A, KIMMEL R. Patch-collaborative spectral surface denoising[J]. Computer Graphics Forum, 2013, 32(8): 1–12.
- [11] FLEISHMAN S, DRORI I, COHEN-OR D. Bilateral mesh denoising[J]. ACM Transactions on Graphics, 2003, 22(3): 950–953.
- [12] 曾妮红, 岳迎春, 魏占营, 等. 车载 LiDAR 点云滤波的改进不规则三角网加密方法[J]. 测绘科学, 2016, 41(9): 136–139, 46.
ZENG Nihong, YUE Yingchun, WEI Zhanying, et al. An improved irregular triangular network encryption method of vehicle-borne LiDAR point clouds[J]. Science of Surveying and Mapping, 2016, 41(9): 136–139, 46. (in Chinese)
- [13] 夏春华, 施瑾, 尹文庆. 基于 TOF 深度传感的植物三维点云数据获取与去噪方法[J]. 农业工程学报, 2018, 34(6): 168–174.
XIA Chunhua, SHI Ying, YIN Wenqing. Obtaining and denoising method of three-dimensional point cloud data of plants based on TOF depth sensor[J]. Transactions of the CSAE, 2018, 34(6): 168–174. (in Chinese)
- [14] 于加其, 杨树兴, 朱伯立. 基于统计特性的激光雷达距离像噪声抑制算法[J]. 强激光与粒子束, 2015, 27(11): 66–72.
YU Jiaqi, YANG Shuxing, ZHU Boli. Noise suppression arithmetic based on statistical property of ladar range image[J]. High Power Laser and Particle Beams, 2015, 27(11): 66–72. (in Chinese)
- [15] 陈世超, 戴华阳, 王成, 等. 激光扫描数据的密集噪声剔除方法[J]. 激光与电子学进展, 2019, 56(6): 62801.
CHEN Shichao, DAI Huayang, WANG Cheng, et al. Method for filtering dense noise from laser scanning data[J]. Laser & Optoelectronics Progress, 2019, 56(6): 62801. (in Chinese)
- [16] ARVANITIS G, LALOS A S, MOUSTAKAS K, et al. Outliers removal of highly dense and unorganized point clouds acquired by laser scanners in urban environments[C]//2018 International Conference on Cyberworlds (CW). IEEE, 2018: 415–418.
- [17] 赵映, 肖宏儒, 梅松, 等. 我国果园机械化生产现状与发展策略[J]. 中国农业大学学报, 2017, 22(6): 116–127.
ZHAO Ying, XIAO Hongru, MEI Song, et al. Current status and development strategies of orchard mechanization production in China[J]. Journal of China Agricultural University, 2017, 22(6): 116–127. (in Chinese)
- [18] 胡静涛, 高雷, 白晓平, 等. 农业机械自动导航技术研究进展[J]. 农业工程学报, 2015, 31(10): 1–10.
HU Jingtao, GAO Lei, BAI Xiaoping, et al. Review of research on automatic guidance of agricultural vehicles[J]. Transactions of the CSAE, 2015, 31(10): 1–10. (in Chinese)
- [19] 韩栋斌, 徐友春, 王任栋, 等. 基于多对点云匹配的三维激光雷达外参数标定[J]. 激光与光电子学进展, 2018, 55(2): 022803.
HAN Dongbin, XU Youchun, WANG Rendong, et al. Calibration of three-dimensional lidar extrinsic parameters based on multiple-point clouds matching[J]. Laser & Optoelectronics Progress, 2018, 55(2): 022803. (in Chinese)
- [20] 薛安荣, 鞠时光, 何伟华, 等. 局部离群点挖掘算法研究[J]. 计算机学报, 2007, 30(8): 1455–1463.
XUE Anrong, JU Shiguang, HE Weihua, et al. Study on algorithms for local outlier detection [J]. Chinese Journal of Computers, 2007, 30(8): 1455–1463. (in Chinese)
- [21] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510–4520.
- [22] 鲁东东, 邹进贵. 三维激光点云的降噪算法对比研究[J]. 测绘通报, 2019(增刊2): 102–105.
LU Dongdong, ZOU Jingui. Comparative research on denoising algorithms of 3D laser point cloud[J]. Bulletin of Surveying and Mapping, 2019(Supp. 2): 102–105. (in Chinese)
- [23] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251–1258.