

光学学报

基于全景图像的无人艇激光雷达杂波滤除方法

张煌*, 何佳洲, 王景石, 蒋佳锐

江苏自动化研究所信息融合实验室, 江苏 连云港 222061

摘要 海上环境复杂, 安装在无人艇上的激光雷达在探测近艇目标过程中会产生各种杂波, 影响了无人艇对近距离船只的检测与跟踪, 威胁了无人艇自主航行安全, 因此必须对激光雷达在海上产生的各种杂波进行有效滤除。将激光雷达与全景相机进行数据关联, 实现了三维点云与全景图像在二维图像上的像素级配准, 并根据两种数据的关联结果以及对全景图像上目标船只的检测, 完成对定义三类杂波点云的滤除。

关键词 图像处理; 无人艇; 数据关联; 目标检测; 杂波滤除

中图分类号 TP391 文献标志码 A

DOI: 10.3788/AOS202242.1810001

Lidar Clutter Filtering of Unmanned Surface Vehicle Based on Panoramic Image

Zhang Huang*, He Jiazhou, Wang Jingshi, Jiang Jiarui

Information Fusion Laboratory, Jiangsu Institute of Automation, Lianyungang 222061, Jiangsu, China

Abstract The sea environment is complex, and the lidar installed on the unmanned surface vehicle will generate various useless clutters in the process of detecting the target near our vehicle. And the useless clutters will affect the detection and tracking process and threaten the safety of the unmanned surface vehicle in the process of autonomous voyage. Therefore, it is necessary to effectively filter out all kinds of useless clutters generated by lidar on the sea. In this paper, the data association between the lidar and panorama camera is carried out to achieve the pixel-level registration of 3D point clouds and panoramic images in 2D images. According to the association results of the two kinds of data and the detection of target ships on the panoramic image, the three types of point cloud clutters defined in this paper are filtered.

Key words image processing; unmanned surface vehicle; data association; object detection; clutters filtering

1 引言

随着高性能传感器设备和无人车辆驾驶技术的快速发展, 水面无人艇(USV)作为水面环境下无人驾驶的重要工具, 在国内外受到了广泛关注。无人艇的首要任务就是要能够实现自主航行, 当前自主航行任务中许多模块设计都离不开各种传感器^[1], 如光学相机、导航雷达、激光雷达、全球定位系统等。正是这些传感器对周围环境的感知, 才保证了无人艇安全、可靠的自主航行。但是单传感器既有优点也有缺点^[2], 由于海洋环境复杂多变, 其优点会被缺点覆盖, 影响自身对周围环境的感知。激光雷达擅长近距离物体检测, 能够获取环境的三维信息, 但是生成的数据存在较多的杂波; 光学全景相机的探测范围广、监测信息量大, 但是易受环境、气候的影响^[3-5]。

无人艇环境感知首先要具备良好的水面目标检测能力^[6], 只有能够实时、精准地检测出目标才能保证自主避障和自主靠离泊等功能的实现。Wang等^[7]提出了一种通过单目相机和立体视觉方法构造的USV障碍物检测系统; Kristan等^[8]提出一种新的图形模型, 可以从视频流中提供快速和连续的障碍物图像地图估计; Mei等^[9]提出一种基于特征和边缘的自适应海岸线检测方法; 齐先智^[10]提出一种基于激光雷达的无人水面艇水面目标检测与识别的方法; Weon等^[11]提出了基于速度和航向角的无人水面艇尾部水波点云去除算法; Chen等^[12]设计了一种深度融合方案, 将来自俯视图与正视图的点云区域特征结合起来; 周治国等^[13]提出了一种基于三维激光雷达的水面目标DBSCAN-VoxelNet联合检测算法; 耿磊等^[14]提出了一种基于激光雷达的多视角点云配准方法; 张长勇等^[15]提出了一

收稿日期: 2022-01-04; 修回日期: 2022-02-06; 录用日期: 2022-02-28

通信作者: *hagzhang@mail.ustc.edu.cn

种改进的 DBSCAN 算法以提高障碍物点云聚类效果。以上算法主要依靠单传感器对环境进行感知。仅通过光学相机进行感知时,环境的改变、目标的运动等因素会导致较差的感知效果;仅通过激光雷达进行感知,需要对点云数据进行大量的预处理,如杂波滤除、点云补全等。要想通过单传感器取得较好的感知效果,往往需要多个传感器来弥补单个传感器的不足。而实际应用中,与其一种传感器多设几个,不如采用多种单传感器信息融合的方式对周围环境进行感知。将激光雷达和光学相机融合构建的系统模块^[16-17]是无人艇中常用的一种方式,将两种时间、空间不完全匹配的数据进行关联融合并保证融合的准确性一直都是国内外无人领域、信息融合领域研究的难点与热点。激光点云与光学图像的关联一般采用提前标定光学相机参数使得两传感器所示场景相同的方法,本文将全景相机与激光雷达进行融合,提前标定 6 个摄像头参数会受后续图像拼接影响,导致两传感器所示场景不同,因此本文提出了自适应匹配算法用于两种数据的关联。

相较于无人车的严格交通规则,无人艇所要遵循的海事规则相对宽松,这也导致各种船只在航行时艏向角可以指向任意方向。无人车进行环境感知时车辆朝向基本一致,同体型的车之间的形态轮廓也基本一致,但无人艇航行时,所遇船只航向大不相同,目标船只轮廓由于其艏向角的不同,本艇激光雷达对同一艘船会感知出各式各样的形态轮廓。而一般的光学相机由于拍摄角度固定,同一艘船在该角度区间内的形态轮廓会基本保持一致,如果仅靠普通光学相机与激光雷达进行融合无法满足无人艇自主航行中对感知能力的要求,全景相机的优势在于 360° 无差别感知周围近距离环境,周围船只航行时各种形态也均能呈现于全景图像上,能够保证其与激光雷达融合时全方位的目标匹配。本文就激光雷达与光学全景相机信息融合问题提出一种角度与像素匹配的算法,在方位角-横轴像素匹配上采用分区匹配算法,在俯仰角-纵轴像素匹配上采用基于目标检测的自适应算法,根据匹配结果对激光雷达与全景相机的信息进行关联,再根据全景图像的目标检测结果对与其关联的激光雷达点云杂波进行滤除。本文的点云杂波滤除算法的流程图如图 1 所示。

2 海面点云杂波介绍

在无人艇按照规划航路进行自主航行时,需要能够精准地感知出本艇周围各种大小型船只,激光雷达在产生周围环境的点云时,会把量程范围内所有能反射激光的物体(未被遮挡)都刻画出来,其中包含了实物的非船只点云与非实物的离群点云。鉴于这些点云均为避障、导航、船只检测识别实验中不需要的反射源,因此本文将上述点云均定义为杂波。

2.1 杂波类型

本文根据杂波所影响目标船只的体型大小对实物的非船只点云与非实物的离群点云杂波进行了三种类

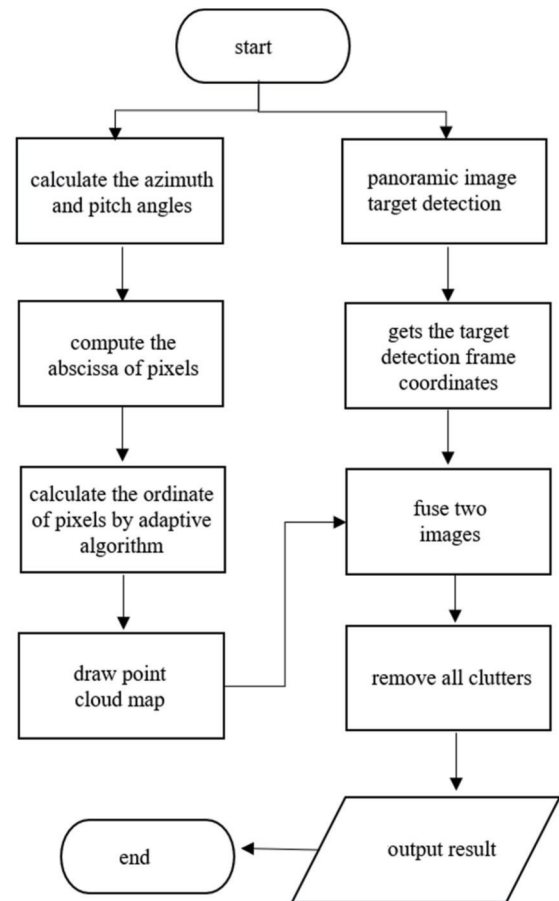


图 1 点云杂波滤除算法流程图

Fig. 1 Flow chart of point cloud clutter filtering algorithm

别的划分,无人艇自主航行时存在的各种杂波如图 2 所示。

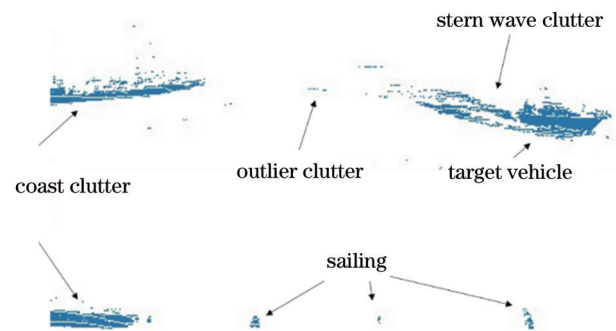


图 2 航行场景激光雷达杂波介绍图

Fig. 2 Introduction of lidar clutters in sailing scene

以下是本文所定义点云杂波的产生原因及分布特点:

1) 海岸杂波。本文中无人艇的主要试验场地为海岸港口,因此大部分场景距离海岸较近,在航行时激光雷达很容易生成海岸点云,其主要分布在点云数据中距离最远处及最边缘处。

2) 尾浪杂波。激光可以穿过水面,在水面平静时基本不会产生水面反射点云,但是有船只经过导致水面出现波浪时,激光会被起伏的波浪反射回激光雷达,

形成船只航行的尾迹点云,其主要分布在目标船的周围及后方。

3) 离群杂波。激光雷达发射的激光在传播过程中如遇到飘在水雾、盐雾等时,可能导致激光提前反射回激光雷达接收器,而这些返回的激光也会被视作正常返回的激光,因为水雾、烟雾分布不均、概率返回等特性,离散点云分布并无规律。

2.2 杂波影响

海岸杂波的分布区域广、数量多,传统感知算法即聚类算法容易将这些海岸杂波聚类为大型船体,从而导致误判。虽然可以通过设置距离参数等方法排除海岸杂波对感知算法的影响,但是距离较远的大型船只以及靠岸较近的船只会被聚类算法忽略。

船只尾浪主要分布在各种运动的目标船只周围,进行检测时可能会将尾浪也视为目标船的一部分,尾浪的分流也可能导致单个目标船只被聚类检测成多个目标,同时因为海浪的扩散性,当本艇与目标艇相对靠近时,本艇的各种决策如避障等会受到极大的影响。

离群点云看似不会对本艇的感知产生影响,但是因其分布不具备规律性,常会在一定程度上与远处的小型船只呈现相同的点云分布方式,从而导致感知算法的误检。

3 激光雷达与全景相机时空对齐

本文所用的两种传感器为激光雷达与全景相机,这两种传感器在实现无人艇环境感知功能上都有着各自的优势,同时也存在着不足。就激光雷达而言,其探测距离范围有限,本文所用激光雷达对 140 m 外目标的探测能力会大幅减弱,在探测范围内所有可反射激光的物体都会相应地反射回点云数据,因此点云数据中存在大量杂波信息。在无人艇自主航行时,激光雷达所生成的点云存在无序性即每个三维点坐标之间不存在顺序关系,存在不规律性即当前时刻周围环境不同点云也会呈不同的分布方式且这种分布方式下会因场景中物体的多少而呈现不均匀的点数。全景相机易受光照、天气等环境因素的影响,无法明确图像中目标的距离信息。

根据两种传感器的优缺点以及激光雷达数据的特性,本文采用数据关联的方式,将激光雷达产生的点云数据与全景相机产生的全景图像进行像素级单位的关联,使两种传感器各自的环境感知能力得到提升,两者的不足得到完善甚至消除。在进行二者的数据关联之前,首先要实现两种数据的时空一致对齐,时空不一致的两种数据难以关联,即便关联,关联后也会带来较大的误差。本文中无人艇上使用的激光雷达与全景相机的部分规格说明如表 1 所示。

表 1 传感器的部分规格说明
Table 1 Part of specification instructions of sensor

Sensor	Specification
Lidar	Ranging: 40 cm-200 m (target reflectivity: 20%)
	Accuracy: ± 3 cm
	Angle of view (vertical): -25° - 15°
	Angle of view (horizontal): 0° - 360°
	Speed: $300 \text{ r}\cdot\text{min}^{-1}$ / $600 \text{ r}\cdot\text{min}^{-1}$ / $1200 \text{ r}\cdot\text{min}^{-1}$ (5 Hz / 10 Hz / 20 Hz)
Panorama camera	Point number per second: 0-600000
	Size: 114.00 mm \times 108.73 mm (diameter \times height)
	Angle of view (horizontal) : 0° - 360°
	Output: 1920 pixel \times 1080 pixel
	Frame rate: 30 frames \cdot s $^{-1}$
	Anti-rolling characteristics: horizontal error after anti-rolling is smaller than 2°
	Splicing blind area: < 10 m
	Size: ≤ 750 mm \times 700 mm

3.1 空间位置对齐

在无人艇进行自主航行时,为更好地实现无人艇自主感知能力,各种传感器都会被摆放在合适的位置。又因各种传感器占用的体积不同,不存在两种传感器在空间位置的摆放上完全重合的情况,因此在数据关联之前需要将两种传感器的数据在空间上进行对齐。

本艇的激光雷达与全景相机在艇上的摆放位置如图 3 所示,世界坐标系的 Y 轴正向正对应本艇的航行方向,两传感器在世界坐标系的三个方向上的空间距离分别为 Δx 、 Δy 、 Δz ($\Delta x > 0$, $\Delta y > 0$, $\Delta z > 0$)。

激光雷达安装于艇艏,其作用区域在水平方向上

是一个 360° 的全方位区域,在垂直方向上为 -15° ~ 25° 的区域。激光雷达坐标系以激光雷达中心点为坐标原点,生成的数据为对应空间中目标物体反射表面上点的坐标。全景相机安装于艇舱上方的桅杆,其作用区域为艇周围的全 360° 的空间范围,生成的数据为以全景相机为原点所拍摄并拼接合成的全景图像。

激光雷达通过发射激光对目标进行感知,所返回的点云数据如图 4(a) 所示,全景相机所拍摄图像为 360° 范围的图像,整幅图像与空间中目标的对应关系如图 4(b) 所示。两传感器均以自身中心为原点,用光的直线传播方式对周围环境进行刻画感知,因此两者




图 3 艇体传感器位置及世界坐标系示意图

Fig. 3 Schematic diagram of position and world coordinate system of vehicle body sensor

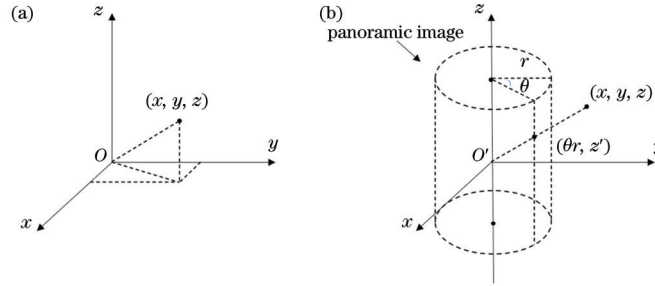


图 4 激光雷达生成点云原理图和全景相机生成全景图像原理图。(a)激光雷达生成点云原理图；(b)全景相机生成全景图像原理图
Fig. 4 Principle diagrams of point cloud generated by lidar, and panoramic image generated by panorama camera. (a) Principle diagram of point cloud generated by lidar; (b) panoramic image generated by panorama camera

对同一目标点的刻画在各自坐标系中是同一相对坐标位置。

对于同一时刻下空间中的一点 (x, y, z) , 全景相机最终所生成的全景图像与激光雷达生成的点云对应的同一点仅在原点的选择上不同, 在相机成像过程中所有的坐标系转换并不会影响最终生成的全景图像与世界坐标系里的物体(三维点云)之间的空间位置上的对齐, 两传感器在艇身上位置的不同会导致两种数据在空间上的距离差。本文将三维点云映射至二维全景图像并将其进行关联, 同时通过将激光雷达坐标系映射至全景相机坐标系来实现这一空间对齐, 激光雷达坐标系与全景相机坐标系的转换关系可表示为

$$\begin{bmatrix} X_c \\ Y_c \\ Z_c \end{bmatrix} = \begin{bmatrix} X_L \pm \Delta x \\ Y_L + \Delta y \\ Z_L - \Delta z \end{bmatrix}, \quad (1)$$

式中: (X_c, Y_c, Z_c) 为相机坐标系; (X_L, Y_L, Z_L) 为激光雷达坐标系。本文中的实验艇上两传感器在世界坐标系 X 方向上的距离为 0。

3.2 时间对齐

事实上, 即便激光雷达和全景相机的数据在空间上进行了一致性对齐, 也不能保证两者就可以感知到同一场景。在本文实验艇中: 激光雷达的转速为 10 Hz, 即每 0.1 s 会对周围 360° 空间进行一次激光扫描并输出一帧点云数据; 而全景相机帧数为 30 frames·s⁻¹, 即平均每 0.1 s 对周围 360° 环境进行三幅图像的输出。即便两传感器都是根据光来成像, 但是二者的成像速度却不尽相同, 其中激光雷达采用激光, 但是每束激光的发射时间有先后, 仅保证在 0.1 s 内完成所有的激光发射并返回, 在这 0.1 s 内目标物体

(动态) 和本艇都会发生一定的位移, 0.1 s 内最先发射的几束激光测得的点在 0.1 s 内会发生或大或小的空间位置变化, 鉴于本文的无人艇航行速度较低(小于 10 n mile/h), 暂未考虑 0.1 s 内目标船体的位移量; 全景相机当前时刻拍摄的画面需要经过相机处理后才能输出, 其所显示的时刻为最终生成的时刻, 且生成图像所需时间并不完全相同, 并不是其拍摄时刻, 同时平均 0.1 s 进行 3 frame 的拍摄也并不能保证是在均匀间隔时间进行拍摄, 最终取同一 0.1 s 内的两种数据也会有 3 种对应方式。正由于这些特点, 激光雷达与全景相机想要实现在时间上的完全一致性对齐非常困难。图 5 展示了两组数据在 0.1 s 内生成数据量的对比关系。

本文进行时间对齐时先保证起始时刻对齐, 后根据两种数据产生的间隔进行对齐, 即便如此, 随着时间的推移, 两种数据在时间上也会存在偏差。为减小偏差程度, 本文在进行处理时, 采用定时对两种待关联的数据进行校正对齐, 每经过 100 s 就根据方位角与横轴像素的匹配误差判定两种数据是否存在相对的时间超前或时间延后, 若存在则采用延后或超前的数据的策略进行误差校正, 将配准对齐的误差校正到 1% 以内以达到一定的误差控制效果。经过空间上与时间上两种数据之间的对齐, 本文获取了在时空上一致对齐的全景图像数据与点云坐标数据。

4 全景图像目标检测

本文的激光雷达点云与全景相机图像的关联策略通过将激光雷达点云由三维空间映射至二维平面并保留距离这一维度来实现。在第 2 节中, 本文对方位角与横轴像素之间的映射进行了相关阐述, 但并未对俯

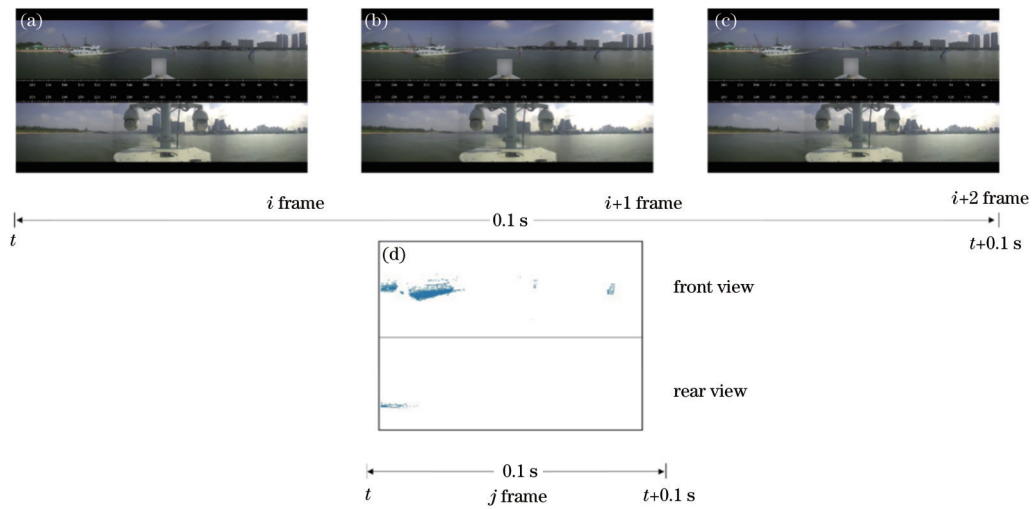


图 5 全景图像与点云在 0.1 s 内数据量的对比图。(a)~(c) 0.1 s 内拍摄的全景图像;(d) 0.1 s 内二维点云示意图

Fig. 5 Comparison of data volume between panoramic images and point cloud during 0.1 s. (a)~(c) Panoramic images taken in less than 0.1 s; (d) diagram of two-dimensional point cloud in 0.1 s

仰角与纵轴像素之间的映射关系进行详细说明,其所用的自适应配准方法需要根据全景图像目标检测来实现。

4.1 YOLOv3 网络设计

常见的目标检测网络有 YOLO 系列^[18]网络和 RCNN 系列网络。相较于 RCNN 而言, YOLO 的缺点在于识别物体位置的精准性较差,召回率低,在无人艇进行航行中,图像的目标检测通常作为辅助手段来增强短距离中无人艇的感知能力,仅靠二维图像保证物体位置的精确性是绝对不可能的,本艇同样也不会靠全景图像来确定目标的具体位置,召回率低则可以通过

与其他传感器的融合来解决。但 YOLO 的优点在于速度快、pipeline 简单、误检率低、通用性强,在无人艇航行中,目标感知的最首要任务就是实时、准确,同时因其通用性强, YOLO 系列的框架很容易并入无人艇整个系统的设计之中,因此本文在进行目标检测网络的选取时采用了 YOLO 系列的 YOLOv3 网络。

YOLOv3 网络模型采用 darknet 框架进行搭建,该网络由一系列 1×1 和 3×3 的卷积层组成,因为一共有 53 个卷积层,该 darknet 网络框架又被称为 Darknet-53,本文在使用 YOLOv3 网络时,特征图的尺寸为 416×416 ,本文中使用的 Darknet-53 的网络结构如图 6 所示。

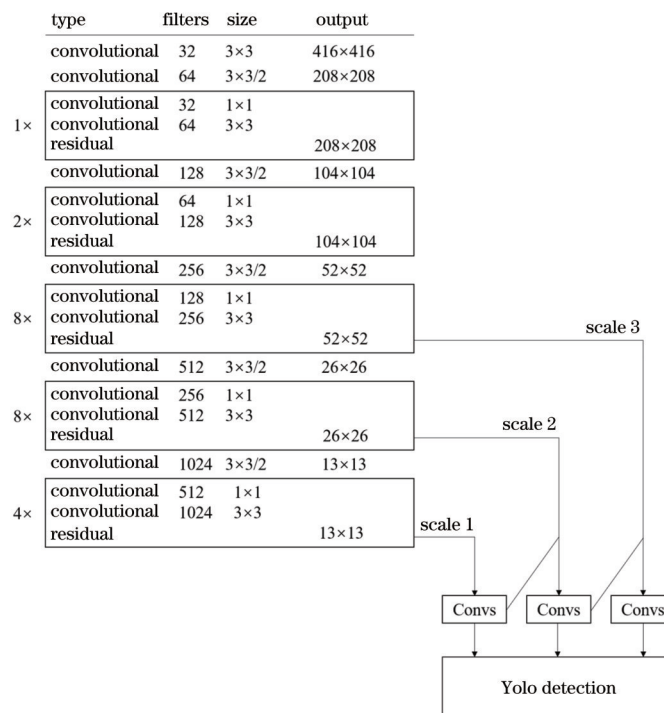


图 6 Darknet-53 的网络结构图

Fig. 6 Network diagram of Darknet-53

4.2 Yolov3 目标检测原理

Yolov3 的检测过程如下: Yolov3 将一张 416×416 的图像作为输入, 输出三层特征图, 每层特征图中有 $N \times N$ 个网格, 分别为 52×52 、 26×26 、 13×13 , 每个网格可分别用于检测目标中心点落在该网格内的目标, 每个网格会用 $(4+1+c)k$ 个大小的 1×1 的卷积核进行卷积预测, 其中 k 为预测边框的个数(初始值一般为 3), c 为预测目标的类别数, 4 为边界框中心点坐标和框的宽和高, 1 为置信度。本文中, 预测目标类数为 3, 最终可通过非极大值抑制筛选出目标检测框、输出框、类别和对应类别的置信度。

在进行边界框的宽度和高度预测时, 直接通过卷积神经网络来预测看似非常合理, 但实际上这样会在训练时带来不稳定的梯度, Yolov3 通过聚类算法在标注好的数据集中得到三组先验框(anchor box)以分别适应网络生成的三种尺度的特征图。特征图尺度越小, 对大目标越敏感; 特征图尺度越大, 对小目标越敏感。目标检测器通过预测对数空间变换来确定边界框, 网格预测中心点与边界框长度为

$$\begin{cases} b_x = \sigma(t_x) + c_x \\ b_y = \sigma(t_y) + c_y \\ b_w = p_w \exp(t_w) \\ b_h = p_h \exp(t_h) \end{cases}, \quad (2)$$

式中: t_x 、 t_y 分别为边界框在 x 和 y 方向的中心偏移量; t_w 、 t_h 分别为宽度 w 、高度 h 的放缩比; (c_x, c_y) 为预设边界框在特征图上的中心坐标; p_w 、 p_h 分别为预设边界框在特征图上的宽和高; b_x 、 b_y 、 b_w 、 b_h 为最终预测的目标边界框; $\sigma(\cdot)$ 为 Sigmoid 函数, 其目的是将预测偏移量缩放到 $0 \sim 1$ 之间。

Yolov3 损失函数由三个部分组成: 目标定位偏移量损失 $L_{\text{loc}}(x)$ 、目标置信度损失 $L_{\text{conf}}(x)$ 和目标分类损失 $L_{\text{cla}}(x)$, 损失函数可表示为

$$L(O, o, C, c, l, g) = \lambda_1 L_{\text{conf}}(o, c) + \lambda_2 L_{\text{cla}}(O, C) + \lambda_3 L_{\text{loc}}(l, g), \quad (3)$$

式中: O 为目标类别损失函数中所有目标预测框中是否存在目标的布尔值集合; C 为目标类别损失函数中所有目标预测框内存在某类目标的概率集合; o 为目标置信度损失函数中所有目标预测框中是否存在目标的布尔值集合; c 为目标置信度损失函数中所有目标预测框中是否存在目标的概率集合; l 为预测框坐标偏移量集合; g 为预测框与默认框之间的坐标偏移量集合; $\lambda_1 + \lambda_2 + \lambda_3 = 1$ 。

目标置信度即预测框内存在目标的概率, 目标置信度损失采用二值交叉熵损失表示:

$$L_{\text{conf}}(o, c) = - \sum \{ o_i \ln [\sigma(c_i)] + (1 - o_i) \ln [1 - \sigma(c_i)] \}, \quad (4)$$

式中: $o_i \in \{0, 1\}$, 表示预测目标边界框 i 中是否真实存在目标, 0 表示不存在, 1 表示存在; $\sigma(c_i)$ 为预测目标边界框 i 内存在目标的 Sigmoid 概率。

目标分类损失函数同样采用二值交叉熵损失:

$$L_{\text{cla}}(O, C) = - \sum_{i \in P} \sum_{j \in T} \{ O_{ij} \ln [\sigma(C_{ij})] + (1 - O_{ij}) \ln [1 - \sigma(C_{ij})] \}, \quad (5)$$

式中: P 表示预测框集合; T 表示类别集合; $O_{ij} \in \{0, 1\}$, 表示预测目标边界框 i 中是否真实存在目标, 0 表示不存在, 1 表示存在; $\sigma(C_{ij})$ 为预测框 i 内存在第 j 类目标的 Sigmoid 概率。

目标定位偏移量损失采用的是真实偏差值与预测偏差值之差的平方和:

$$\begin{cases} L_{\text{loc}}(l, g) = \sum_{i \in P} \sum_{m \in \{x, y, w, h\}} [\hat{l}_i^{(m)} - \hat{g}_i^{(m)}]^2 \\ \hat{l}_i^{(x)} = b_i^{(x)} - c_i^{(x)} \\ \hat{l}_i^{(y)} = b_i^{(y)} - c_i^{(y)} \\ \hat{l}_i^{(w)} = \lg[b_i^{(w)}/p_i^{(w)}] \\ \hat{l}_i^{(h)} = \lg[b_i^{(h)}/p_i^{(h)}] \\ \hat{g}_i^{(x)} = g_i^{(x)} - c_i^{(x)} \\ \hat{g}_i^{(y)} = g_i^{(y)} - c_i^{(y)} \\ \hat{g}_i^{(w)} = \lg[g_i^{(w)}/p_i^{(w)}] \\ \hat{g}_i^{(h)} = \lg[g_i^{(h)}/p_i^{(h)}] \end{cases}, \quad (6)$$

式中: \hat{l} 为预测框坐标偏移量; \hat{g} 为真值框与默认框之间的 box 与默认框之间的坐标偏移量; $b^{(x)}$ 、 $b^{(y)}$ 、 $b^{(w)}$ 、 $b^{(h)}$ 为预测的目标框参数; $c^{(x)}$ 、 $c^{(y)}$ 、 $p^{(w)}$ 、 $p^{(h)}$ 为默认矩形框参数; $g^{(x)}$ 、 $g^{(y)}$ 、 $g^{(w)}$ 、 $g^{(h)}$ 为真实目标矩形框参数; 下标 i 代表第 i 个预测目标边界框。这些参数均映射在预测特征图上。

5 点云杂波滤除

相较于全景图像较为丰富的数据信息, 激光雷达产生的有效的点云信息则非常少, 甚至在某些时段无法产生有效点云信息, 因此, 直接从激光雷达产生的点云数据中提取船只点云难以实现, 本文通过激光点云与全景图像的关联来进行点云杂波滤除, 滤除无效点云后的剩余点云则为需要的船只点云。

5.1 三维点云的二维映射

本文中的坐标系变换包括: 在两传感器空间对齐时, 将激光雷达坐标系映射变换至全景相机坐标系; 在全景相机生成图像时, 将世界坐标系映射至全景图像坐标系; 在点云图像生成时, 将三维点云坐标系映射至二维平面坐标系; 在点云图像与全景图像关联时, 将两个二维平面坐标系进行分辨率映射对齐。

在上述 4 种坐标系变换过程中, 全景图像与生成的二维点云图像具有高度的相似性, 两者在水平方向上的角度均为 360° , 在垂直角度上激光雷达的初始角度为 $-15^\circ \sim 25^\circ$, 经过坐标系变换后取 $-25^\circ \sim 25^\circ$ 内的点云, 全景相机的上下广角未知, 且会因航行时本艇吃水深度的改变而产生一定的变化。

全景图像与点云图像的坐标系变换俯视图、侧视

图如图 7 所示。全景图像与点云图像均对水平方向上 360°范围以及垂直方向上部分角度视野进行了刻画,图

7(a)中上半圆周即为全景图像所摄前方图像的俯视图,下半圆周即全景图像所摄后方的图像的俯视图。

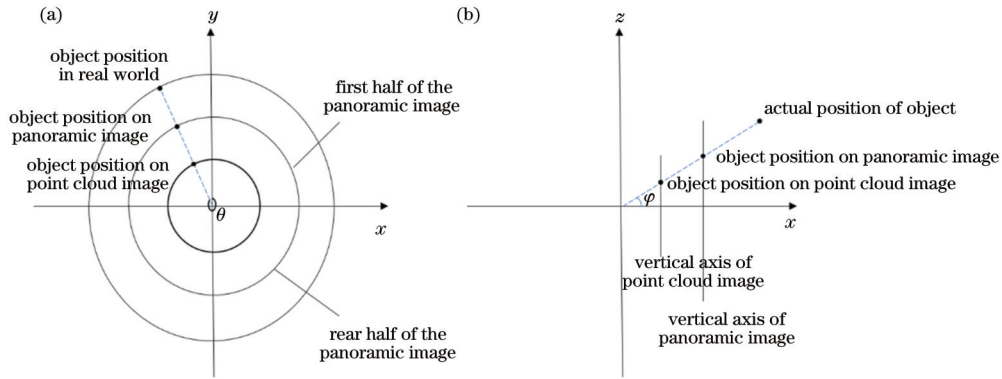


图 7 全景图像与世界坐标系的映射关系。(a)俯视图;(b)侧视图

Fig. 7 Mapping relationship of panoramic image and world coordinate system. (a) Top view; (b) side view

二维点云图像通过三维到二维的空间点映射完成从空间坐标 (x, y, z) 至平面坐标 (θ, φ) 的映射生成,其映射关系为

$$\begin{cases} \theta = \arccos\left(\frac{Y_w}{\sqrt{X_w^2 + Y_w^2}}\right) \frac{180^\circ}{\pi}, X_w > 0 \\ \theta = \arccos\left(\frac{Y_w}{\sqrt{X_w^2 + Y_w^2}}\right) \frac{180^\circ}{\pi} + 180^\circ, X_w < 0, \\ \varphi = \arctan\left(\frac{Z_w}{\sqrt{X_w^2 + Y_w^2}}\right) \frac{180^\circ}{\pi} \end{cases} \quad (7)$$

式中: (X_w, Y_w, Z_w) 为以全景相机中心为原点、正方向与全景相机坐标系相同时所构建的世界坐标系中的一点; θ, φ 分别为二维点云图像中的方位角与俯仰角。

5.2 二维点云图像的分辨率适配

全景图像的分辨率为 $1920 \text{ pixel} \times 1080 \text{ pixel}$, 点云图像的分辨率为 $558 \text{ pixel} \times 416 \text{ pixel}$, 因此还需要完成分辨率的适配, 使得水平角与方位角所表示的一个点能够对应全景图像上的某一像素点。

本文实验中的全景图像由 6 幅图像拼接而成, 每个相机拍摄的图像在最终拼接而成的图像中占据 $1/6$, 水平角度占据 60° 。考虑到由拼接算法带来的旋转校正误差以及无人艇航行过程中海浪的影响, 本文在进行分辨率适配时, 对拼接后图像的 6 个区域分别进行适配, 方位角与横轴像素的匹配原理如图 8 所示, 俯仰角与纵轴像素则采用自适应算法进行匹配。

在全景图像中, 每个相机拍摄的图像大小为 $640 \text{ pixel} \times 380 \text{ pixel}$, 横轴上 640 个像素点分别与一些角度值对应, 角度的取值范围为实数域, 而像素值的范围则是整数域, 所以在匹配过程中会出现点云中的多个点对应图像中的某一像素坐标。点云与像素横坐标的对应关系为

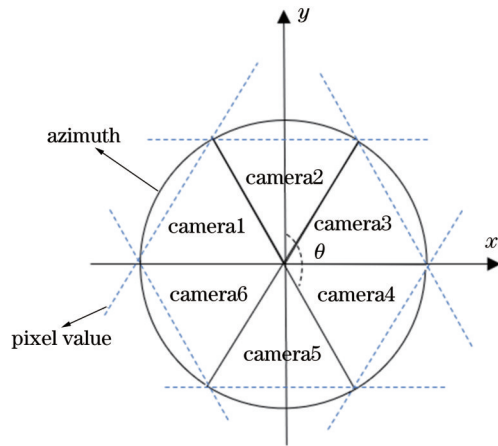


图 8 全景图像的方位角与横轴像素的关系(俯视图)

Fig. 8 Relationship between azimuth of panoramic image and pixels of horizontal axis of image (top view)

$$\begin{cases} p_{1l} = [d - \sqrt{3} d \tan(300 - \theta)] \\ p_{1r} = [d + \sqrt{3} d \tan(\theta - 300)] \\ p_{2l} = [3d - \sqrt{3} d \tan(360 - \theta)] \\ p_{2r} = [3d + \sqrt{3} d \tan \theta] \\ p_i = [(2i - 1)d \mp \tan|\theta - 60(i - 2)|], \\ i \in \{3, 4, 5, 6\} \end{cases}, \quad (8)$$

式中: p_{1l}, p_{2l} 表示相机 1、2 图像的左半部分像素坐标; p_{1r}, p_{2r} 表示相机 1、2 图像的右半部分像素坐标; $d = 320$; $i \in \{3, 4, 5, 6\}$ 时, 左半部分对应的干符号取一, 右半部分对应的干符号取+; $[\cdot]$ 为取整符号。

5.3 纵轴像素自适应匹配算法

时空一致对齐的全景图像与点云方位-俯仰角图像所展现的场景是同一场景, 在横轴上均为 360° 的空间, 在纵轴上则是受到两种传感器自身的限制来显示不同的角度范围。无人艇在航行过程中受到水面波浪

的影响,两种传感器的角度可视范围同样会改变。由于角度范围不同以及对应 0° 俯仰角的纵轴像素值会在无人艇航行时产生变化,如果采用方位角与横轴像素

的匹配方式来进行匹配会出现如图 9 所示的匹配误差,同一目标点会因水面高度而产生多种像素纵坐标。

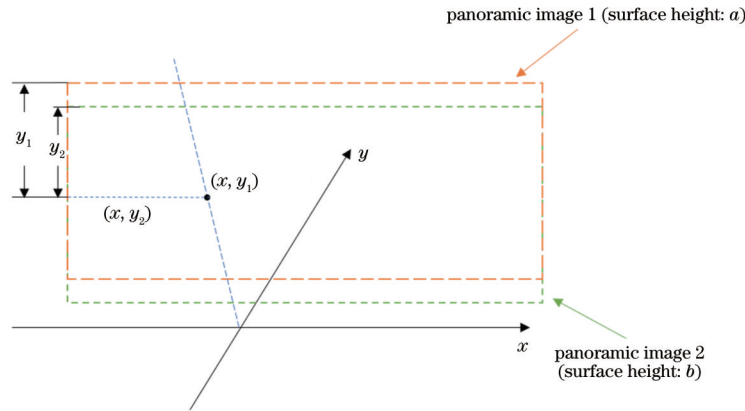


图 9 水面高度对纵轴像素的影响示意图

Fig. 9 Schematic diagram of influence of water surface height on vertical axis pixels

为解决由于水面高度变化带来的纵轴匹配误差问题,本文对全景图像中的目标进行检测,确定目标的像素框范围,进行纵轴像素匹配,使更多属于该目标的点落入检测矩形框内,完成俯仰角与纵轴像素的匹配,自适应匹配算法流程图如图 10 所示。

自适应匹配算法首先对 360° 的全景图像进行目标检测,得出场景中多个目标的矩形检测框,分别提取全景图像中 6 个区域各自包含的所有矩形检测框左上角与右下角的像素坐标, 0° 俯仰角对应的纵轴像素坐标由多次实验给出可能的先验值,按照与横轴相同的映射计算方式对各个先验值进行计算,得出矩形检测框内出现点数最多的先验值,完成纵轴匹配。

自适应算法的实物配准调整如图 11 所示,图 11 (a)~(c)各展示了一个先验值对应的点云俯仰角与全景图像纵轴像素值配准的示意图,最终统计矩形检测框内点云数量最多的一个先验值来进行 0° 俯仰角与对应纵轴像素值的配准。通过方位角映射至横轴像素坐标及自适应纵轴匹配算法,完成全景图像与激光点云像素级别的配准。

5.4 点云滤除

通过纵轴的自适应配准算法对点云俯仰角与像素纵坐标进行匹配后,点云图像已经完成了从方位角-俯仰角图向像素横-纵坐标图的转变,两种不同类型的数据也完成了关联,所有三维空间中的点云也像全景图像一样分布在 360° 的全景二维图像上,激光点云与全景图像中能反射激光的物体位置重合。

进行杂波滤除的目的是使目标船的点云能够不受杂波影响且精准地被呈现出来,在全景图像中,船只的特征比点云中更加丰富,且相较于在三维空间中滤除点云中的所有杂波而言,通过对全景图像的目标检测获取船体像素位置坐标则更加快捷方便。

本文在完成两种数据的关联并保留所有全景图像检测框中的点云后,基本完成了滤除杂波的任务。对于较大的目标船体,在进行目标检测时会有一些背景也带入检测矩形框中,背景中的一些物体同样可以反射点云,因此即便滤除了框外点云,依然会存在本文定义的杂波,此时,根据背景中的点云距离信息与目标船体点云距离信息的差异对检测框内点云进行二次滤除。

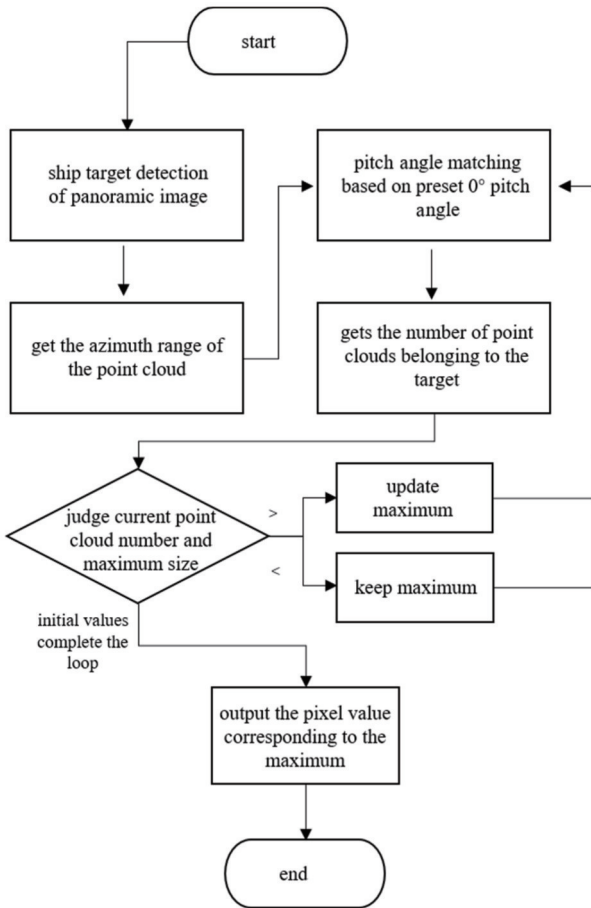


图 10 自适应匹配算法流程图

Fig. 10 Flow chart of adaptive matching algorithm




图 11 不同的图像纵轴像素值对应 0°俯仰角的目标点云配准示意图

Fig. 11 Registration diagrams of target point clouds with different vertical axis pixel values of image correspond to the 0° pitch angle

6 实验结果展示

本文杂波滤除的实验结果如图 12 所示,图 12(a)为激光雷达三维点云分布图,图 12(b)左图为将三维点云不经过坐标转换直接映射至二维平面的点云方位-俯仰角平面图,图 12(b)右图为将激光雷达坐标系与全景相机坐标系对齐后进行二维映射的点云方位-

俯仰角平面图,图 12(c)为点云方位-俯仰图与全景图像分辨率对齐后的点云像素图,图 12(d)为全景相机同时刻拍摄的全景图像,图 12(e)为图 12(d)经过目标检测并加上检验框的全景图像,图 12(f)为图 12(c)与图 12(e)的叠加结果,图 12 最下方展示了点云与实物的匹配结果。

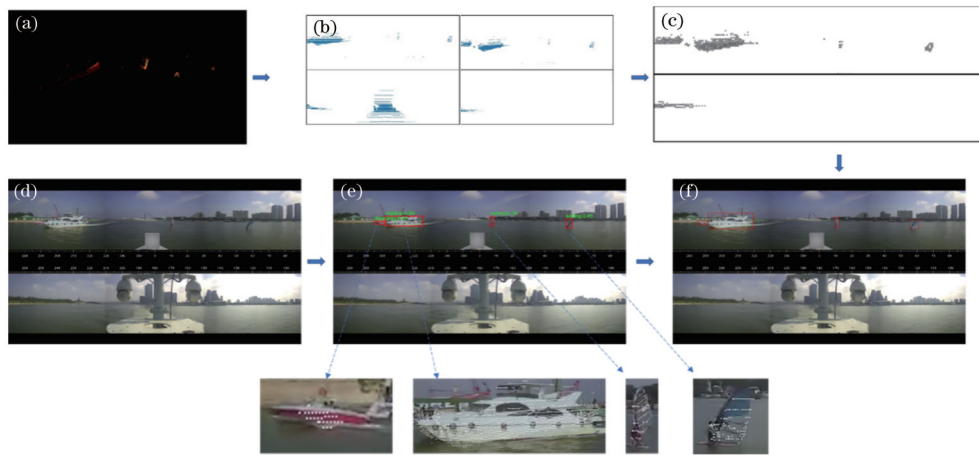


图 12 激光雷达与全景相机融合的点云杂波滤除效果图。(a)三维点云示意图;(b)二维点云示意图;(c)点云像素图;(d)全景图像;(e)全景图像目标检测图;(f)目标船只点云映射图

Fig. 12 Point cloud clutter removal effect of fusion of lidar and panorama camera. (a) Three-dimensional point cloud diagram; (b) two-dimensional point cloud diagram; (c) point cloud pixel image; (d) panoramic image; (e) target detection for panoramic image; (f) point cloud mapping of target ship

图 13 展示了图 12 场景中滤除杂波前后的点云聚类效果图,图 13(a)为未滤除杂波的前帧三维点云分布示意图,图 13(b)中展示了图 13(a)的聚类效果,图 13(c)为经过本文滤除算法滤除杂波后的当前帧三维点云分布示意图,图 13(d)中展示了图 13(c)的聚类效果。可以发现:滤除杂波后,聚类算法所聚类的目标均为船只;经过杂波滤除后,剩余的点云目标更容易被聚类检测到,同时该算法也能够提取出完整的目标船只点云。

图 14 展示了无人艇自主航行中随着本艇与目标船只的航行,同一目标船只的三维点云分布所产生的剧烈变化,如果仅靠单独的点云数据对这种剧烈变化进行目标船只点云提取,检测、识别显然会出现较大误差。激光点云与全景图像的融合策略既能充分利用点云数据中距离、方位信息,也能充分利用全景图像中目

标船只的类别信息。

为验证本文算法的优势,将本文中提出的杂波滤除算法与传统的离群点滤除算法、传统的尾浪滤除算法进行对比,采用的数据为船在港池中航行时采集到的 4622 帧点云数据(每 0.1 s 产生一帧),评价指标包括准确率、召回率和耗时。传统的离群点滤除算法采用经典的半径滤波器,半径滤波器设定半径为 1.5 m,点数阈值为 3;传统的尾浪滤除算法采用 RANSAC 算法,取距离阈值为 1 m,此时尾浪点的召回率达到 98% 以上。半径滤波器滤波算法的耗时为消除离群杂波耗时,经典 RANSAC 算法的耗时为消除尾浪杂波耗时,本文算法的耗时为消除三类杂波的平均总耗时。各算法性能对比如表 2 所示。

从表 2 的结果可以看到,与传统杂波滤除算法相比,本文提出的算法在耗时上有一定的优势,对离群点

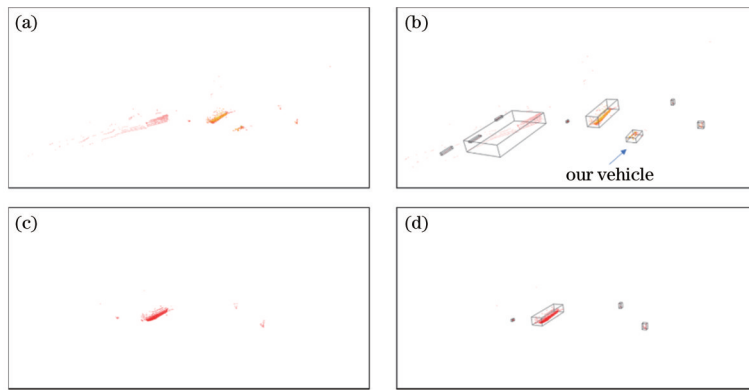


图 13 激光雷达点云杂波滤除前后聚类效果图。(a)三维点云示意图;(b)三维点云聚类示意图;(c)杂波滤除后三维点云示意图;(d)杂波滤除后三维点云聚类示意图

Fig. 13 Clustering effect of lidar point cloud before and after clutter filtering. (a) Three-dimensional point cloud diagram; (b) three-dimensional point cloud clustering diagram; (c) three-dimensional point cloud diagram after clutter filtering; (d) three-dimensional point cloud clustering diagram after clutter filtering

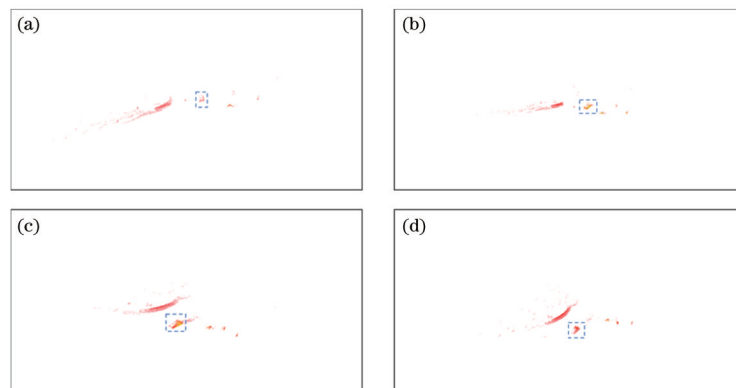


图 14 同船只点云轮廓在航行中的变化示意图。(a)目标艇与本艇对遇前三维点云分布图;(b)目标艇与本艇对遇中三维点云分布图;(c)目标艇与本艇对遇后三维点云分布图;(d)目标艇驶离本艇后三维点云分布图

Fig. 14 Changes in ships with point cloud contour in sailing. (a) 3D point cloud distribution before target ship encounters local ship; (b) 3D point cloud distribution in the encounter between target ship and ship; (c) 3D point cloud distribution after target ship encounters local ship; (d) 3D point cloud distribution map after target ship leaves ship

表 2 本文算法与传统杂波滤除算法的对比

Table 2 Comparison between proposed algorithm and traditional clutter filtering algorithms

Algorithm	Point set size	Accuracy / %	Recall / %	Time / ms
Radius filtering	6157	83.1	88.4	7.6
Classic RANSAC algorithm	6157	72.6	99.4	16.5
Proposed algorithm	6157	95.4	99.9	17.9

的滤除效果有较大提升,对尾浪杂波的滤除准确度也有较大提升。本文算法的优势如下:1)本文算法在进行杂波滤除时,无需设定各种阈值且无需寻找最优参数,本文额外滤除了不需要的海岸杂波,避免通过海岸线检测进行杂波滤除的额外耗时;2)本文进行杂波滤除时一次性滤除了所有杂波,且耗时少于多种杂波各自滤除的总耗时。

7 结 论

通过激光雷达与全景相机信息关联的方法,对激光雷达点云进行了杂波滤除,最大程度地保留了在全

景图像中被检测出来的目标船的点云,这一方法避免了直接进行点云聚类中受到各种杂波的影响;同时提出了一种提取不同船只不同方位距离的点云方法,相较于单独通过点云数据滤除杂波,本文滤除方法的精度与准确度有一定程度的提升。

参 考 文 献

[1] Elkins L, Sellers D, Monach W R. The Autonomous Maritime Navigation (AMN) project: field tests, autonomous and cooperative behaviors, data fusion, sensors, and vehicles[J]. Journal of Field Robotics,

- 2010, 27(6): 790-818.
- [2] 邹俊杰. 无人船航行环境感知方法研究[D]. 镇江: 江苏科技大学, 2020.
Zou J J. Research on navigation environment perception of unmanned ship[D]. Zhenjiang: Jiangsu University of Science and Technology, 2020.
- [3] 那田. 基于雷达和机器视觉融合的前方车辆障碍物检测[D]. 合肥: 合肥工业大学, 2016.
Na T. Detection of ahead vehicle obstacle based on radar and computer vision[D]. Hefei: Hefei University of Technology, 2016.
- [4] Prasad D K, Rajan D, Rachmawati L, et al. Video processing from electro-optical sensors for object detection and tracking in a maritime environment: a survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(8): 1993-2016.
- [5] Thompson D. Maritime object detection, tracking, and classification using lidar and vision-based sensor fusion [D]. Daytona Beach: Embry-Riddle Aeronautical University, 2017.
- [6] 朱健楠, 虞梦苓, 杨益新. 无人水面艇感知技术发展综述[J]. *哈尔滨工程大学学报*, 2020, 41(10): 1486-1492.
Zhu J N, Yu M L, Yang Y X. Overview of development of unmanned-surface-vehicle sensing technology[J]. *Journal of Harbin Engineering University*, 2020, 41(10): 1486-1492.
- [7] Wang H, Wei Z, Wang S S, et al. A vision-based obstacle detection system for Unmanned Surface Vehicle [C]//2011 IEEE 5th International Conference on Robotics, Automation and Mechatronics, September 17-19, 2011, Qingdao, China. New York: IEEE Press, 2011: 364-369.
- [8] Kristan M, Sulic K V, Kovacic S, et al. Fast image-based obstacle detection from unmanned surface vehicles [J]. *IEEE Transactions on Cybernetics*, 2016, 46(3): 641-654.
- [9] Mei J H, Arshad M R. Adaptive shorelines detection for autonomous surface vessel navigation[C]//2013 IEEE International Conference on Control System, Computing and Engineering, November 29-December 1, 2013, Penang, Malaysia. New York: IEEE Press, 2013: 221-225.
- [10] 齐先智. 基于激光雷达的无人艇水面目标检测与识别方法研究[D]. 武汉: 华中科技大学, 2020.
Qi X Z. Research on detection and recognition method of USV surface target based on lidar[D]. Wuhan: Huazhong University of Science and Technology, 2020.
- [11] Weon I S, Lee S G, Ryu J K. Virtual bubble filtering based on heading angle and velocity for unmanned surface vehicle (USV) [C]//2017 17th International Conference on Control, Automation and Systems (ICCAS), October 18-21, 2017, Jeju, Korea (South). New York: IEEE Press, 2017: 1954-1958.
- [12] Chen X Z, Ma H M, Wan J, et al. Multi-view 3D object detection network for autonomous driving[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6526-6534.
- [13] 周治国, 李怡瑶, 曹江微, 等. 基于 3D 激光雷达的水面目标检测算法研究[J]. *激光与光电子学进展*, 2022, 59(18): 1815006.
Zhou Z G, Li Y Y, Cao J W, et al. Research on surface target detection algorithm based on 3D lidar[J]. *Laser & Optoelectronics Progress*, 2022, 59(18): 1815006.
- [14] 耿磊, 曹春鹏, 肖志涛, 等. 基于激光雷达的多视角点云配准方法[J]. *激光与光电子学进展*, 2022, 59(12): 1228004.
Geng L, Cao C P, Xiao Z T, et al. Multiview point cloud registration method based on laser radar[J]. *Laser & Optoelectronics Progress*, 2022, 59(12): 1228004.
- [15] 张长勇, 陈治华, 韩梁. 基于改进 DBSCAN 的激光雷达障碍物检测[J]. *激光与光电子学进展*, 2021, 58(24): 2428005.
Zhang C Y, Chen Z H, Han L. Obstacle detection of lidar based on improved DBSCAN algorithm[J]. *Laser & Optoelectronics Progress*, 2021, 58(24): 2428005.
- [16] Chen Y S, Jilkov V P, Li X R. Multilane-road target tracking using radar and image sensors[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2015, 51(1): 65-80.
- [17] Botha F J, van Daalen C E, Treurnicht J. Data fusion of radar and stereo vision for detection and tracking of moving objects[C]//2016 Pattern Recognition Association of South Africa and Robotics and Mechatronics International Conference (PRASA-RobMech), November 30-December 2, 2016, Stellenbosch, South Africa. New York: IEEE Press, 2016: 16585476.
- [18] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2021-02-06]. <https://arxiv.org/abs/1804.02767>.