

引用格式: YUAN Shuai, YAN Xiang, XU Jingxian, et al. Cognitive Imaging Lidar Based on Deep Learning (Invited)[J]. Acta Photonica Sinica, 2021, 50(10):1011002

袁帅, 延翔, 许景贤, 等. 基于深度学习的认知成像激光雷达(特邀)[J]. 光子学报, 2021, 50(10):1011002

## 基于深度学习的认知成像激光雷达(特邀)

袁帅, 延翔, 许景贤, 朱文锐, 秦翰林

(西安电子科技大学 物理与光电工程学院, 西安 710071)

**摘要:** 为提升传统成像激光雷达系统对场景的感知能力和信号处理算法的泛化能力, 提出了一种基于深度学习的认知成像激光雷达方法, 通过深度学习点云目标检测算法的处理结果进一步调控核心成像参数, 形成认知反馈, 提升系统成像质量和环境感知能力。为验证该方法的可行性, 设计并实现了一套认知成像激光雷达演示模块, 通过实验对比分析, 选择激光器的发射功率、成像系统的扫描视场和扫描角分辨率三个成像参数进行认知反馈, 并结合深度学习方法实现了与场景的动态交互学习, 解决了传统激光雷达成像参数固化的问题。实验结果表明, 采用基于深度学习的认知成像工作模式有效提升了现有深度学习点云目标检测算法的泛化能力和目标检测精度。

**关键词:** 激光雷达; 认知系统; 深度学习; 反馈控制; 自适应算法

中图分类号: TP18; TN958.98

文献标识码: A

doi:10.3788/gzxb20215010.1011002

### Cognitive Imaging Lidar Based on Deep Learning (Invited)

YUAN Shuai, YAN Xiang, XU Jingxian, ZHU Wenrui, QIN Hanlin

(School of Physics and Optoelectronic Engineering, Xidian University, Xi'an 710071, China)

**Abstract:** To improve the scene perception ability of traditional imaging lidar system and the generalization ability of the signal processing algorithm, a cognitive method of imaging laser radar based on deep learning is proposed. Through the result of deep learning point cloud target detection algorithm, the core imaging parameters are further regulated, and the cognitive feedback is formed, improving the system imaging quality and environmental perception. To test and verify the feasibility of the proposed method, a cognitive imaging laser radar presentation module is designed and implemented. Through the experimental comparison and analysis, three imaging parameters of laser emission power, scanning field of view and scanning angular resolution of imaging system are selected for cognitive feedback, and the module combined with the deep learning method realize the dynamic interaction learning of the scene, which has solved the problem of solidification of traditional lidar imaging parameters. The experimental results show that the cognitive imaging mode based on deep learning can effectively improve the generalization ability and target detection accuracy of the existing deep learning point cloud target detection algorithm.

**Key words:** Lidar; Cognitive systems; Deep learning; Feedback control; Adaptive algorithms

**OCIS Codes:** 110.6880; 110.1085; 280.3640; 100.3005

## 0 引言

激光成像雷达因具有抗干扰能力强、探测精度高、三维信息获取全面等独特优势, 在目标识别<sup>[1]</sup>、场景建

基金项目: 国家自然科学基金(No. 61901330), 陕西省自然科学基金基础研究计划(No. 2020JQ-322), 中国博士后科学基金(No. 2019M653566)

第一作者: 袁帅(1997—), 男, 博士研究生, 主要研究方向为激光雷达信号处理。Email: shuaiyuan@stu.xidian.edu.cn

通讯作者: 秦翰林(1982—), 男, 教授, 博士, 主要研究方向为目标探测与人机融合。Email: hlqin@mail.xidian.edu.cn

收稿日期: 2021-07-29; 录用日期: 2021-09-14

<http://www.photon.ac.cn>

图<sup>[2]</sup>、地貌测绘<sup>[3]</sup>与无人驾驶<sup>[4]</sup>等领域应用广泛。然而传统的成像激光雷达难以通过系统获取的周围环境信息动态调整自身参数来实现对周围环境更精细化的感知,其主要依赖硬件和算法来完成对周围环境的理解。因此,研究具有认知能力的激光雷达具有非常重要的理论意义和应用价值。

针对传统微波雷达工作模式固定、杂波信号过大和环境干扰日益复杂等问题,HAYKIN S<sup>[5-6]</sup>首次提出了认知雷达,该雷达通过不断与环境动态交互对目标回波信号进行分析并优化发射波形,有效提升了微波雷达的系统信噪比。受此新技术的启发,KRISTINE L等<sup>[7]</sup>利用认知雷达的反馈机制和优化理论提出了面向目标检测跟踪的认知雷达新技术,该技术有效克服了前馈式雷达目标检测和跟踪准确率低的难题。LIU Hongwei等<sup>[8]</sup>提出了基于先验知识的微波雷达多波束功率认知分配方法,设计了一款认知发射器,该发射器能自适应地调整波束的发射功率从而有效提高了杂波情况下微波雷达目标跟踪精度。FERREIRA PVR等<sup>[9]</sup>提出了认知卫星通信的无线电资源分配方法,其通过引入在线学习、多目标强化学习理论实现了无线电资源的合理分配。为了解决强电磁场的射频干扰问题,ZHOU Bo等<sup>[10]</sup>提出了一种危险信号认知对抗策略,有效提升了雷达与通信设备的抗干扰能力。分析可知认知理论在协同完成场景信息感知、智能分析、动态信息反馈等任务中表现出了优越的性能。雷达通过发射和接收电磁波获取目标与环境信息,认知雷达利用获取的目标与环境信息优化发射的电磁波波形来提高雷达对目标与环境的认知能力。类似地,成像激光雷达通过发射和接收激光光束可获取目标与环境信息。

本文将认知理论引入到成像激光雷达中,利用其获取的目标与环境信息优化发射激光光束提高成像激光雷达的成像质量。

## 1 基于深度学习的认知成像激光雷达

认知雷达通过自适应的方式实时响应各种场景,具备对目标及环境信息在线感知和记忆能力。该设备能够结合先验知识,动态调整波形、资源和信号处理算法,实时优化雷达发射和接收处理模式,使系统达到与目标及环境的最优匹配,提高雷达系统的工作性能<sup>[11]</sup>。基于此,将基于深度学习的认知成像激光雷达定义为:通过深度学习点云目标检测算法处理三维场景信息,根据目标检测识别结果,在线调控成像激光雷达中激光器的发射功率、中心频率<sup>[12]</sup>、脉冲宽度<sup>[13]</sup>、成像系统的扫描视场和扫描角分辨率等重要成像参数以提升成像激光雷达的成像质量的系统。所提的基于深度学习的认知成像激光雷达工作原理如图1所示。

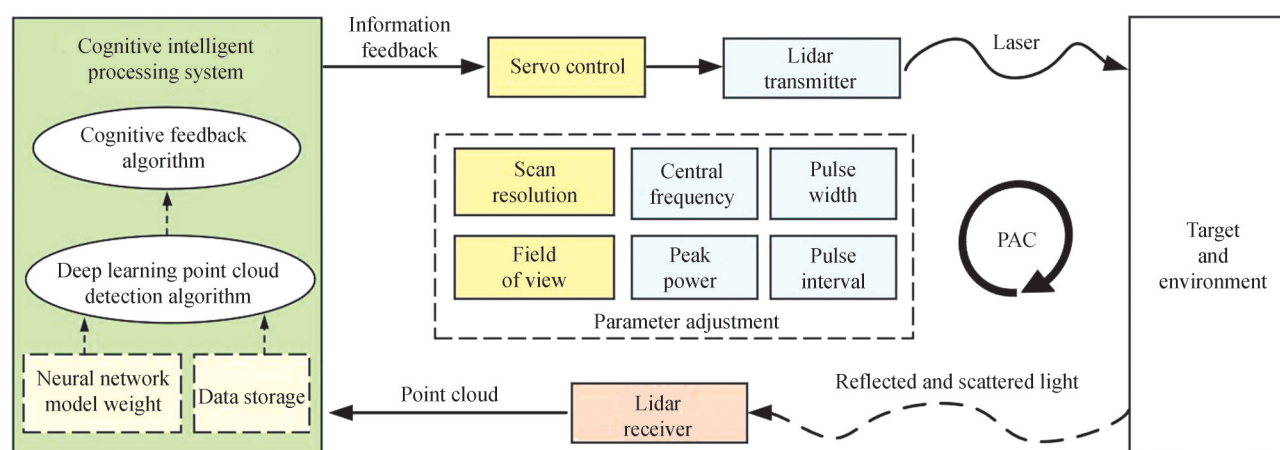


图1 基于深度学习的认知成像激光雷达工作原理

Fig. 1 Operating principle of cognitive imaging lidar based on deep learning

提出的认知成像激光雷达主要由雷达发射机、接收机、伺服控制系统和认知智能处理系统组成。认知成像激光雷达在执行目标与环境认知任务时,首先利用接收机获取的目标与环境信息形成可视化的点云数据;然后认知智能处理系统利用点云目标深度学习算法对获取的点云数据进行智能化解译,并根据解译的感兴趣区域(Region of Interest, ROI)优化激光器激光发射功率、成像扫描视场和扫描角分辨率;以此工作模式不断循环优化直到成像激光雷达的成像质量能够使得激光雷达完成对周围环境中目标的准确认知。

## 2 基于深度学习的认知成像激光雷达原理演示模块

针对传统激光雷达成像参数固化,难以与环境动态交互智能优化成像参数的问题,提出了基于深度学习的认知成像激光雷达方法,为验证该方法的可行性,自研了一套原理演示模块,实现激光发射功率、成像扫描视场和扫描角分辨率三个参数的调整。基于深度学习的认知成像激光雷达模块内部结构框图如图2所示。

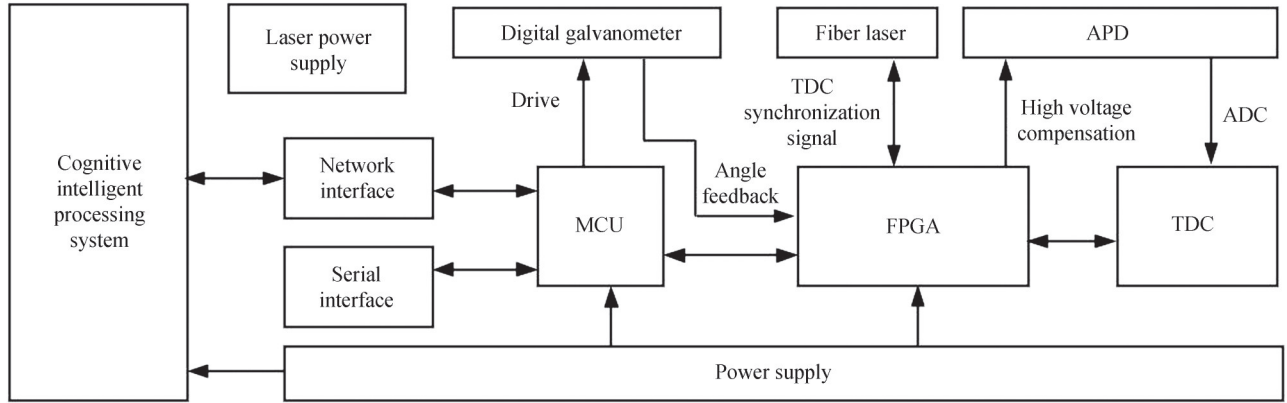


图2 模块内部结构框图

Fig. 2 Block diagram of module internal structure

在模块内部结构中,认知智能处理系统通过串口将任务指令下发到微控制单元(Microcontroller Unit, MCU)以及可编程逻辑阵列(Field Programmable Gate Array, FPGA)中,MCU驱动数字振镜根据任务指令完成扫描视场和扫描角分辨率的调控;FPGA根据任务指令控制光纤激光器改变激光发射功率。对以上三个参数调控的必要性进行分析,并提供一种基于深度学习目标检测结果的参数反馈控制方法。

### 2.1 激光发射功率

在相同场景下,采用不同激光功率对点云数据进行采集,利用 Sparsely Embedded Convolutional Detection (SECOND)<sup>[14]</sup>深度学习算法对车辆和行人两类目标点云图像进行检测。SECOND网络是基于体素的三维点云目标检测算法。该算法在Voxelnet网络基础上加入了稀疏卷积方法以提升网络运行速度,并且采用一种新的角度损失函数用来回归候选框,进一步提升方位估计性能,该网络在KITTI测试集上达到当时的最优结果。利用SECOND算法在KITTI数据集上的测试模型对同一场景不同激光发射功率下的目标检测识别结果进行对比,如图3所示。

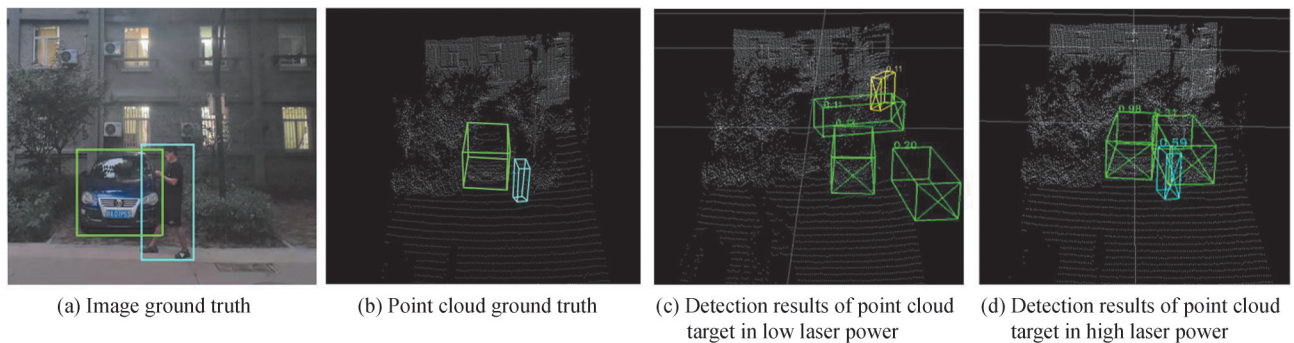


图3 同一场景的不同激光发射功率下的目标检测结果对比

Fig. 3 Comparison of object detection results under different laser power in the same scene

图3(a)和(b)是同一场景下可见光和点云图像人工标注的目标真实位置,其中绿色方框代表车辆、蓝色方框表示行人。图3(c)是低发射功率下的目标检测结果,图3(d)是高激光发射功率下的目标检测结果。对比图3(c)与(d),从回波点云数上可以看出,激光发射功率越高,探测器可响应的点云数越多,目标环境信息



获取越全面。从图3(c)目标检测结果中可以发现低激光发射功率所成的点云图像稀疏,无规则的点云数据类似于随机噪声对真实目标造成干扰,检测结果中存在2处漏检4处误检;如图3(d)所示,在高激光发射功率下,成像激光雷达获取的目标环境信息全面,减少了2处漏检和3处误检。然而,对于近距离场景,过高的激光发射功率不仅造成资源的浪费还加重了激光器的工作负担。因此,为获取高质量的激光雷达成像数据,要求激光发射器的功率动态可调,本模块内的激光光源参数如表1所示。

表1 激光光源参数  
Table 1 Laser source parameters

Wavelength	Pulse duration	Pulse repetition frequency	Average power	Peak power	Divergence	Spot diameter
1.55 $\mu\text{m}$	10 ns	50 kHz	25 W	1 kW	0.351 mrad	12.2 mm

## 2.2 成像系统的扫描视场

成像激光雷达的扫描视场是决定其感知环境范围的参数,通常情况下,因受成像系统的最小扫描角分辨率的约束,很难实现大视场高分辨成像。因此,为了实现对环境中重要目标的高分辨率精细化感知,动态自适应调整扫描视场是成像激光雷达应具有的一项重要功能。设计的认知成像激光雷达采用了数字振镜机械扫描结构如图4(a)所示。




图4 扫描结构以及扫描视场控制模型

Fig. 4 Scanning structure and scanning field of view control model

采用双轴数字振镜的二维机械扫描成像结构在同一个光路中完成了激光光束的发射与接收,在有效控制扫描视场大小的同时能够减小光路结构的尺寸、降低光路结构设计的复杂度。以 $yoz$ 平面为基准,扫描视场如图4(b)所示,系统采用逐行点扫的方式进行成像,坐标 $(y,z)$ 为水平和垂直方向扫描的起始点, $\Delta y$ 与 $\Delta z$ 分别为水平和垂直方向扫描视场的大小,只要动态调整 $y$ 、 $z$ 、 $\Delta y$ 与 $\Delta z$ 四个扫描参数就可以实现成像激光雷达的成像视场动态优化。

## 2.3 成像系统的扫描角分辨率

成像激光雷达的扫描角分辨率决定了点云图像分辨率,为提升认知成像激光雷达的成像质量,进一步分析扫描角分辨率对认知成像激光雷达性能的影响,从而使得系统能够根据实际应用场景动态选择合适的扫描角分辨率。为此,利用点云目标检测识别算法SECOND对同一场景下不同扫描角分辨率获取的点云图像进行目标检测,如图5所示。

图5(a)和(b)是同一场景中可见光图像和点云图像人工标注的目标真实位置,图5(c)是低扫描角分辨率下的目标检测结果,图5(d)是高扫描角分辨率下的目标检测结果,相比之下,高扫描角分辨率成像条件下的图像检测结果中,目标的检测精度和置信度均有所降低。通过多组实验,发现对于近距离或者大目标使用较低的成像分辨率,过高成像分辨率虽然视觉效果会变好但会造成误检或漏检。其原因在于过高的扫描角分辨率采集到的数据与SECOND网络训练时所用的数据点云的稀疏性差异较大,这是深度学习算法

泛化能力差的体现。

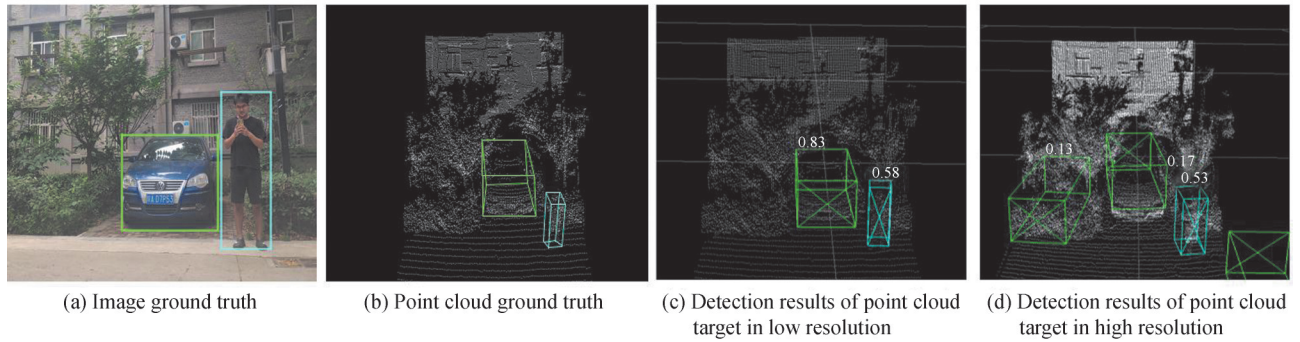


图5 不同扫描角分辨率下的同一场景目标检测结果

Fig. 5 Object detection results under different scanning resolutions in the same scene

因此,为实现认知成像激光雷达对不同应用场景的目标高精度检测,提升深度学习算法的泛化能力,本模块通过内部设置  $128 \times 128$ 、 $256 \times 256$  以及  $512 \times 512$  三种  $H_{res}$  对成像激光雷达的扫描角分辨率动态优化调整,  $H_{res}$  是激光器单方向发射的点云数目。

#### 2.4 深度学习认知反馈

通过对激光发射功率、成像角分辨率及成像系统扫描视场三个参数进行分析后,提出了深度学习认知反馈框架如图6所示。本系统通过初始化参数设置低激光发射功率、最大扫描视场和低扫描角分辨率对目标与环境进行初次成像,由于激光发射功率的调整策略不受目标检测结果的影响,因此优先对激光发射功率进行调整,其调整思路为在尽可能获取全面目标环境信息的情况下使用低激光发射功率。记激光器单方向发射的点云数为  $H_{res}$ ,则完成一次成像激光发射的点云总数表示为  $H_{res}^2$ ,记当前激光雷达接收的点云数据量为  $t$ ,则可定义点云数据的采集效率  $p$  为

$$p = t/H_{res}^2 \quad (1)$$

当系统接收机能量响应阈值一定时,激光发射功率越大,系统接收的点云数量越多。因此点云数据的采集效率  $p$  可以作为系统间接调控激光发射强度的参考,根据本系统的实际工作经验值,以 20 W 为步长调整激光发射功率并逐次成像计算,直至满足  $p \geq 80\%$ ,可视为系统激光发射功率调节完成。

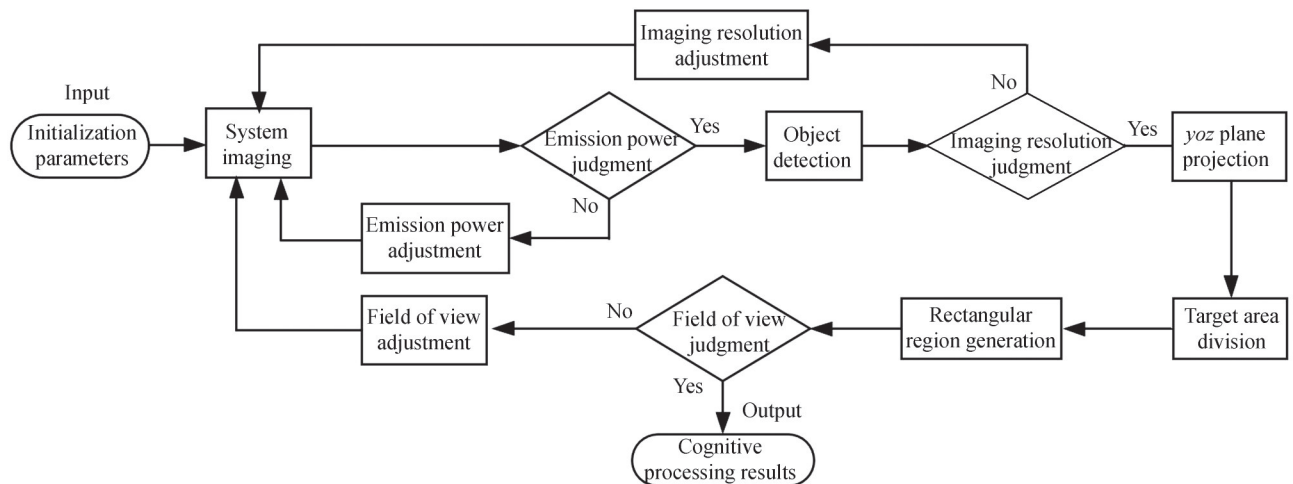


图6 深度学习认知反馈流程

Fig. 6 Flow chart of cognitive feedback for deep learning

一旦成像激光雷达的最佳激光发射功率被确定,系统进行成像角分辨率的自适应动态优化。具体地,先利用认知成像激光雷达模块内的深度学习算法对采集到的点云图像进行目标检测;将该结果反馈到成像系统以进一步优化成像分辨率,即目标全部漏检或检测到的目标置信度均低于某个阈值(本系统设置为

30%),则成像系统认为此时的成像角分辨率较低,逐步动态优化调整该参数直到目标检测识别算法获得最佳结果。

成像激光雷达确定最佳成像角分辨率后,为了减少环境冗余信息的持续干扰,系统通过动态优化成像视场对目标进行精细化成像。由于三维空间的目标分割异常复杂,设计的成像激光雷达首先将所有目标中心位置及对应的目标检测框投影到成像二维平面,然后基于目标中心点的距离对成像面进行目标区域划分,最后对每个划分后的区域依次动态优化成像视场。具体地,根据目标检测结果先对 $n$ 个目标向 $yoz$ 面进行投影;然后在投影区域计算每个目标框中心位置 $[S_1, S_2, S_3, \dots, S_n]$ ,对于任意目标 $u_x$ 的中心位置 $S_x$ 坐标记为 $(y_x, z_x)$ ;最后计算所有目标中心位置之间的距离 $d$ 可得 $[d_1, d_2, d_3, \dots, d_{n(n-1)/2}]$ 。为了对成像区域有效划分,采用阈值设定划分原则。具体地,设置区域划分阈值 $d_{th} = H_{res}/t$ , $t$ 为任意正整数,若 $t$ 取值过小,则无法对成像区域进行有效划分;若 $t$ 取值过大,则成像区域划分过多,增加认知流程的复杂程度;根据实际系统工作经验,取 $t=5$ 对成像区域进行划分可得到良好的划分结果。若某两个目标中心位置间的距离 $d_x \leq d_{th}$ ,则可将目标划分成同一成像区域,根据区域内多个目标的中心生成垂直方向的外接矩形,对矩形框依次成像,相比于直接对单个目标逐次调节视场,对划分后的外接矩形区域进行逐次成像可降低系统工作的复杂性。

基于成像区域划分结果,成像激光雷达对划分后成像区域的视场依次进行优化调整,具体方法如图7所示。具体地,首先将当前视场投影面中心划分为四个象限;对于某一矩形区域 $r_1$ ,若 $r_1$ 内目标的投影框中心均集中在同一象限且不包括投影面的中心点,认为对于区域 $r_1$ 的成像系统的成像视场偏大,则成像系统以一定扫描角度步长(本模块设置为 $5^\circ$ )将成像视场向该象限聚焦。例如,在图7(a)中,对于区域 $r_1$ ,在 $y$ 不变的情况下,增大 $z$ ,减小 $\Delta y$ 与 $\Delta z$ ,使得视场向第一象限调整聚焦如图7(b)所示,其中红色框代表第一次成像视场调整的结果。如图6所示,经过第一次成像视场调整后,成像激光雷达继续对该场景成像、目标检测识别、成像参数优化,第二次视场调整结果如图7(c)中黄色框所示。紧接着系统继续按流程图6运行,直至矩形区域 $r_1$ 包括了当前视场的中心点,视为 $r_1$ 区域视场调节完毕,如图7(d)所示,蓝色框即为最后一次视场调整的结果。在完成区域 $r_1$ 的成像视场调整后,成像激光雷达依次遍历区域 $r_x$ ,完成全部区域的视场优化。




图7 深度学习认知扫描视场自适应调节策略

Fig. 7 Adaptive adjustment strategy of cognitive scanning field of view for deep learning

### 3 实验验证与分析

为了验证提出的基于深度学习的认知成像激光雷达的有效性,利用所设计的基于深度学习认知成像激光雷达模块对外场环境中的车辆(Car)、行人(Pedestrian)目标进行成像探测与认知,采用SECOND<sup>[14]</sup>、Pointpillars<sup>[15]</sup>和Centpoint<sup>[16]</sup>三种经典深度学习算法验证认知成像激光雷达的认知成像反馈性能。其中,Pointpillars算法是对SECOND算法的改进,该算法提出了新的点云编码端到端学习的三维目标检测网络,利用二维卷积取代三维卷积,有效提高了目标检测速度,取得了良好的检测效果;Centpoint是一种基于三维目标中心点检测的两阶段三维目标检测算法,算法在第一阶段使用KeyPoint检测器检测目标的中心,将目标中心回归到其检测框大小和方向上,在第二阶段利用目标的附加特征点来进一步优化一阶段参数,该算法在Waymo数据集上取得了最先进的检测性能。在网络模型测试时,SECOND、Pointpillars算法均使用KITTI数据集下的测试权重模型,Centpoint算法使用Waymo数据集下的权重测试模型,以上三个网络模型



均未进行额外的数据训练,测试的车辆目标的交并比(Intersection Over Union, IOU)设置为0.7,行人目标的IOU设置为0.5。

图8~10给出了三组不同场景下的认知成像激光雷达的成像结果和目标检测结果,其中图8~10的(a)~(c)分别表示利用三种不同算法对传统模式下激光雷达获取数据进行目标检测的结果,可以观察到距离激光雷达比较近的区域中,车辆轮廓较为清晰,而在距离较远区域中,获取的车辆点云数据空间分辨率较低,且不同类别目标点云数据较为相似,这给目标检测算法带来了很大的困难。图8~10的(e)~(g)表示经过认知反馈后的认知成像雷达目标检测的结果,从这些图中可以发现,通过成像激光雷达进行核心参数发射功率、视场和角分辨率的自适应优化后,系统获取的点云图像中目标轮廓和细节信息更加完善。图8~10的(d)、(h)分别给出了点云图像和可见光图像下目标的Ground truth。

图8给出了一组简单场景下传统成像模式与认知成像模式的目标检测结果。由于传统成像模式激光雷达的成像参数固定,对场景的自适应能力较差,获取的点云数据空间分辨率较低,导致目标检测难度增加,现有大部分算法均难以准确检测出目标,如图8(a)~(c)所示。从图8(a)与(b)中可以看出目标检测算法SECOND和PointPillars出现了误检,图8(c) CenterPoint算法存在漏检。图8(d)~(f)给出了基于认知成像激光雷达的目标检测结果,相比传统成像激光雷达数据,认知成像激光雷达通过认知系统的反馈后,三个点云图像的点云数目和图像分辨率得到明显提高,目标检测效果更好,SECOND和PointPillars算法能够有效避免目标误检的问题,CenterPoint算法则是将之前漏检的车辆目标重新识别出来,三个算法的置信度得到了普遍提高。

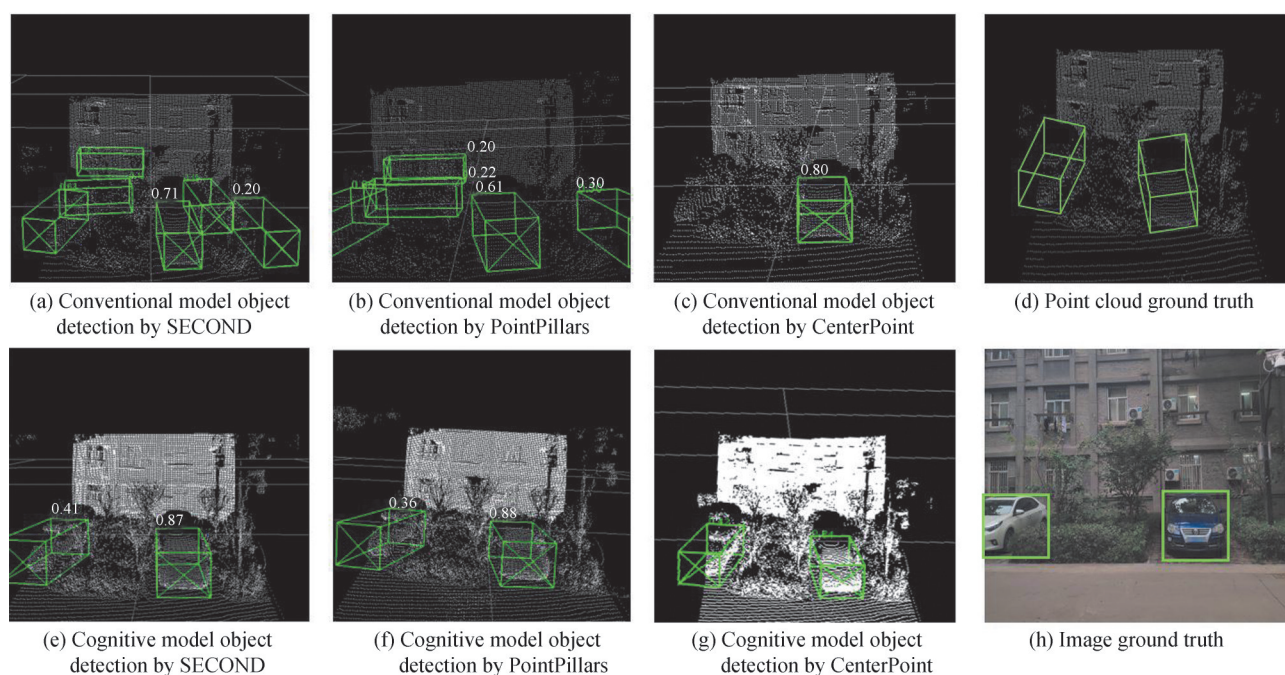


图8 传统模式目标检测和认知反馈后的目标检测效果对比

Fig. 8 Comparison of conventional model detection result and cognitive feedback detection result

图9给出了一组远距离多目标场景下传统激光雷达成像模式与认知激光雷达成像模式的目标检测结果。由于传统成像模式激光雷达参数固定,目标车辆距离激光雷达较远,且干扰目标较多,导致获取的车辆点云数据空间分辨率低,车辆点云稀疏,如图9(g)所示。在这种情况下,三维目标检测识别算法通常会出现误检或漏检,如图9(a)~(c)所示,SECOND算法漏检较多。相比之下,本文设计的认知成像激光雷达获取的三维点云数据更有利于提高三维目标的检测识别精度,如图9(e)~(g)所示。认知成像激光雷达通过认知系统的动态优化增大了激光发射功率和扫描角分辨率,将成像视场均聚焦于目标车辆上,完成了目标精细化识别,相比于传统成像方式,三个算法均有效避免了目标误检和漏检的问题。

图10给出了一组远距离目标斜视场景下传统成像模式与认知成像模式的目标检测结果。从图10(a)



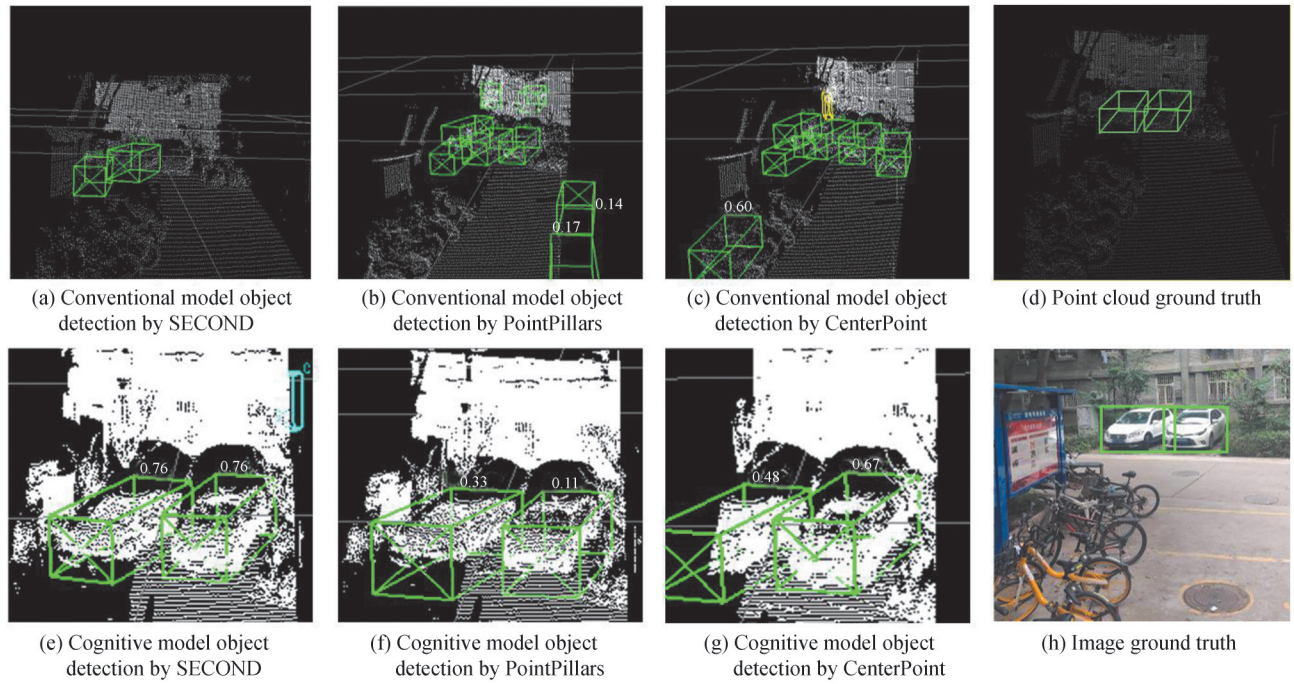


图9 远距离多目标场景下传统模式目标检测和认知反馈后的目标检测效果对比

Fig. 9 Comparison of target detection effects between conventional model and cognitive feedback in remote multi-object scene

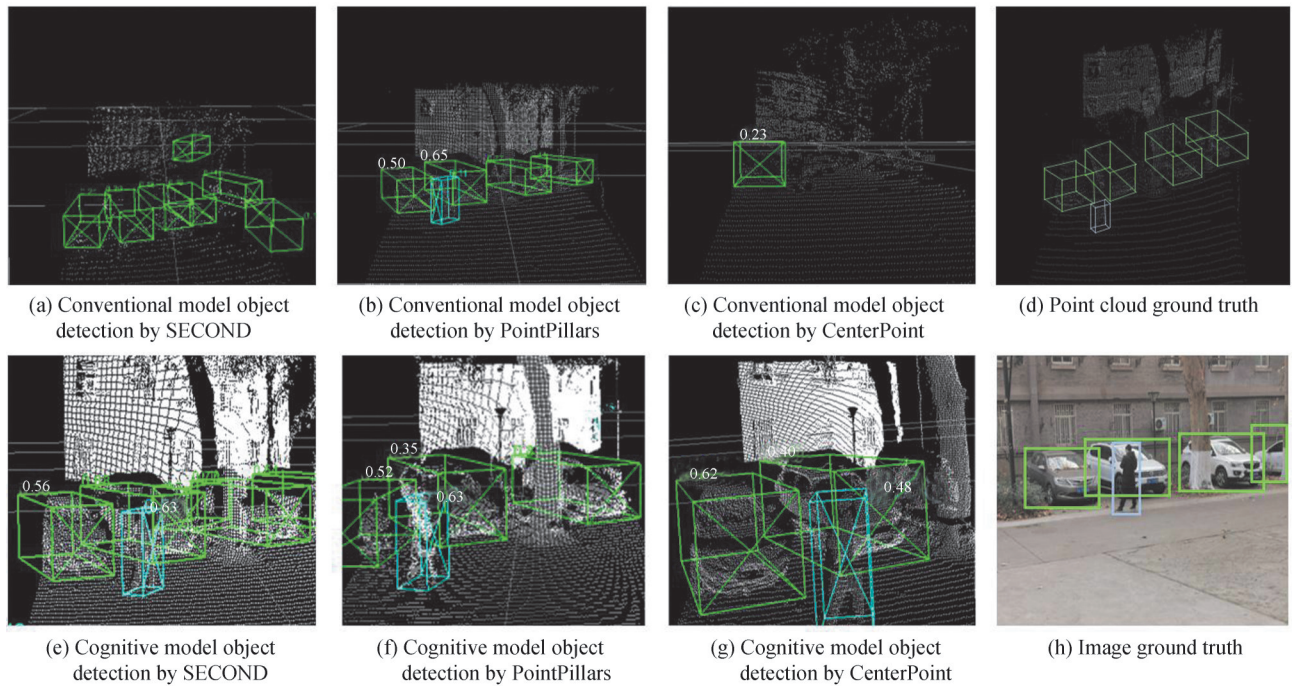


图10 远距离目标斜视场景下传统模式目标检测和认知反馈后的目标检测效果对比

Fig. 10 Comparison of target detection effects between traditional mode and cognitive feedback in long-range target squint scene

和(c)中可以看出,目标检测算法SECOND和CenterPoint均未能识别出行人,并且SECOND算法存在误检问题,CenterPoint算法存在漏检问题。图10(e)~(g)给出了基于认知成像激光雷达的目标检测结果,图10(e)中SECOND算法通过认知系统的优化增大了激光发射功率和扫描角分辨率,调整了扫描视场,剔除了两个误检目标,并重新检测出行人。图10(g)中Centerpoint算法通过认知系统的反馈后检测效果得到明显提升,系统将成像视场调整到传统模式检测到的车辆目标附近,经过成像分辨率和激光发射功率进一步提高后,算法从车辆目标周围检测出了额外的车辆和行人目标,挖掘了更多的目标环境信息,显著提升了系



统对场景的感知能力。

为了全面验证设计的基于深度学习的认知成像激光雷达的有效性和实用性,对该认知成像激光雷达采集的50组不同场景数据进行了测试。为了客观评价认知成像激光雷达与传统成像激光雷达的优缺点,采用召回率(Recall)和准确率(Precision)对传统模式和认知模式下车辆3D目标的检测精度进行对比,在计算召回率和准确率时汽车IOU设置为0.7,检测结果对比如表2所示。

表2 传统模式与认知模式下车辆目标召回率和准确率对比  
Table 2 Comparison of recall and precision of car targets under traditional mode and cognitive mode

Method	Recall/%		Precision/%	
	Conventional	Cognitive	Conventional	Cognitive
SECOND	71.62	76.58	54.88	65.23
PointPillars	72.93	77.31	55.46	65.88
CenterPoint	75.21	80.02	54.31	64.67

从表2中可以明显得出,三种深度学习点云目标检测算法在运用本文的认知调控策略后对汽车目标的召回率和准确率均有所提升,且由于测试所用的实验场景均未经过网络训练,说明相比于传统成像模式,系统通过认知动态优化后深度学习算法的泛化能力得到了提升。另外,三种算法的平均召回率提高了4.72%,平均准确率提高了10.38%,说明认知系统对误检目标的优化能力较漏检目标更强。

## 4 结论

本文提出并设计实现了认知成像激光雷达,利用深度学习理论实现了认知成像激光雷达的感知与认知协同优化。实验结果表明,所提的认知成像激光雷达相比传统的成像激光雷达能够获得更好的目标数据信息,有效提升了点云目标深度学习检测识别算法的泛化能力,为成像激光雷达同时具备感知认知能力的研究提供了一条新思路。此外,未来可通过在认知成像激光雷达中引入强化学习、在线学习等机制更加有效地自适应调控成像参数,以获取更有利于目标检测算法的点云数据,从而进一步提升认知成像激光雷达的感知与认知能力。

### 参考文献

- [1] YIN Zhou, ONCEL T. VoxelNet: end-to-end learning for point cloud based 3D object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4490-4499.
- [2] HRIDAY B, PALOMA D L P, JPNATHAN P, et al. VPS-SLAM: visual planar semantic SLAM for aerial robotic systems[J]. IEEE Access, 2020, 8: 60704-60718.
- [3] LANG N, SCHINDLER K, WEGNER J D. Country-wide high-resolution vegetation height mapping with Sentinel-2[J]. Remote Sensing of Environment, 2019, 233(111347): 1-18.
- [4] GRAUBOHM R, STOLTE T, BAGSCHIK G, et al. Towards efficient hazard identification in the concept phase of driverless vehicle development[C]. IEEE Intelligent Vehicles Symposium, 2020: 1297-1304.
- [5] HAYKIN S. Cognitive radar: a way of the future[J]. IEEE Signal Processing Magazine, 2006, 23(1): 30-40.
- [6] HAYKIN S. Cognitive dynamic systems[C]. IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP, 2007, 4: IV-1369-IV-1372.
- [7] KRISTINE L B, CHRISTOPHER J B, GRAEME E S, et al. Cognitive radar framework for target detection and tracking [J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 9(8): 1427-1439.
- [8] YAN Junkun, JIU Bo, LIU Hongwei, et al. Prior knowledge-based simultaneous multibeam power allocation algorithm for cognitive multiple targets tracking in clutter[J]. IEEE Transactions on Signal Processing, 2014, 63(2): 512-527.
- [9] FERREIRA P V R, PAFFENROTH R, WYGLINSKI A M, et al. Multiobjective reinforcement learning for cognitive satellite communications using deep neural network ensembles [J]. IEEE Journal on Selected Areas in Communications, 2018, 36(5): 1030-1041.
- [10] ZHOU Bo, KONG Depei, GENG Hongfeng, et al. A design of cognitive anti-jamming system in complex environment [C]. Cross Strait Quad-Regional Radio Science and Wireless Technology Conference, 2019: 1-3.
- [11] 左群声, 王彤. 认知雷达导论[M]. 北京: 国防工业出版社, 2017.
- [12] SONG Yuehui, SHI Gaodong, LI Shichun, et al. Design of wavelength tunable lidar system [J]. Acta Photonica Sinica, 2017, 46(10): 1001001.

- 宋跃辉, 石高栋, 李仕春, 等. 波长可调谐激光雷达系统设计[J]. 光子学报, 2017, 46(10): 1001001.
- [13] YANG Boda, XING Zhengquan, CHEN Donglin, et al. High-temperature LDAs Pulsedly Side-pumped Nd:YAG Laser [J]. Acta Photonica Sinica, 2021, 50(3): 0314002.  
杨博达, 刑政权, 陈东林, 等. 高温 LDAs 侧面脉冲泵浦 Nd:YAG 激光器[J]. 光子学报, 2021, 50(3): 0314002.
- [14] YAN Yan, MAO Yuxing, LI Bo. SECOND: Sparsely embedded convolutional detection[J]. Sensors, 2018, 18(10): 3337.
- [15] ALEX H L, SOURABH V, HOLGER C, et al. PointPillars: fast encoders for object detection from point clouds[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 12697-12705.
- [16] YIN Tianwei, ZHOU Xingyi, PHILIPP K. Center-based 3D object detection and tracking[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 11784-11793.