SC-MII：面向分割计算的边缘设备基础设施激光雷达三维目标检测与多中间输出集成

TaisukeNoguchi Takayuki Nishio Takuya Azumi理工研究生院 工学院 埼玉大学学术协会 东京科学大学
（理工研究生院）埼玉，日本 东京，日本 埼玉大学t.noguchi.471@ms.saitama-u.ac.jp 埼玉，日本

arXiv:2601.07119v1 [cs.DC] 12 Jan 2026

摘要—**利用基于激光雷达的点云数据和深度神经网络进行三维目标检测，是自动驾驶技术的关键。然而，由于计算需求和能耗较高，在边缘设备上部署最先进的模型面临挑战。此外，单激光雷达配置存在盲区。本文提出 SC-MII，即面向分割计算的边缘设备多基础设施激光雷达三维目标检测与多中间输出集成方案。在 SC-MII 中，边缘设备通过初始 DNN层处理本地点云，并将中间输出发送到边缘服务器。服务器集成这些特征并完成推理，从而降低延迟和设备负载，同时提升隐私保护能力。在真实世界数据集上的实验结果表明，该方案实现了 2.19× 倍加速，并将边缘设备处理时间缩短 71.6%，而准确率最多仅下降 1.09%。**

索引词—**边缘计算、基础设施激光雷达、中间输出集成、点云、分割计算、三维目标检测**

一、引言

自动驾驶技术 [1] 发展迅速，为社会带来了显著益处。目标检测是其中的核心组成部分，对于理解环境并实现路径规划和车辆控制至关重要。尽管主要依赖车载传感器，基础设施传感器能够扩大覆盖范围，尤其是在盲区。值得注意的是，激光雷达是车载和基础设施配置中使用的核心传感器 [2]。

激光雷达采集三维点云，深度神经网络（DNNs）对其进行分析以实现目标检测 [3]，[4]。基于基础设施的DNN推理通常在边缘设备上执行。为提高检测可靠性，可以使用多个激光雷达，但将原始点云传输到边缘服务器会引发隐私问题。本地推理可以减少传输需求，但边缘设备通常缺乏运行最先进模型所需的算力，导致延迟和功耗效率低下 [4]。

本研究通过使用多个基础设施激光雷达进行三维目标检测，同时尽量缩短处理时间、降低边缘侧负载并减少隐私风险，以应对这些挑战。本文采用分割计算（SC） [5], [6], ，将一个深度神经网络（DNN）划分到边缘设备和边缘服务器之间。边缘设备处理前段层，并将中间输出发送至边缘服务器进行最终推理，从而减轻边缘设备的计算负担，并避免传输原始数据。

本研究得到日本学术振兴会科研费资助，资助编号23H00464。

为应对这些挑战，本文提出了 SC-MII，这是一种面向分割计算的基础设施激光雷达三维目标检测方法，采用多中间输出集成。每个边缘设备通过深度神经网络的初始层处理本地激光雷达数据，并将中间特征传输至边缘服务器。边缘服务器接收后，将保留原始点云位置信息的中间输出在空间上对齐至统一参考坐标系，将其集成并完成推理。本文的贡献如下：

- 通过将计算从边缘设备卸载至边缘服务器，大幅缩短推理时间。
- 通过部分执行深度神经网络模型，降低边缘设备的计算负担。
- 通过集成多个激光雷达的中间输出，相较于使用单个激光雷达，提高了检测准确率。

II. 系统模型

本文提出了一种利用多个激光雷达的点云数据进行三维目标检测的方法。SC-MII 的系统模型如图 1 所示。该推理方法基于分割计算的理念。在该设置中，使用 NDT 扫描匹配计算每个激光雷达的相对位置。

本节介绍与所提方法相关的背景知识。第 II-A 节介绍分割计算，第 II-B 节阐述基于点云的三维目标检测，第 II-C 节讨论 NDT扫描匹配。

A. 分割计算（*SC*）

分割计算（SC）是一种将深度神经网络（DNN）拆分为两部分，分别在边缘设备和边缘服务器上执行的方法。这种方法能够降低边缘设备的计算负载，同时保持较高的准确率和效率。预训练模型被拆分为分配给边缘侧的头部模型和分配给服务器的尾部模型。在推理过程中，

© 2026 IEEE。允许将此材料用于个人用途。DOI: 10.1109/CCNC

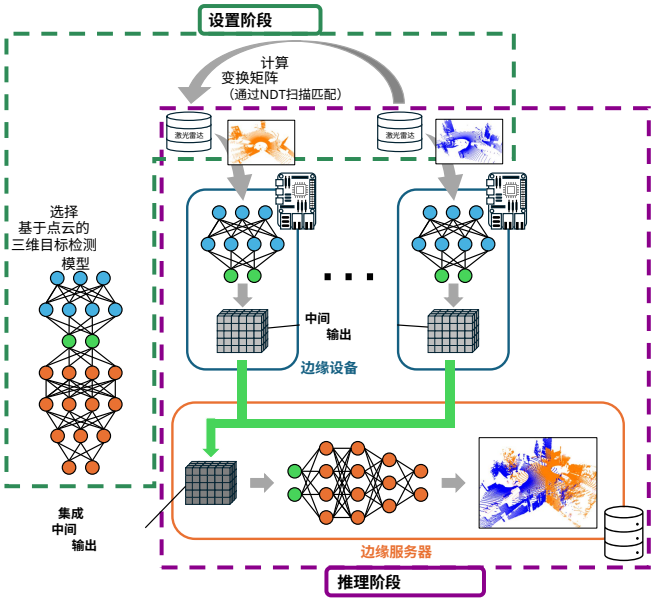

图1. 系统模型。

边缘设备使用输入数据运行头部模型，并将中间输出传输到边缘服务器；边缘服务器运行尾部模型并返回最终预测。

分割计算通过将计算卸载到边缘服务器来优化处理，无需使用轻量级模型。提前设置切分点可进一步降低边缘侧负载、功耗和推理时间。

B. 基于点云的三维目标检测

三维目标检测是自动驾驶技术中的一项关键任务。在各种数据格式中，点云提供了丰富的空间信息，有助于精确的位置估计。点云通常由激光雷达传感器获取。基于点云的检测方法分为以下三类。基于点的方法 [7]直接处理原始点云，而基于体素的方法 [3]将其转换为称为体素的三维网格，以便进行结构化处理。基于鸟瞰图的方法 [8]将点云投影到二维平面（即鸟瞰图）上，再对其进行处理。此外，也有结合这些方法的目标检测模型 [9]。

*C. NDT*扫描匹配

NDT扫描匹配是一种利用激光雷达及其他传感器获取的点云数据进行同步定位与建图的方法。正态分布变换（NDT） [10]通过将三维空间划分为体素，并计算每个体素的均值和协方差，将点云的局部区域建模为正态分布。由此可得到一个连续可微的概率密度函数。

为参考点云生成 NDT表示后，通过旋转和平移传感器的当前点云，使其与参考点云达到最佳匹配，从而完成对齐。对齐后，可估算传感器相对于参考坐标系的位置和方向。

III. 方法

我们提出了一种三维目标检测方法，该方法融合来自多台基础设施激光雷达的信息，以解决盲区问题并提高检测准确率。一种方法是合并各台激光雷达的原始点云数据 [11]。然而，由于需要将原始数据传输到服务器，这会引发隐私问题。另一种方法是在边缘设备上独立汇总检测结果 [12]，但算力有限的边缘设备难以运行高准确率模型，且不会增加处理时间或功耗。轻量级模型虽能降低资源消耗，却往往会牺牲准确率。

为克服这些局限性，本研究采用了一种集成中间输出的方法。边缘设备计算初始DNN层，并将中间输出而非原始点云传输至边缘服务器，在边缘服务器上对特征进行对齐和集成。这样可以避免传输敏感的原始数据，并降低边缘设备的计算负载。

我们提出的方法SC-MII采用分割计算的思想，通过集成多个基础设施激光雷达的中间特征来进行三维目标检测。SC-MII由设置阶段和推理阶段组成。在设置阶段，计算变换矩阵以对齐多个基础设施激光雷达的坐标系，并训练检测模型。在推理阶段，每个边缘设备根据其激光雷达输入计算中间输出，并将其传输至边缘服务器，由边缘服务器进行对齐、集成和处理，以完成目标检测。

本节其余部分的组织如下。III-A节介绍推理阶段，包括推理流程、中间输出的坐标变换及其集成。III-B节解释设置阶段，涵盖变换矩阵计算、模型选择与拆分以及模型训练。

A. 推理阶段

1) 推理流程：所提方法通过整合来自多个基础设施激光雷达的点云数据来执行三维目标检测。在此设置中，使用一台边缘服务器，并为每台激光雷达配备一台边缘设备。每台边缘设备与一台激光雷达配对，并持续接收其点云数据。在设置阶段配置的目标检测模型被拆分为头部模型和尾部模型，分别部署在边缘设备和边缘服务器上。所有边缘设备执行架构相同的头部模型，但由于输入数据不同，模型参数也有所差异。

SC-MII 的推理流程如图2所示。每台边缘设备接收对应激光雷达的点云数据并运行头部模型。生成的中间输出被发送至边缘服务器，在那里进行对齐和整合。随后，边缘服务器使用整合后的数据运行尾部模型，以生成最终检测结果，包括目标位置和类别。

2) 中间输出的坐标变换：我们假设所有边缘设备都在相同的体素网格分辨率下生成中间特征图，并具有共同的坐标原点，从而确保变换矩阵

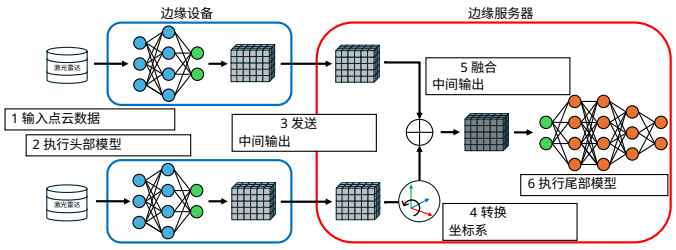

图2. SC-MII 的推理流程。

可以直接应用于特征张量。为了将多个边缘设备的中间输出在共同坐标系中进行空间对齐，我们对稀疏卷积后得到的体素级特征应用坐标变换。不同于在体素化之前对原始点云进行对齐的传统方法，该方法对边缘设备执行部分推理后生成的中间特征图进行变换。

首先，将中间输出的离散体素索引转换为连续物理坐标。转换时，使用有效体素尺寸对体素索引进行缩放；该尺寸同时考虑原始体素分辨率，以及步幅卷积等会改变中间特征空间分辨率的卷积操作所引入的缩放因子。随后，将缩放后的索引加上各激光雷达传感器局部坐标系的原点，以获得物理坐标。尽管所得物理坐标仍与体素网格对齐，但为进行坐标变换，会将其视为空间中的连续表示。

随后，将设置阶段估算出的已知变换矩阵应用于物理坐标。该矩阵表示一种刚体变换，用于将各传感器的局部坐标系与共同的全局参考坐标系对齐。变换在齐次坐标中进行，以同时纳入旋转和平移。

应用变换后，通过逆向执行缩放和偏移操作，将物理坐标转换回体素索引。所得索引会在体素网格上四舍五入至最近的整数，并限制在集成范围内。此过程能够在保留空间局部性的同时，对来自多个传感器的中间特征进行空间一致的集成。此方法之所以可行，是因为卷积操作尽管会改变空间分辨率，却能保留体素空间中特征之间的空间关系。

3) 中间输出集成：坐标变换后，来自多个边缘设备的中间输出在公共参考坐标系中实现空间对齐。为集成这些对齐后的输出，采用以下两种方法之一。

第一种方法在每个体素坐标处，从所有中间输出中选取最大值。这种方法只需进行简单的逐元素比较。第二种方法沿特征维度拼接所有中间输出，并对拼接后的特征应用一个卷积层。该操作的输出旨在与来自每台设备的原始中间输出尺寸相匹配。本研究采用卷积核尺寸为 1 或 3 的卷积层实现这种集成方法。我们评估了这两种集成方法在下游目标检测任务中的效果。这些方法具有通用性，适用于广泛的目标检测模型。

B. 设置阶段

设置阶段在系统部署和推理之前进行。该过程如图3所示。

1) 变换矩阵计算：在 SC-MII 中，来自多个边缘设备的中间输出必须在公共坐标系中进行集成。由于每个基础设施激光雷达都在各自的局部坐标系中运行，因此有必要计算变换矩阵，将这些坐标系对齐到公共参考坐标系。

为估计这些变换矩阵，本研究采用 NDT 扫描匹配。如图4所示，预先收集每个观测同一场景的激光雷达所获取的点云数据。选取一个激光雷达作为参考，并使用 NDT 对其点云进行建模，将局部点分布表示为正态分布。将其他激光雷达的点云与该模型对齐，从而为每个传感器得到一个刚体变换矩阵。

由于基础设施激光雷达的位置是固定的，与车载传感器不同，这些变换矩阵会长期保持有效。边缘服务器会存储这些矩阵，并在坐标变换过程中使用它们，将中间输出转换到统一的坐标系中，从而确保不同传感器之间的空间一致性。

2）模型选择与切分点策略：模型拆分是 SC-MII 中一项关键的设计决策，旨在平衡通信效率、隐私保护和计算负载分配。三维目标检测模型中的分割点必须满足两项重要约束。

首先，为了最大限度地缩短传输时间并节省带宽，分割点应位于能够产生较小中间输出的层。传输紧凑特征可以降低通信开销并加快推理速度。还必须考虑模型中的分支结构，因为额外数据可能会导致输出量增加。其次，切分必须在完成充分预处理后进行，以避免传输隐私敏感的原始点云数据。这样可以确保边缘设备处理所有原始数据，从而保护用户隐私。对于需要在中间层使用原始点云的模型而言，它们并不适用于 SC-MII，因为这类模型要么必须传输敏感数据，要么会削弱计算卸载的优势。

尽管模型架构和切分点的优化是一个重要的研究课题，但本研究采用了文献 [6]提出的配置，并通过在网络中合并来自多个基础设施激光雷达的紧凑中间特征图对其加以改进，从而增强隐私保护并降低通信开销。我们实验中使用的具体模型和切分点详见 IV-B节。

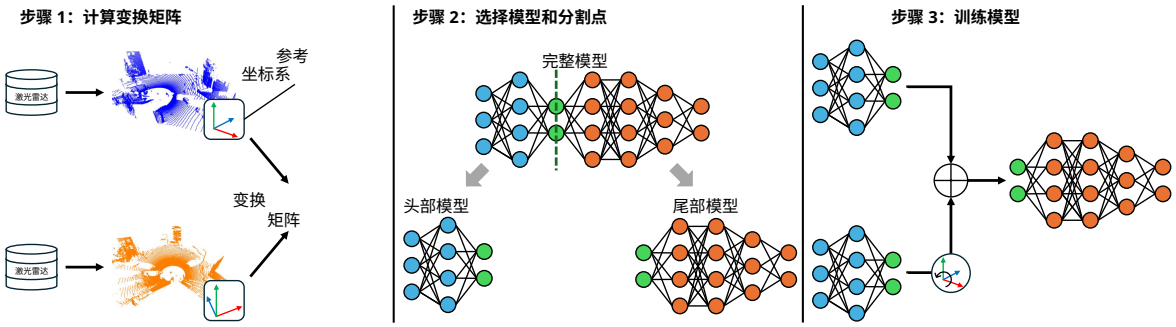

图 3. SC-MII 的设置阶段。

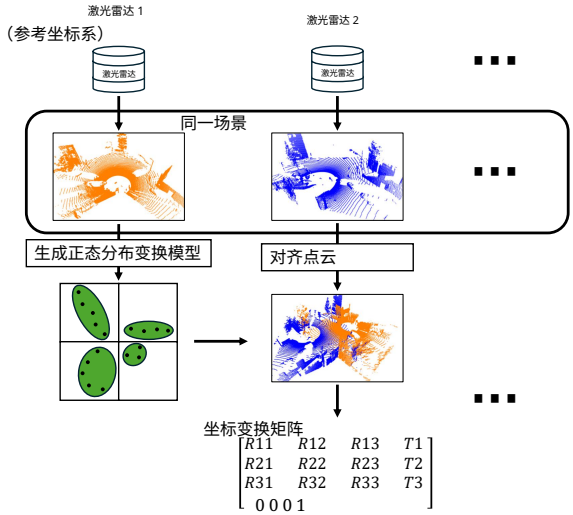

图 4. 通过 NDT 扫描匹配计算坐标变换矩阵。

3）训练目标检测模型：训练在系统部署前的设置阶段离线进行。训练前，会汇总从各激光雷达传感器采集的点云数据及其对应标签，并进行时间同步。训练所用的模型架构与推理阶段相同，以确保两个过程保持一致。推理采用边缘设备与边缘服务器之间的分布式处理，而训练则以集中式批处理方式进行。训练前不会对原始点云进行空间变换；相反，坐标变换在模型内部作用于中间特征，这与推理过程一致。

IV. 评估

本节评估 SC-MII。我们从准确率和执行时间两个方面比较各集成方法，并探讨其中的权衡。

本节其余内容安排如下。IV-A节概述用于评估的数据集，以及评估过程中使用的环境和设备。IV-B节讨论 SC-MII 中所用模型的选择，以及切分点的确定。IV-C节评估各项所提出集成方法的准确率。IV-D节考察各项集成方法的执行时间。

表 I 评估环境

组件	规格
边缘设备	Jetson Orin Nano: - 六核 Arm 1.5 GHz CPU - 1024 核 NVIDIA Ampere架构GPU 配备 32 个运行频率为 625 MHz 的张量核心 - 8 GB 128 位 LPDDR5 内存
边缘服务器	Intel® Core i9-14900K CPU NVIDIA RTX 4090 GPU 192 GB DDR5 内存
通信	1 Gbps 有线局域网

表 II 各边缘设备的基础设施激光雷达分配及相应传感器型号

设备	分配的激光雷达	激光雷达型号
设备 1	激光雷达 1	Ouster OS1-64
设备 2	激光雷达 2	Ouster OS1-128

A. 数据集与评估环境

本研究使用 V2X-Real 数据集 [13]，这是一个用于车联网（V2X）协同感知的真实世界数据集。该数据集采集于一个交叉路口，使用了两个基础设施传感器和两辆网联自动驾驶汽车（CAV），每辆车均配备一台激光雷达和一台摄像头。本研究使用了两台基础设施激光雷达：Ouster OS1-64 和 OS1-128，二者的工作频率均为 10 Hz。

在 SC-MII 中，处理任务分布在边缘设备和边缘服务器之间。本研究使用两台 Jetson Orin Nano 作为边缘设备，并使用一台高性能服务器。硬件和通信详情汇总于表 I。设备 1 配备 OS1-64，设备 2 配备 OS1-128，如表 II 所示。由于传感器规格不同，设备 2 处理的点数约为设备 1 的两倍。

B. 模型选择与切分点确定

为确保隐私并减少传输数据量，SC-MII 要求三维目标检测模型仅在初始阶段使用点云数据。一项将分割计算应用于三维目标检测的先前研究 [6] 根据模块架构和执行时间分布，分析了两种模型：PV-RCNN [9] 和 Voxel R-CNN [3]。

PV-RCNN 不适用于分割计算（SC），因为它会在后续层中重复使用原始点云数据，导致必须传输的数据量增加，并引发隐私问题。相比之下，Voxel R-CNN 仅在初始

表 III 总体准确率

传感器配置	融合方法	mAP AP@0.3	mAP AP@0.5
单个激光雷达	激光雷达 1（无融合）	71.79	48.88
	激光雷达 2（无融合）	73.24	50.47
多个激光雷达	输入点云	78.17	56.41
	中间输出（**SC-MII**）		
	最大值选择	74.54	53.53
	一个卷积层		
	卷积核尺寸：1	75.72	54.09
	卷积核尺寸：3	**77.12**	**55.32**

体素化步骤中访问点云。后续层仅处理体素化后的特征，因此更适合 SC-MII。

同一项研究通过权衡隐私与执行时间，确定了最合适的分割点。所选分割点位于体素化之后的第一个三维卷积层之后。SC-MII采用这一分割点，使后续所有处理均无需访问原始点云。

C. 集成方法的准确率评估

本节比较了 SC-MII（所提出的中间输出集成方法）与两种基线方法的准确率：使用单个激光雷达，以及集成来自多个激光雷达的输入点云。总体比较结果如表 III 所示。与单个激光雷达的设置相比，使用多个激光雷达能够提高检测准确率，这可能是因为多个激光雷达可在远距离区域提供更密集的点，并有助于恢复从单一视角观察时部分被遮挡的物体形状。在多激光雷达方法中，与输入点云集成相比，SC-MII 的准确率仅略有下降，在 AP@0.3 和 AP@0.5 下分别降低了 1.05% 和 1.09%。尽管输入集成能够利用原始数据，SC-MII 在处理中间输出的情况下仍实现了相当的性能。

D. 集成方法的执行时间

本节比较了 SC-MII 与一种基线方法的执行时间，该基线方法在单个边缘设备上完成所有处理，从集成来自多个激光雷达的输入点云到生成检测结果。

推理时间和边缘设备执行时间如图 5 所示。推理时间是指从输入点云到输出最终检测结果所需的时长。边缘设备执行时间是指在 SC-MII 下，从输入到中间输出传输完成所需的时间。与完全在边缘侧执行相比，SC-MII 在所有融合方法下均缩短了推理时间。采用单个卷积层且卷积核大小为 3 的方法速度提升最大，平均为 2.19×，最高为 1.70×。

此外，由于所有 SC-MII 变体的边缘侧处理方式相同，因此按设备分别呈现边缘设备的执行时间。相比之下，当所有处理都在边缘设备上进行时，边缘设备的执行时间等于整体推理时间。在计算负载更大的设备 2 上，SC-MII 将边缘侧处理时间平均缩短了 71.6%，最大缩短幅度为 62.2%。

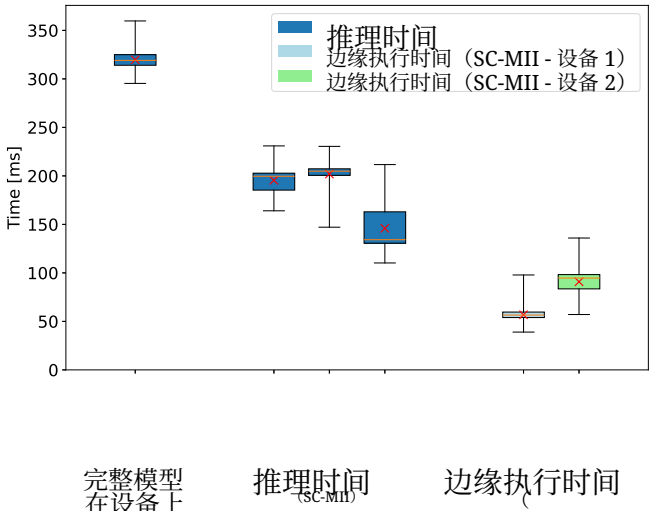

图 5. 执行时间对比。

E. 经验总结

本节总结了本研究评估结果中的关键见解。这些见解为在自动驾驶系统中设计高效且准确的分布式感知系统提供了有价值的启示。

SC-MII利用多个基础设施激光雷达，显著提高了三维目标检测的准确率，有助于减少盲区并增加点云密度。与输入级集成相比，中间输出集成的准确率仅略有下降，同时保持了相当的整体性能，证明了所提方法的有效性。在各种集成方法中，使用卷积核尺寸为 3 的单个卷积层取得了最高的检测准确率，优于最大值选择和卷积核尺寸为 1 的卷积。这表明，在集成过程中纳入空间上下文有利于实现准确检测。

通过将计算卸载到高性能边缘服务器，SC-MII显著缩短了资源受限边缘设备上的处理时间。尽管卸载会带来通信开销，整体推理延迟仍然有所降低。这表明，在只能使用低功耗边缘设备的场景中，将繁重的计算任务交由边缘服务器处理，可以有效支持实时性能。不过，网络状况可能不稳定，这凸显了进一步优化通信效率的必要性。

为提升分割计算中的通信鲁棒性，未来工作应探索减少从边缘设备传输的数据量的技术。集成压缩的中间输出有助于在准确率与延迟之间实现更好的权衡。此外，设计能够容忍部分数据丢失且无需重传的系统，可提升不稳定网络条件下的实时性能。这些方向有助于为分布式环境开发更可靠、高效的三维感知系统。

表 IV 所提方法与相关工作的比较

	Edge 设备	SC	多重中间集成	三维目标检测	点云
Voxel R-CNN [3]				✓	✓
轻量级模型用于三维检测 [4]	✓			✓	✓
三维检测采用分割计算 [6]	✓	✓		✓	✓
BottleFit [14]	✓	✓			
ImVoxelNet [15]			✓	✓	
NNFacet [16]	✓	✓	✓		
SC-MII（我们的方法）	✓	✓	✓	✓	✓

V. 相关工作

本节回顾了分割计算以及使用多数据源进行三维目标检测的相关工作。与所提方法的对比结果汇总于表 IV。

Voxel R-CNN [3] 是一种三维目标检测模型，它将点云数据转换为体素，以降低计算成本。三维骨干网络从体素中提取特征，随后将其转换为二维特征，并通过二维骨干网络和区域提议网络生成区域提议。该模型引入的 VoxelRoI 池化能够高效提取感兴趣区域特征，在保持准确率的同时提升速度。

面向三维点云目标检测的轻量级模型 [4] 旨在适用于计算资源有限的边缘设备。该模型引入 LW-Sconv 模块，结合因式分解卷积和组卷积，以降低模型复杂度。知识蒸馏进一步提升了准确率，使模型能够以极小的性能损失实现高效检测。

面向分割计算的边缘设备三维点云目标检测 [6] 采用分割计算，以降低资源受限边缘设备上三维目标检测的高计算成本。与完全在设备上执行相比，通过分割计算卸载计算任务可缩短推理时间并降低功耗。

BottleFit [14] 在不增加模型复杂度的情况下，为用于分割计算的深度神经网络引入瓶颈结构，这与以往采用自编码器的方法不同。该方法修改原始模型以减少层数，同时实现压缩，并采用两阶段训练过程分别训练头部和尾部模型。该方法在降低通信延迟和功耗的同时，提高了准确率。

ImVoxelNet [15] 使用任意数量的多视角 RGB 图像进行三维目标检测。每幅图像中的二维特征被投影到统一的三维空间中，并按体素求平均，以形成三维特征图。随后，该特征图经过三维卷积和检测头处理。与之前基于 RGB 的方法相比，该方法实现了更高的准确率。

NNFacet [16] 提出了一种面向并发智能传感器的深度神经网络拆分框架：边缘设备提取类别特定特征，并将中间输出传输至服务器进行融合与分类。其整体架构与 SC-MII 十分相似，因为两者都通过共享特征实现协同推理，同时降低设备负载并保留数据局部性。不过，SC-MII 专为基于基础设施激光雷达的三维目标检测量身打造，在空间对齐和特征集成方面带来了独特挑战。

VI. 结论

本文提出了 SC-MII，这是一种面向边缘设备的基于多个基础设施激光雷达的三维目标检测方法，旨在缩短边缘设备上的推理时间并降低计算负载。SC-MII 运用分割计算的概念，通过集成多个中间输出，利用多个激光雷达实现目标检测。检测模型在选定的位置进行拆分，后续处理则卸载至边缘服务器。在本研究中，使用 Jetson Orin Nano 作为边缘设备对 SC-MII 进行了评估。本文采用 VoxelR-CNN 作为目标检测模型。与集成输入点云的仅边缘处理相比，SC-MII 实现了更短的推理时间，并显著降低了计算负载，同时仅造成轻微的准确率下降。

参考文献

[1] S. Kato、S. Tokunaga、Y. Maruyama、S. Maeda、M. Hirabayashi、Y. Kitsukawa、A. Monrroy、T. Ando、Y. Fujii 和 T. Azumi，《Autoware on Board：利用嵌入式系统实现自动驾驶汽车》，载于 *Proc. of ACM/IEEE ICCPS*，2018 年，第 287–296 页。[2] T. Azumi、Y. Maruyama 和 S. Kato，《ROS-lite：面向基于片上网络的嵌入式众核平台的 ROS 框架》，载于 *Proc. of IEEE/RSJ IROS*，2020 年，第 4375–4382 页。[3] J. Deng、S. Shi、P. Li、W. Zhou、Y. Zhang 和 H. Li，《Voxel R-CNN：迈向高性能的基于体素的三维目标检测》，载于 *Proc. of AAAI*，第 35 卷第 2 期，2021 年，第 1201–1209 页。[4] Z. Li、Y. Li、Y. Wang、G. Xie、H. Qu 和 Z. Lyu，《用于三维点云目标检测的轻量级模型》，《应用科学》，第 13 卷第 11 期，第 6754 页，2023 年。[5] Y. Matsubara、M. Levorato 和 F. Restuccia，《深度学习应用的分割计算与提前退出：综述及研究挑战》，*ACM Computing Surveys*，第 55 卷第 5 期，第 1–30 页，2022 年。[6] T. Noguchi 和 T. Azumi，《面向分割计算的边缘设备三维点云目标检测》，载于*Proc.of ACM/IEEE RAGE*，2024 年，第 1–6 页。[7] S. Shi、X. Wang 和 H. Li，《PointRCNN：从点云生成和检测三维目标提议》，载于 *Proc. of IEEE/CVF CVPR*，2019 年，第 770–779 页。[8] A. H. Lang、S. Vora、H. Caesar、L. Zhou、J. Yang 和 O. Beijbom，《PointPillars：用于点云目标检测的快速编码器》，载于 *Proc. of IEEE/CVF CVPR*，2019 年，第 12 697–12 705 页。[9] S. Shi、C. Guo、L. Jiang、Z. Wang、J. Shi、X. Wang 和 H. Li，《PV-RCNN：用于三维目标检测的点体素特征集抽象》，载于 *Proc. of IEEE/CVF CVPR*，2020 年，第 10 529–10 538 页。[10] P. Biber 和 W. Straßer，《正态分布变换：一种新的激光扫描匹配方法》，载于 *Proc. of IEEE/RSJ IROS*，第 3 卷，2003 年，第 2743–2748 页。[11] Q. Chen、S. Tang、Q. Yang 和 S. Fu，《Cooper：基于三维点云的网联自动驾驶汽车协同感知》，载于 *Proc. of IEEE ICDCS*，2019 年，第 514–524 页。[12] R. Xu、W. Chen、H. Xiang、X. Xia、L. Liu 和 J. Ma，《模型无关的多智能体感知框架》，载于 *Proc. of IEEE ICRA*，2023 年，第 1471–1478 页。[13] H. Xiang、Z. Zheng、X. Xia、R. Xu、L. Gao、Z. Zhou、X. Han、X. Ji、M. Li、Z. Meng *et al.*，《V2X-Real：用于车联网协同感知的大规模数据集》，载于 *Proc. of ECCV*，2025 年，第 455–470 页。[14] Y. Matsubara、D. Callegaro、S. Singh、M. Levorato 和 F. Restuccia，《BottleFit：为有效且高效的分割计算学习深度神经网络中的压缩表示》，载于 *Proc. of IEEE WoWMoM*，2022 年，第 337–346 页。[15] D. Rukhovich、A. Vorontsova 和 A. Konushin，《ImVoxelNet：用于单目和多视角通用三维目标检测的图像到体素投影》，载于 *Proc. of IEEE/CVF WACV*，2022 年，第 2397–2406 页。[16] J. Chen、D. Van Le、R. Tan 和 D. Ho，《NNFacet：用于并发智能传感器的神经网络分割》，《*IEEE* 移动计算汇刊》，第 23 卷第 2 期，第 1627–1640 页，2023 年。