arXiv:2603.01026v1 [cs.CV] 1 Mar 2026

RaUF：雷达空间不确定性场学习

Shengpeng Wang Kuangyu Wang 华中科技大学wsp666@hust.edu.cn
wangky@hust.edu.cn

Wei Wang*武汉大学
wangw@whu.edu.cn

摘要

毫米波雷达在恶劣天气下具有独特优势，但其空间保真度较低、方位角模糊严重，且存在杂波引起的虚假回波。现有方法主要通过由粗到细的跨模态监督来提升空间感知有效性，却往往忽视了模糊的特征到标签映射，这可能导致病态几何推断，并给下游感知任务带来根本性挑战。本文提出 *RaUF*，这是一种空间不确定性场学习框架，通过雷达测量的物理基础各向异性特性对其进行建模。为解决特征到标签映射冲突，我们设计了一种各向异性概率模型，用于学习细粒度不确定性。为进一步提升可靠性，我们提出双向域注意力机制，利用空间结构与多普勒一致性之间的互补性，有效抑制虚假反射或多径反射。在公开基准和真实世界数据集上进行的大量实验表明，*RaUF* 能够提供高度可靠且不确定性校准良好的空间检测。此外，下游案例研究进一步验证了 *RaUF* 在具有挑战性的真实驾驶场景中的可靠性和可扩展性。

1. 引言

雷达感知 [24, 26, 28]已成为各种应用中的重要组成部分，包括自动驾驶 [10, 13], 机器人技术 [12, 25], 和监控系统。雷达能够在恶劣天气条件和低能见度环境下有效运行，因此可实现全天候、全天时感知，同时提升态势感知能力和安全性。此外，雷达信号中蕴含的独特多普勒信息可提供散射体的相对径向速度，在定位 [25], 速度估计 [18], 目标检测

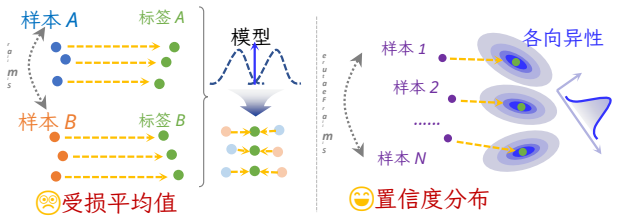

图1. 传统方法在冲突下做出妥协，从而导致病态几何推断。

任务以及分割任务中，作为基于视觉的感知的补充线索。然而，雷达数据固有的稀疏性和噪声给实现精准的稠密感知带来了重大挑战。

为提升雷达感知，现有研究 [6, 9, 24]侧重于通过来自更高分辨率传感器（如摄像机和激光雷达）的由粗到细跨模态监督来增强雷达点云（PCL）。然而，仍存在两大挑战：*1*）基于稀疏测量的病态几何推断。从低分辨率到高分辨率的细节细化，本质上是由网络依据稀疏雷达线索“幻觉”出几何结构来实现的，而这可能缺乏物理保真度。这种模糊的特征到标签映射会在各样本间引发监督不一致性。如图1所示，在缺乏不确定性建模的情况下，网络被迫调和相互冲突的监督信号，往往收敛到几何上不合理的中间解，而这些中间解并不反映真实分布的任一模态。这种折中的平均结果最终阻碍了稳定优化与特征泛化。*2*）过度依赖振幅线索且对虚假反射缺乏鲁棒性，当前许多方法在雷达感知中严重依赖强度值，往往忽视虚假点的存在——这些虚警可能源于多径反射或噪声。这种疏忽会因对雷达数据的误读而导致不可靠的感知结果。

为应对这些挑战，我们深入探究雷达的物理本质，并为我们的框架提出基于物理原理的动机。如图 2a 所示，

*通讯作者

我们观察到雷达具有一种固有的各向异性测量特性：由于有效到达角天线数量有限，方位角不确定性远高于距离不确定性，因此形成了特征性的“新月形”空间分布。我们进一步阐明了不确定性感知学习的有效性：它将含糊的特征到标签映射从相互冲突的监督信号转化为有用的线索，以学习目标区域的细粒度置信度，从而提升泛化能力和物理可解释性。此外，正向检测中固有的多普勒一致性也可加以利用，如图 2b 所示。反射的多普勒速度由雷达的自车速度和散射体的方向向量决定。多普勒测量的时间相干性是一种具有物理可靠性的线索，可用于识别并抑制虚假反射或多径反射，从而提升杂波环境下空间感知的鲁棒性和可靠性。

为充分释放这一令人振奋的潜力，我们提出了*RaUF*，一种新颖的多普勒感知空间感知方法，可学习雷达测量的空间各向异性不确定性场，并有效缓解几何推断中的歧义。具体而言，我们首先为雷达目标区域引入各向异性几何不确定性表示，并构建一种显式纳入此类几何不确定性的贝叶斯概率损失函数。该设计将模糊特征到标签映射之间相互冲突的监督信号转化为有意义的学习信号，使网络能够推断目标区域上的细粒度置信度分布，而非依赖不完整的确定性映射。这使网络能够学习目标区域上的细粒度置信度，从而提升泛化能力和物理可解释性。接下来，我们在空间特征和多普勒特征上引入双向域注意力，以识别并抑制虚假反射，从而提升杂波环境下空间感知的鲁棒性和可靠性。最后，我们在多个公开数据集和真实世界数据集，以及多种类型的雷达上开展了大量实验，以验证我们的方法在下游任务上的有效性、可靠性和可扩展性。

总而言之，我们的主要贡献体现在以下几个方面。

• 我们提出了一种新颖的雷达感知框架，通过学习各向异性几何不确定性校准，重新解决低保真雷达空间固有的病态几何推断。据我们所知，这是首次尝试实现雷达空间不确定性学习。

•我们为多普勒雷达设计了一种双向域注意力模块，通过多普勒信息强化空间特征，从而以一种基于物理原理的机制减少假阳性。

•我们在基准数据集上进行了大量实验，证明了所提出方法的优越性。此外，我们将向研究界公开自行采集的数据集。

2. 相关工作

2.1. 雷达点云提取

传统的雷达点云提取主要依赖恒虚警率（CFAR） [17]等信号处理方法及其变体 [3, 8]。然而，受天线数量有限的制约，生成的点云通常较为稀疏且容易受到噪声干扰，难以满足速度估计、环境重建和定位等稠密感知任务的需求。尽管虚拟天线阵列设计 [5, 23, 30] 显著提高了角分辨率，但往往存在硬件不兼容问题，或严重依赖运动先验。

近年来，研究者日益致力于通过来自更高分辨率传感器的由粗到细跨模态监督，生成高保真稠密雷达点云。RPDNet [4]采用深度网络，在激光雷达监督下对距离-多普勒谱图进行细化，但仍受限于恒虚警率式处理范式，因而角分辨率有限。RadarHD [19] 将多帧CFAR稀疏点云投影到平面距离-方位角鸟瞰图上，并采用U-Net [21] 学习结构化占用表示。近期，Radar-Diffusion [30] 和RaLD [28]引入基于扩散的频谱去噪，以提升空间分辨率，但它们过度依赖强度线索，因此容易受到伪影和多径失真的影响。SDDiff [24]针对单芯片雷达联合估计点云和自车速度，从而在不同任务中实现互补效益。然而，它依赖计算开销较大的重复扩散迭代，阻碍了其在级联雷达系统中的可扩展性和车载部署。

2.2. 点云不确定性量化

一些工作（如 GICP [14]）可以通过统计点分布量化局部空间方差。这类不确定性描述能够捕捉稠密几何结构中的域内空间方差，但不适用于稀疏且含噪的雷达点。S3E [25] 和 UTR [1] 从注意力加权频谱特征和数据关联中估计不确定性，并根据各向同性评分推断占用置信度。然而，这些模型无法捕捉雷达的各向异性物理特征，而这种特征源于不同的距离-角度分辨率差异。受运动恢复结构和位姿图优化的启发，雷达SLAM系统 [10, 11, 31] 引入后端不确定性传播，通过位姿优化对检测级地标不确定性进行建模。但它们仍需

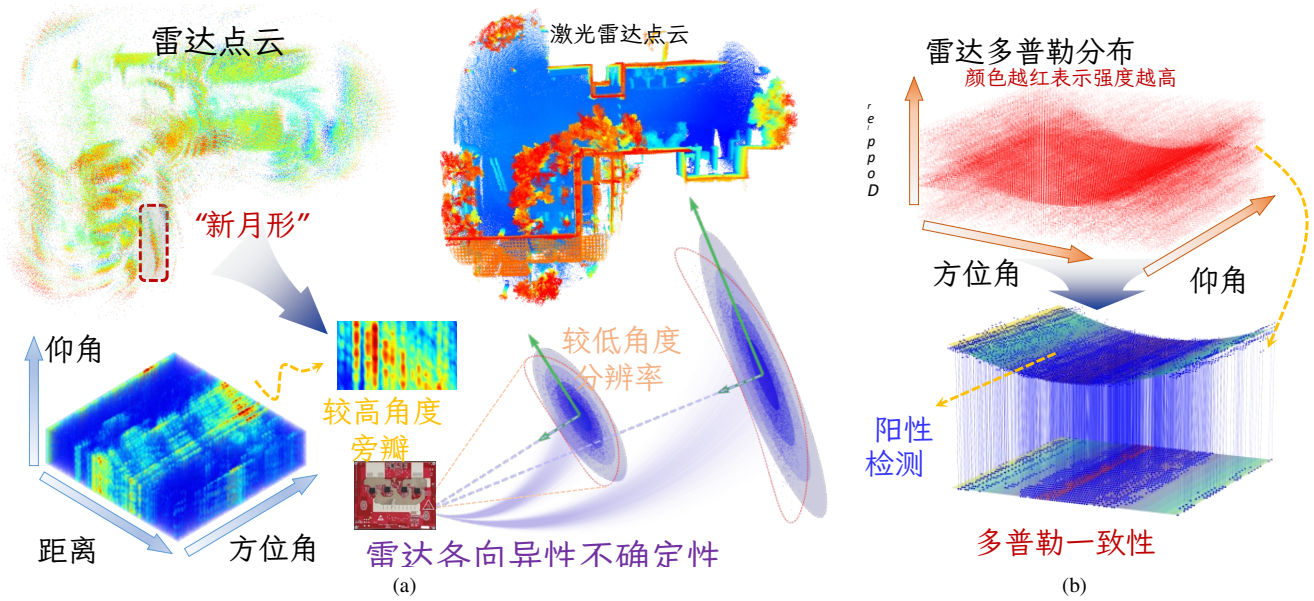

图2. 我们的洞见：(a) 多帧统计分析表明，雷达点云本质上呈现各向异性不确定性，这不同于激光雷达的各向同性特性。(b) 阳性检测的多普勒测量符合运动学约束。（实验数据基于 Coloradar [15] 和 RaDelft [20]）

要满足多帧一致性并实现精确的地标对应。

3. 方法

本节首先在第 3.1 节介绍用于雷达不确定性学习的贝叶斯概率模型（BPM）。随后，我们在第 3.2 节提出多普勒感知预测增强方法，以利用多普勒一致性改进雷达几何表征；最后，在第 3.3 节介绍我们提出的 RaUF 的架构和不确定性训练细节，如图 3 所示。

3.1. 雷达不确定性学习的 BPM

为缓解雷达稀疏测量导致的病态几何推断，我们构建贝叶斯概率模型（BPM），以学习雷达空间不确定性。我们重新将任务定义为估计定位预测模型$f_{\boldsymbol{\theta}}(x)$和不确定性量化模型 $g_{\boldsymbol{\varphi}}(x)$，二者分别由 $\boldsymbol{\theta}$ 和 $\boldsymbol{\varphi}$参数化。

$x \in \mathbb{R}^{R\times A\times E\times 2}$ 是雷达测量输入，其中 R、 A和 E 分别表示距离、方位角和仰角维度，并由占用真值 y监督。为利用多普勒一致性抑制虚假反射，我们将强度域和多普勒域拼接到特征通道中。在BPM下，我们指定似然$p(y|\boldsymbol{\theta},\ \boldsymbol{\varphi},\ x)$来对数据生成过程建模。学习$(\boldsymbol{\theta},\ \boldsymbol{\varphi})$等价于最小化负对数后验：

$$\begin{aligned}\left(\hat{\boldsymbol{\theta}},\hat{\boldsymbol{\varphi}}\right) &= \arg\min_{\boldsymbol{\theta},\boldsymbol{\varphi}}\left[-\log p(\boldsymbol{\theta},\boldsymbol{\varphi}\mid\boldsymbol{\mathcal{D}})\right]\\ &= \arg\min_{\theta}\left[-\log p(\boldsymbol{\mathcal{D}}\mid\boldsymbol{\theta},\boldsymbol{\varphi})-\log p(\boldsymbol{\theta},\boldsymbol{\varphi})\right]\end{aligned} \tag{1}$$

其中 $\mathrm{D}=\{(x_n,y_n)\}_{n=1}^{N}$。采用平坦先验时，目标是最小化 $-\log\ p(\mathrm{D}\mid\boldsymbol{\theta},\boldsymbol{\varphi})=-\log\prod_{i=1}^{N}p(y_i\mid x_i,\boldsymbol{\theta})$。考虑到图2a所示的雷达测量的各向异性不确定性，我们使用异方差高斯分布对似然进行建模，其中$y_i=f_{\boldsymbol{\theta}}(x_i)+\epsilon_i$，且 $\epsilon_i\sim\mathcal{N}(0,g_{\boldsymbol{\varphi}}(x_i))$。条件似然为：

$$p(y_i\mid x_i,\boldsymbol{\theta},\boldsymbol{\varphi})=\frac{\exp(-||y_i-f_{\boldsymbol{\theta}}(x_i)||^2_{g_{\boldsymbol{\varphi}}(x_i)}/2)}{\sqrt{(2\pi)^N\det\left(g_{\boldsymbol{\varphi}}\left(x_i\right)\right)}} \tag{2}$$

其中马氏距离为 $||\epsilon_i||^2_{\Sigma}=\epsilon_i^T\Sigma^{-1}\epsilon_i$。雷达不确定性学习的负对数似然损失为：

$$\begin{aligned}&\left(\hat{\boldsymbol{\theta}},\hat{\boldsymbol{\varphi}}\right)=\arg\min_{\boldsymbol{\theta},\boldsymbol{\varphi}}\left[-\log\prod_{i=1}^{N}p(y_i\mid x_i,\boldsymbol{\theta})\right]\\ &\Rightarrow\arg\min_{\boldsymbol{\theta},\boldsymbol{\varphi}}\sum_{i=1}^{N}\left(||\epsilon_i(\boldsymbol{\theta})||^2_{g_{\boldsymbol{\varphi}}(x_i)}+\log\det\left(g_{\boldsymbol{\varphi}}\left(x_i\right)\right)\right)\end{aligned} \tag{3}$$

第一项促使模型 $\boldsymbol{\theta}$ 拟合数据 $\boldsymbol{\mathcal{D}}$，同时考虑雷达给出的预测不确定性 $\boldsymbol{\varphi}$；第二项则惩罚较大的不确定性估计，以避免出现平凡解。

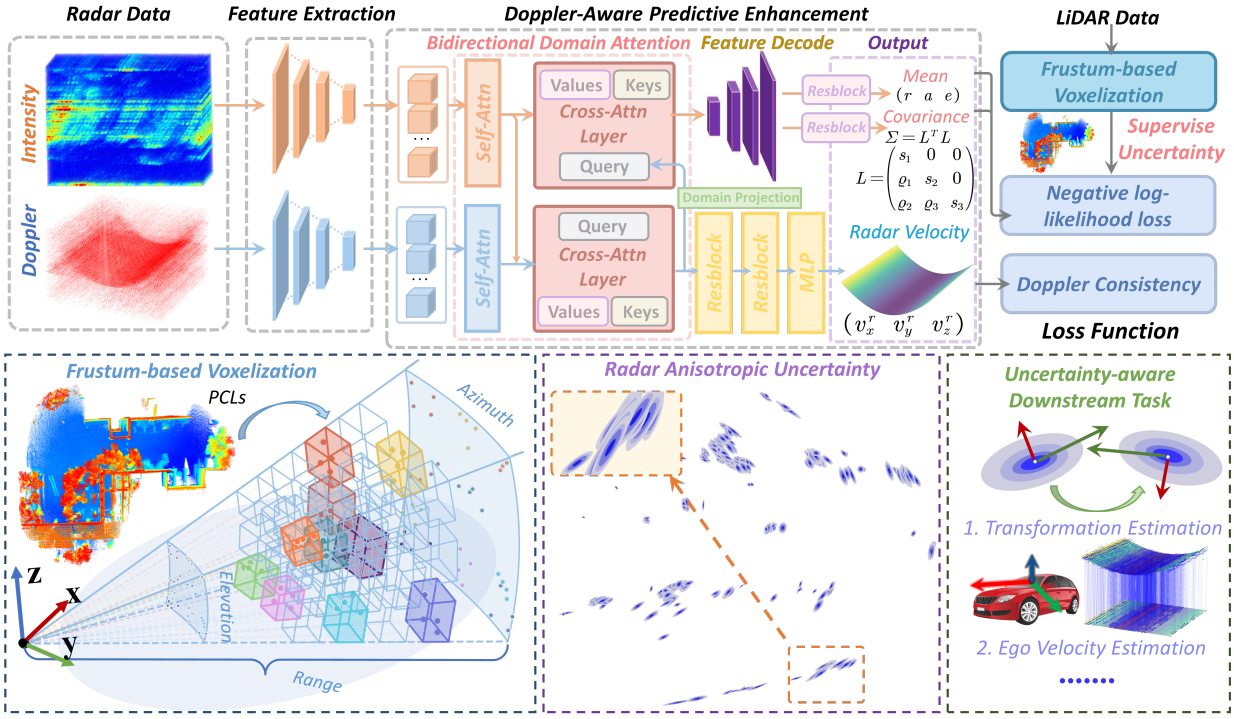

图3. 我们提出的 RaUF 框架，通过多普勒感知预测增强学习雷达各向异性不确定性。

3.2. 多普勒感知预测增强

仅使用强度信息可能会因雷达感知中的多径效应而产生许多虚假反射。如图 2b所示，我们发现，正向雷达反射的多普勒测量符合运动学约束，而大多数虚假反射则偏离该约束。为了有效利用多普勒一致性来增强雷达几何表征，我们首先在定理 1中分析多普勒速度与雷达自身运动之间的关系。

定理 1。 当目标相对于地面静止时，反射的多普勒速度，即相对径向速度$v_{i,\,j}^{r}$，由雷达的自运动速度 $\boldsymbol{v}^{r}$ 和散射体的方向向量 (α, β) 决定，其中 (α, β)表示散射体相对于雷达坐标系的方位角和仰角。

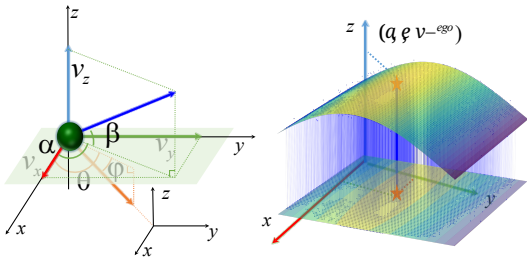

图4. 静止有效散射体的多普勒一致性。

证明。图 4 说明了多普勒一致性的原理。详细证明和技术细节请见 https://shengpeng.wang/rauf/#Supplementary。

□

因此，通过多普勒一致性可以有效抑制虚假反射，这一点已由定理1证实。为此，我们设计了一个多普勒感知预测增强模块，如图3所示，该模块通过第3.3节所述的双向域注意力融合（BDAF），利用多普勒信息增强空间特征。

3.3. 网络与不确定性训练

雷达特征提取。给定雷达测量输入 x （包括强度和多普勒通道），我们首先使用两个独立的三维卷积神经网络主干提取空间特征 $\boldsymbol{F}_s \in \mathbb{R}^{H\times W\times C_s}$ （编码空间占据率）和多普勒特征 $\boldsymbol{F}_d \in \mathbb{R}^{H\times W\times C_d}$ （反映速度分布）。与以往方法 [19, 27] 不同，后者要么将仰角压缩为一个特征通道，要么沿距离和方位角使用二维卷积；我们的三维卷积神经网络主干联合建模距离、方位角和仰角之间的相关性，从而获得更丰富的空间表征，并更好地捕捉雷达散射模式。

双向域注意力融合。强度

图提供了可靠的空间定位线索，而多普勒图有助于抑制虚假反射。为有效利用多普勒一致性来增强雷达几何表征，我们提出了一种用于多普勒雷达的双向域注意力融合（BDAF）模块，以多普勒信息强化空间特征。如图3所示，BDAF由两个交叉注意力层组成，用于建模空间特征与多普勒特征之间的相关性。具体而言，首先将两种特征切分为块，并添加位置编码进行嵌入，形成序列 $\boldsymbol{S}_p$，$\boldsymbol{D}_p \in \mathbb{R}^{L\times C}$，以便在统一表征长度 $L = \frac{HW}{p^2}$ 下实现逐词元交互。BDAF的第一阶段利用空间线索作为注意力查询，通过 $\boldsymbol{Q}_s = \boldsymbol{W}_s^q \boldsymbol{S}_p$、$\boldsymbol{K}_d = \boldsymbol{W}_d^k \boldsymbol{D}_p$和 $\boldsymbol{V}_d = \boldsymbol{W}_d^v \boldsymbol{D}_p$增强多普勒特征，其中 $\boldsymbol{W}_s^q$、$\boldsymbol{W}_d^k$和$\boldsymbol{W}_d^v$为可学习投影矩阵。注意力输出的计算方式如下：

$$\boldsymbol{S}_p \rightarrow \boldsymbol{D}_p' = \mathrm{Softmax}\left(\frac{\boldsymbol{Q}_s \boldsymbol{K}_d^T}{\sqrt{d_k}}\right)\boldsymbol{V}_d \tag{4}$$

其中，d_k 是键向量的维度。这使网络能够聚焦于多普勒测量值与雷达自运动一致的区域。$\boldsymbol{D}_p'$ 随后通过残差网络与原始多普勒特征 $\boldsymbol{D}_p$ 拼接，并投影为多普勒特征 $\boldsymbol{D}_p$。为进一步使多普勒信息与空间占用语义对齐，我们引入一个域投影网络，在将 $\boldsymbol{D}_p$ 馈送至第二个交叉注意力层之前，将其转换为类占用潜在表征 $\boldsymbol{D}_p''$；该层采用轻量级残差瓶颈实现。其输出编码了来自多普勒分布的空间似然，作为可微的物理先验，用于后续的注意力细化。

反过来，第二阶段会逆转这一过程，使用多普勒投影令牌作为查询来增强空间特征，并通过 $\boldsymbol{S}_p' = Attention(\boldsymbol{Q}_d = \boldsymbol{W}_d^q \boldsymbol{D}_p'',\ \boldsymbol{K}_s = \boldsymbol{W}_s^k \boldsymbol{S}_p,\ \boldsymbol{V}_s = \boldsymbol{W}_s^v \boldsymbol{S}_p)$引导空间特征重建。最终增强后的空间表征为$\boldsymbol{F}_s' =$残差网络(拼接($\boldsymbol{S}_p$，$\boldsymbol{S}_p'$))。这种双向细化使空间精度与多普勒相干性能够相互补偿，并增强了对一致的空间-多普勒模式的关注。随后，输出 $\boldsymbol{F}_s'$、$\boldsymbol{D}_p$ 分别被馈送至特征解码器，用于计算空间负对数似然损失$\mathcal{L}_{\text{spatial}}$ 和速度回归损失 $\mathcal{L}_{\text{doppler}}$。

雷达各向异性不确定性学习。为了对图 2a 所示的雷达测量各向异性不确定性进行建模，我们设计了不确定性量化模型$g_{\boldsymbol{\varphi}}(x)$，用于预测具有各向异性协方差矩阵的异方差高斯分布。具体而言，我们在极坐标中对不确定性进行参数化，分别预测径向不确定性 σ_t 和角度不确定性 σ_a。通过一阶误差传播推导出笛卡尔坐标系中的近似不确定性分布。

agation，如定理2所述。

定理 2。对于雷达检测测量 $\hat{\boldsymbol{p}}_{i,\ j,\ k}$，其真实位置在极坐标中为$(r_i, \alpha_j, \beta_k)$，距离不确定性为 $\boldsymbol{\delta}_{r_i} \sim \mathcal{N}\left(0, \sigma_{r_i}^2\right)$，方位角不确定性为 $\boldsymbol{\delta}_{\alpha_i} \sim \mathcal{N}\left(0, \sigma_{\alpha_i}^2\right)$，仰角不确定性为 $\boldsymbol{\delta}_{\beta_i} \sim \mathcal{N}\left(0, \sigma_{\beta_i}^2\right)$，则其在笛卡尔坐标中的相应不确定性可近似为高斯分布。

证明。考虑到 $\boldsymbol{p}$可在（r，α，β）附近用一阶泰勒展开近似，因此有：

$$\begin{aligned}\boldsymbol{\delta}_{\boldsymbol{p}} &= \frac{\partial \boldsymbol{p}}{\partial r}\boldsymbol{\delta}_r + \frac{\partial \boldsymbol{p}}{\partial \alpha}\boldsymbol{\delta}_\alpha + \frac{\partial \boldsymbol{p}}{\partial \beta}\boldsymbol{\delta}_\beta \\ &= \begin{bmatrix} \cos\alpha\cos\beta & -r\sin\alpha\cos\beta & -r\cos\alpha\sin\beta \\ \sin\alpha\cos\beta & r\cos\alpha\cos\beta & -r\sin\alpha\sin\beta \\ \sin\beta & 0 & r\cos\beta \end{bmatrix} \begin{bmatrix} \boldsymbol{\delta}_r \\ \boldsymbol{\delta}_\alpha \\ \boldsymbol{\delta}_\beta \end{bmatrix}\end{aligned} \tag{5}$$

令雅可比矩阵记为 $\boldsymbol{J}$。由于 $\boldsymbol{\delta}_r$、$\boldsymbol{\delta}_\alpha$和$\boldsymbol{\delta}_\beta$ 是相互独立的高斯变量，$\boldsymbol{\delta}_{\boldsymbol{p}}$ 也是一个高斯变量，其协方差为。因此，笛卡尔坐标中的不确定性可用高斯分布 $\mathcal{N}(\mathbf{0},\ \boldsymbol{\Sigma})$ 近似，其协方差矩阵为 $\boldsymbol{\Sigma} = \boldsymbol{J}\boldsymbol{D}\boldsymbol{J}^T$，其中$\mathbf{D} = \mathrm{diag}(\sigma_r^2,\ \sigma_\alpha^2,\ \sigma_\beta^2)$。 □

根据定理1，雷达测量中的“新月形”不确定性可由各向异性高斯分布下的“椭球形”置信区域近似，如图2a所示。结合式3 与定理2，我们优化空间定位模型 $f_{\boldsymbol{\theta}}$（x）和不确定性模型 $\boldsymbol{\Sigma} = g_{\boldsymbol{\varphi}}$（$x$），即最小化具有各向异性协方差矩阵的负对数似然损失，如下：

$$\mathcal{L}_{\text{spatial}} = \sum_{i=1}^{N}\left(||\epsilon_i(\boldsymbol{\theta})||^2_{g_{\boldsymbol{\varphi}}(x_i)} + \log\det\left(g_{\boldsymbol{\varphi}}\left(x_i\right)\right)\right) \tag{6}$$

此外，为了进一步增强多普勒一致性，我们引入了一项辅助速度回归任务，用于预测每个雷达检测的多普勒速度。

基于视锥的体素化策略。为了有效监督雷达不确定性学习，我们采用基于视锥的体素化策略，根据激光雷达点云构建占用真值。给定雷达的内参，我们沿距离、方位角和仰角方向延伸射线，生成视锥形区域。该视锥内的所有激光雷达点都被视为与雷达检测相对应的潜在反射。通过这种方法，我们能够构建更准确的占用真值，以反映雷达测量中固有的不确定性。

4. 实验与评估

我们使用公开可用的 Coloradar 和 RaDelft 数据集，以及自行采集的数据集，对所提出的方法进行了评估。这些数据集涵盖了采用不同类型雷达传感器的各种室内和室外场景。

4.1. 数据集

RaDelft 数据集。 RaDelft 数据集 [20]提供同步采集的雷达模数转换器（ADC）数据和激光雷达数据，采集地点为大规模城市环境。该数据集使用一部最远检测距离为 51 米的远距离级联雷达，在 7 个不同场景中记录了约 35 分钟的数据。

Coloradar 数据集。 该数据集包含 43,000 帧雷达帧，采集自各种室内和室外环境，使用的是一台最大检测距离为 15 m 的短程单雷达以及一台级联雷达。我们使用激光雷达点云作为点云提取估计的真实值，并使用通过里程计求得的速度作为速度监督信号。

自采集数据集。 我们使用自有平台从多种环境中采集真实世界数据，以进一步验证模型的泛化能力。该数据集包含单芯片雷达和级联雷达数据，涵盖各种室内和室外场景中的 11,000 多帧数据。可靠的速度真实值通过 Fast-Livo2 [29] 获取。

实现细节。 对于公式 6 中定义的负对数似然（NLL）损失，我们预测方差项的指数值以确保其为正，从而缓解模型训练过程中的数值不稳定性。为监督占据率和速度估计，我们采用权重系数为 0.001 的均方误差损失。我们使用 AdamW 优化器进行训练，初始学习率为 2×10^{-4}。所有实验均在配备四块 NVIDIA GeForce RTX 4090 GPU 和一颗 Intel Xeon Gold 6226R CPU 的工作站上进行，总训练时间为 6 天。

4.2. 基线与案例研究

RaUF 是首个能够联合重建雷达点云并显式估计其空间不确定性的框架。为评估其有效性和可靠性，我们将其与传统的基于模型的方法 OS-CFAR [3]和 RPDNet [4], , 以及最先进的基于学习的方法 RadarHD [19]和 SDDiff [24]进行比较。此外，我们还针对变换估计（TE）和自车速度估计（EVE）开展案例研究，并与 ICP [2], GICP [22],RANSAC [7], 和 RadarEVE [18], 进行比较，以验证不确定性估计能够显著提升下游感知的鲁棒性和准确性。

4.3. 评估指标

1）有效性：我们采用 Chambers 距离（CD）和 F 分数（FS）来评估重建点云的表征有效性 $\mathcal{P}$。

2）可靠性： 为了评估生成的 PCL 相对于杂波的可靠性 $\mathcal{P}_c$，我们定义杂波点比例（CPR） η 计算如下：

$$\eta = \frac{|\mathcal{P}_c|}{|\mathcal{P}|}, \mathcal{P}_c = \{p \in \mathcal{P}, \text{s.t.}, d\,(q,p) > \zeta,\ \forall q \in \mathcal{Q}\} \quad (7)$$

其中， $\mathcal{Q}$ 是真实值点云（PCL）的集合， $d(\cdot,\ \cdot)$是两点之间的欧氏距离函数， ζ 是距离阈值，在我们的实验中设为 0.5 米。较低的 CPR 表示 PCL 更可靠，杂波点更少。

3）可扩展性：为验证所提出的不确定性估计的实际效用，我们评估其对下游任务的影响，以突出我们的方法在各类雷达感知任务中的可扩展性和普适性。

4.4. 性能与分析

空间检测。 如图所示，我们对比展示了不同方法在各类场景下对级联雷达和单芯片雷达进行空间检测的结果。5。与现有方法相比，我们的方法具有更高的点密度和更丰富的结构保真度，表现与当前最先进的 SDDiff 不相上下。在定量评估中，我们将不同方法在 Coloradar 数据集上生成的点云与激光雷达点云进行比较。如表所示。1，我们的方法预测精度更高，在平均倒角距离和 F 分数方面比传统恒虚警率高出 70.1%，5× 展现出更优的几何保真度。一些基线方法专注于包含地面特征的全场景重建，而我们则针对无地面点云进行评估。这种设置更符合大多数下游感知任务的需求。

此外，我们在 RaDelft 数据集上评估长距离级联雷达的性能，在表中使用倒角距离和 CPR 评估有效性与鲁棒性，并考察运行效率。3。模型在此前未见过的场景上进行微调后，仍能保持出色表现，展现出稳健的泛化能力。结果证明了我们方法的优越性。为进一步验证模型的泛化能力，我们在自行采集的数据集上进行微调。RaUF 能够快速适应不同的传感器配置，展现出鲁棒性。这表明，我们的不确定性量化网络能够校准预测样本的置信区域，有效缓解低保真空间中病态几何推断所带来的问题。更多实验结果和场景可视化见补充材料。

不确定性量化。 如可视化结果所示，我们的模型有效利用了基于物理原理的雷达机制，捕捉到了具有特征性的月牙形空间分布。这不仅能为目标区域提供可靠的置信度估计，还能通过引导几何一致性推理和稳健的测量利用，为 3D 重建、定位、目标跟踪和速度估计等下游任务提供有价值的先验。

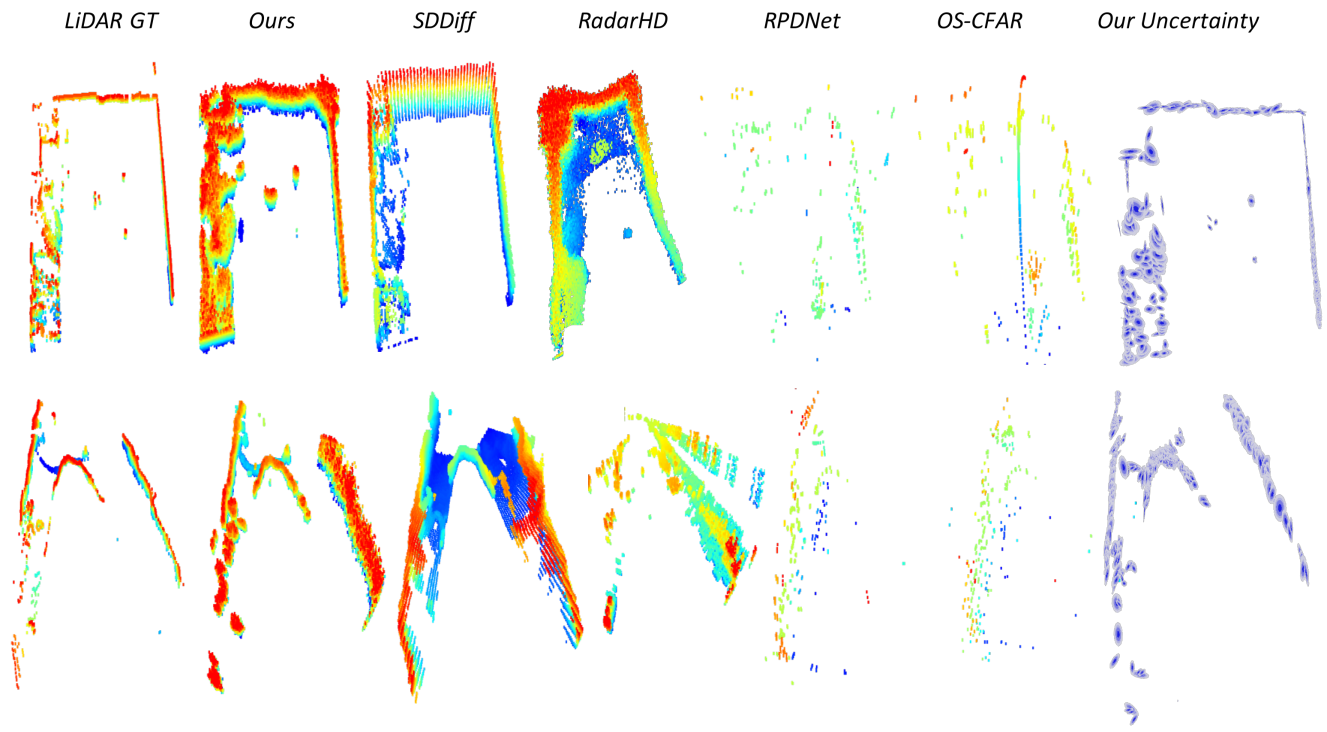

图5. 鸟　　瞰视图展示了经各种模型增强的雷达点云，以及激光雷达地面真值　　h.

雷达类别	检测方法	Armyroom 倒角距离 ↓	Armyroom FS ↑	教室 Aspen Room 倒角距离 ↓	教室 Aspen Room FS ↑	实验室 倒角距离 ↓	实验室 FS ↑	走廊 倒角距离 ↓	走廊 FS ↑	Longboard 倒角距离 ↓	Longboard FS ↑		
Coloradar Single-Chip	OS-CFAR [3]	4.15	0.19	4.81	0.17	2.99	0.02	2.78	0.02	2.75	0.02	-	-
	RPDNet [4]	4.07	0.18	5.83	0.13	2.46	0.03	2.45	0.03	2.64	0.03	-	-
	RadarHD† [19]	1.74	0.42	2.45	0.28	0.95	0.23	0.87	0.25	1.24	0.18	-	-
	SDDiff [24]	0.42	0.17	5.38	0.17	3.78	0.02	3.97	0.02	3.70	0.02	-	-
	我们的方法（不含负对数似然）		0.53	6.35	0.31	0.58	0.38	0.86	0.32	1.34	0.26	-	-
	我们的方法（不含 BDA		0.61	3.44	0.47	0.54	0.36	0.76	0.33	1.14	0.28	-	-
	我们的方法（不含 GS）	1.33	0.69	1.89	0.56	0.48	0.46	0.66	0.38	0.79	0.35	-	-
	Ours	1.31	0.69	1.74	0.54	0.48	0.44	0.64	0.38	0.78	0.34	-	-
Coloradar Cascade	OS-CFAR [3]	2.14	0.04	1.95	0.05	2.04	0.02	2.20	0.04	2.19	0.06	12.99	0.04
	RPDNet [4]	1.81	0.05	1.39	0.08	1.82	0.06	1.78	0.16	1.84	0.15	13.75	0.02
	RadarHD† [19]	1.08	0.23	1.29	0.25	1.49	0.14	1.12	0.22	1.38	0.19	4.66	0.19
	SDDiff [24]	0.86	0.43	0.69	0.44	1.16	0.38	1.97	0.12	1.92	0.15	9.00	0.08
	本文（不含负对数似然		0.45	0.48	0.50	0.83	0.38	1.22	0.31	1.20	0.33	7.97	0.20
	我们的方法(不含 BDA		0.40	0.50	0.41	0.81	0.37	1.15	0.34	1.11	0.36	5.98	0.28
	我们的方法(不含 GS)	0.50	0.49	0.45	0.54	0.76	0.40	1.17	0.33	1.15	0.35	3.86	0.37
	Ours	0.50	0.47	0.45	0.54	0.75	0.39	1.12	0.34	1.10	0.36	3.79	0.36

表 1. 不同场景和　　d
Coloradar 数据集上的雷达类别的空间检测性能对比。* 由于地面去除和视场约束滤波后有效点极少，因此不包含 Longboard 场景（单芯片）。

方法	EVE 误差分布（m/s） 10% ↓	20% ↓	40% ↓	60% ↓	80% ↓	TE 误差 T.（米）↓	R.（度）↓
ICP	0.15	0.20	0.41	0.65	1.03	0.99	0.63
GICP	0.13	0.27	0.38	0.57	1.26	**0.54**	**0.50**
RadarEVE	**0.09**	**0.15**	**0.26**	**0.37**	**0.75**	✗	✗
RANSAC	**0.11**	0.23	0.32	0.56	0.85	0.86	0.65
Ours	**0.09**	**0.17**	**0.25**	**0.39**	**0.77**	**0.42**	**0.39**

表 2. EVE 和 TE 案例研究评估。

检测方法	RaDelft 数据集 序列 2	RaDelft 数据集 序列 4	自行采集 室内	自行采集 室外
OS-CFAR	0.19 / 0.76	0.17 / 0.78	0.15 / 0.77	0.39 / 0.87
RPDNet	0.22 / 0.75	0.15 / 0.72	0.22 / 0.70	0.17 / 0.74
RadarHD	0.42 / 0.58	0.28 / 0.59	0.40 / 0.56	0.39 / 0.66
SDDiff	**0.66 / 0.44**	**0.46 /0.51**	**0.43/ 0.44**	**0.43 /0.56**
Ours	**0.69/ 0.41**	**0.54/ 0.50**	**0.45 /0.44**	**0.49/ 0.61**

表3. 可靠性、表征效果和计算效率的评估。（左：F-分数；右：CPR。）

为评估我们所提出的不确定性量化方法在下游任务中的可扩展性，我们针对变换估计和自车速度预测进行了案例研究。定量结果汇总于表 2。利用我们的不确定性感知点云，我们取得了最佳的变换估计性能，在平移和旋转精度方面均比 GICP 提高了 22%。这一提升源于 GICP 的协方

估计仅依赖局部几何统计，无法捕捉雷达测量中固有且具有物理意义的不确定性。这凸显了我们学习得到的不确定性表征相较于传统基于结构的估计器的优势。在自车速度估计方面，我们的方法优于经典的 RANSAC，性能与端到端的 RadarEVE 相当。这些结果进一步表明，我们的双向域注意力机制

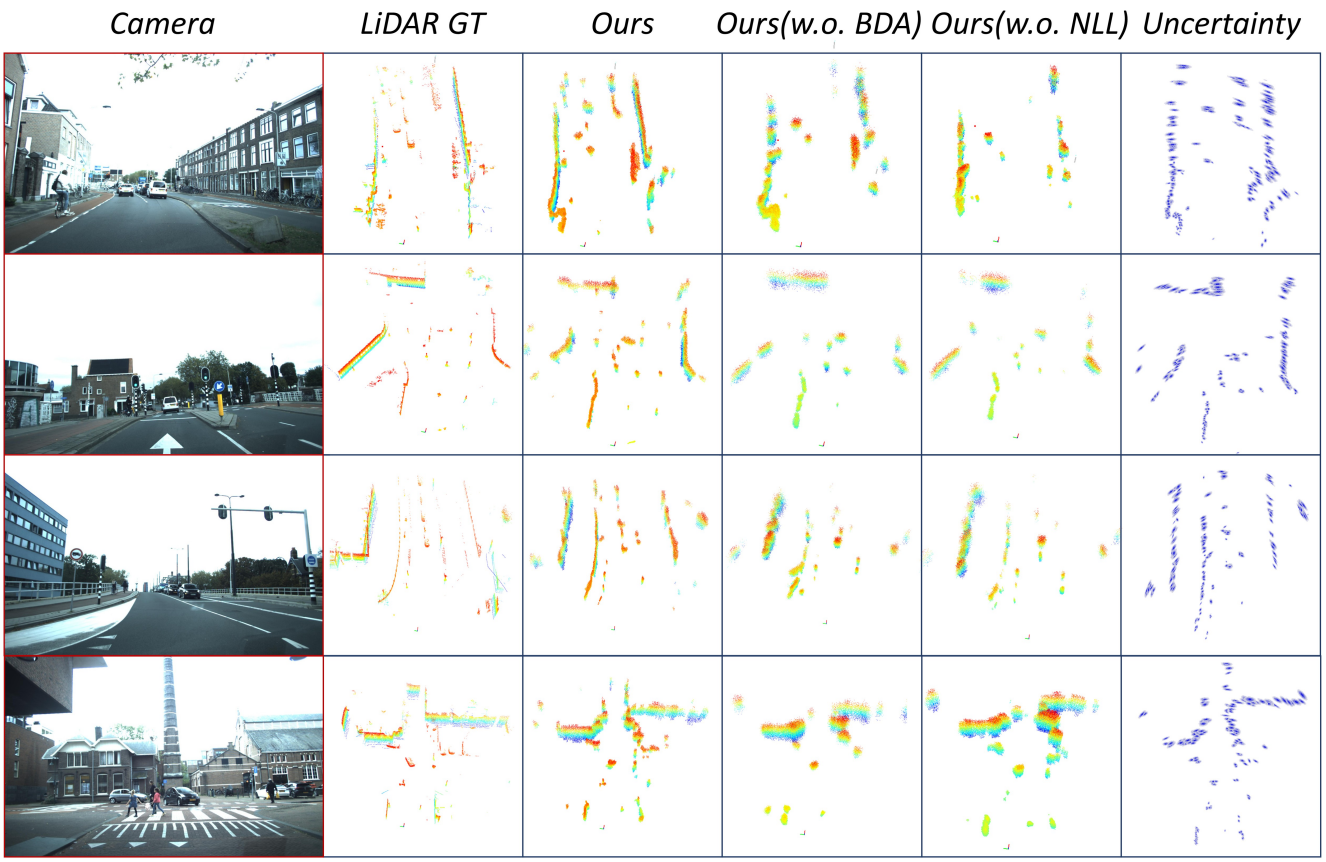

图 6. 采用不同方法增强的雷达点云与激光雷达真值的鸟瞰图可视化。

能够促进空间精度与多普勒相干性之间的相互补偿，从而提升运动推断的稳定性和物理一致性。

4.5. 消融研究

我们开展消融研究，以评估不确定性校准在缓解低保真雷达空间中病态几何推断方面的有效性，以及所提出的双向域注意力（BDA）的作用。如表 1 和图 6所示，引入不确定性校准可使倒角距离降低 30.55%-37.18%，并使 F分数提高 27.27%-38.71%，表明对各向异性不确定性进行建模能够提供更符合物理规律且无冲突的几何表征。此外，BDA 模块使仅强度基线提升了 14.98%-15.95%，这表明 BDA 能有效利用空间结构与多普勒相干性之间的互补性，从而提高杂波环境下的特征可靠性。

5. 结论

在这项工作中，我们提出了一种用于雷达感知的空间不确定性场学习框架，可从根本上预测具有各向异性不确定性的空间检测。为缓解低保真雷达空间中的病态几何推断，我们设计了一种用于不确定性学习的各向异性概率模型。此外，我们设计了双向域注意力，有效利用空间结构与多普勒相干性之间的互补性，使模型能够抑制虚假散射点。在公共数据集和真实世界数据集上进行的全面评估，证实了我们的方法在下游任务中具有出色的表征有效性、可靠性和可扩展性。

致谢

本研究工作部分得到国家自然科学基金（批准号 62522214、62471194）以及湖北省重点研发计划（项目编号2025BAB023）的资助。

参考文献

[1] Dan Barnes 和 Ingmar Posner。《Under the radar：学习预测用于雷达里程计估计和度量定位的鲁棒关键点》。载于 2020 年 IEEE 国际

机器人与自动化会议（ICRA），第 9484–9490 页。IEEE，2020 年。2[2] Paul J Besl 和 Neil D McKay。三维形状配准方法。载于《传感器融合 IV：控制范式与数据结构》，第 586–606 页。国际光学工程学会，1992 年。6[3] Stephen Blake。面向多目标和非均匀杂波的 OS-CFAR 理论。《IEEE航空航天与电子系统汇刊》，24(6):785–790，1988 年。2、6、7[4] Yuwei Cheng、Jingran Su、Mengxin Jiang 和 Yimin Liu。一种用于机器人环境感知的新型雷达点云生成方法。《IEEE 机器人学汇刊》，38(6):3754–3773，2022 年。2、6、7[5] Laura Dodds、Tara Boroushaki、Kaichen Zhou 和 Fadel Adib。通过毫米波表面法线估计进行非视距三维物体重建。载于《第23届移动系统、应用与服务国际年会》论文集，第 445–458 页，2025 年。2[6] Cong Fan、Shengkai Zhang、Kezhong Liu、Shuai Wang、Zheng Yang 和 Wei Wang。通过视觉惯性监督增强毫米波雷达点云。arXiv 预印本 arXiv:2404.17229，2024 年。1[7] Martin A Fischler 和 Robert C Bolles。随机采样一致性：一种用于模型拟合的方法，及其在图像分析和自动制图中的应用。《《ACM 通讯》》，24(6):381–395，1981 年。6[8] Prashant P Gandhi 和 Saleem A Kassam。单元平均 CFAR 检测器的最优性。《IEEE 信息论汇刊》，40(4):1226–1228，2002 年。2[9] Hong Gao、Xiangkai Xu、Tianqi Zhu、Xiugang Dong、Yiming Bao 和 Min Ling Zhang。Radar-Mamba：基于状态空间模型的四维毫米波点云增强。载于《第33届 ACM 多媒体国际会议》论文集，第 1774–1782 页，2025 年。1[10] Pengen Gao、Shengkai Zhang、Wei Wang 和 Chris Xiaoxuan Lu。DC-Loc：通过显式多普勒补偿实现基于汽车雷达的精准度量定位。载于《2022 年机器人与自动化国际会议（ICRA）》，第 4128–4134 页。IEEE，2022 年。1、2[11] Pengen Gao、Shengkai Zhang、Wei Wang 和 Chris Xiaoxuan Lu。通过单芯片雷达结合多普勒补偿实现自动驾驶中的鲁棒度量定位。《IEEE 智能交通系统汇刊》，25(1):491–502，2023 年。2[12] Kyle Harlow、Hyesu Jang、Timothy D Barfoot、Ayoung Kim 和 Christoffer Heckman。机器人技术的新篇章：近期毫米波雷达在机器人技术中的应用综述。《IEEE 机器人学汇刊》，2024 年。1[13] Youngseok Kim、Juyeb Shin、Sanmin Kim、In-Jae Lee、Jun Won Choi 和 Dongsuk Kum。CRN：用于精准、鲁棒、高效三维感知的相机雷达网络。载于《IEEE/CVF 国际计算机视觉会议》论文集，第 17615–17626 页，2023 年。1[14] Kenji Koide、Masashi Yokozuka、Shuji Oishi 和 Atsuhiko Banno。用于快速、精准三维点云配准的体素化 GICP。载于《2021 年 IEEE 国际机器人与自动化会议（ICRA）》，第 11054–11059 页。IEEE，2021 年。2[15] Andrew Kramer、Kyle Harlow、Christopher Williams 和 Christoffer Heckman。Coloradar：直接式 3D 毫米波雷达数据集。《国际机器人研究杂志》41(4):351–360，2022年。3[16] Zhiwei Lin、Zhe Liu、Zhongyu Xia、Xinhao Wang、Yong- tao Wang、Shengxiang Qi、Yang Dong、Nan Dong、Le Zhang 和 Ce Zhu。RCBEVDet：用于 3D 目标检测的鸟瞰视图雷达-相机融合。载于《IEEE/CVF计算机视觉与模式识别会议》论文集，第14928–14937页，2024年。1[17] Ramon Nitzberg。针对多种干扰的恒虚警率信号处理器。《IEEE航空航天与电子系统汇刊》(1):27–34，1972年。2[18] Changsong Pang、Xieyuanli Chen、Yimin Liu、Huimin Lu 和 Yuwei Cheng。RadarMoseve：用于仅雷达移动目标分割和自车速度估计的时空Transformer网络。载于AAAI人工智能大会论文集，第4424–4432页，2024年。1, 6[19] Akarsh Prabhakara、Tao Jin、Arnav Das、Gantavya Bhatt、Lilly Kumari、Elahe Soltanaghai、Jeff Bilmes、Swarun Ku- mar 和 Anthony Rowe。毫米波雷达生成高分辨率点云。载于2023年IEEE机器人与自动化国际会议（ICRA），第4135–4142页。电气电子工程师学会，2023年。2, 4, 6, 7[20] Ignacio Roldan、Andras Palffy、Julian F. P. Kooij、Dariu M. Gavrila、Francesco Fioranelli 和 Alexander Yarovoy。使用RaDelft数据集的深度汽车雷达检测器。《IEEE雷达系统汇刊》2:1062–1075，2024年。3, 6[21] Olaf Ronneberger、Philipp Fischer 和 Thomas Brox。U-net：用于生物医学图像分割的卷积网络。载于《医学图像计算与计算机辅助干预——MICCAI 2015：第18届国际会议》，德国慕尼黑，2015年10月5日至9日，论文集，第III部分18，第234–241页。施普林格，2015年。2[22] Aleksandr Segal、Dirk Haehnel 和 Sebastian Thrun。广义ICP。载于《机器人学：科学与系统》，第435页。美国华盛顿州西雅图，2009年。6[23] Dang-wei Wang、Xiao-yan Ma、A-Lei Chen 和 Yi Su。利用具有两个分布式阵列的宽带MIMO雷达系统进行高分辨率成像。《IEEE图像处理汇刊》19(5):1280–1289，2009年。2[24] Shengpeng Wang、Xin Luo、Yulong Xie 和 Wei Wang。SDDiff：通过空间-多普勒融合提升雷达感知。载于《第三十四届人工智能国际联合会议论文集》，IJCAI-25，第8805–8813页。人工智能国际联合会议组织，2025年。主会场。1, 2, 6, 7[25] Shengpeng Wang、Yulong Xie、Qing Liao 和 Wei Wang。S3E：雷达-惯性系统的自监督状态估计。载于《IEEE/CVF 国际计算机视觉会议》论文集，第26686–26695页，2025年。1, 2[26] Wei Wang、Chunshen Li、Bixin Zeng、Lieke Chen、Liang Sun、Kai Luo 和 Da Chen。缓解密集交通中汽车毫米波雷达感知所受的干扰

场景。《IEEE移动计算汇刊》，2025年。1[27] Ruibin Zhang、Donglai Xue、Yuhan Wang、Ruixu Geng 和 Fei Gao。通过高效跨模态扩散模型实现密集且精准的雷达感知。《IEEE机器人与自动化快报》9(9):7429–7436，2024年。4[28] Ruijie Zhang、Bixin Zeng、Shengpeng Wang、Fuhui Zhou 和 Wei Wang。RALD：利用潜在扩散生成高分辨率三维雷达点云。载于AAAI人工智能大会论文集，2026年。1，2[29] Chunran Zheng、Wei Xu、Zuhao Zou、Tong Hua、Chongjian Yuan、Dongjiao He、Bingyang Zhou、Zheng Liu、Jiarong Lin、Fangcheng Zhu、Yunfan Ren、Rong Wang、Fanle Meng 和 Fu Zhang。Fast-LIVO2：快速直接的激光雷达–惯性–视觉里程计。《IEEE 机器人学汇刊》41 346，2025 3266：–。[30] Kai Zheng、Wuqiong Zhao、Timothy Woodford、Ren- jie Zhao、Xinyu Zhang 和 Yingbo Hua。利用相控MIMO架构增强毫米波雷达感知。载于第22届移动系统、应用与服务年度国际会议论文集，第56 69页，2024年2–。[31] Yuan Zhuang、Binliang Wang、Jianzhu Huai 和 Miao Li。4D IRIOM：四维成像雷达惯性里程计与建图。《IEEE机器人与自动化快报》8 3253，2023 6 32462( ): –。