利用学习到的表征进行室内无人机的FMCW雷达感知

Ali Safa[1,3], Tim Verbelen[2,3], Ozan C¸atal[2,3], Toon Van de Maele[2],Matthias Hartmann[3],Bart Dhoedt[2,3],Andr´e Bourdoux[3]1*ESAT*，鲁汶大学， [2]*IDLab*，根特大学， [3]*imec*，*3001*，鲁汶，比利时{Ali.Safa, Tim.Verbelen}@imec.be

arXiv:2301.02451v1 [cs.RO] 6 Jan 2023

摘要—**调频连续波（FMCW）雷达是一种很有前景的室内无人机传感器技术，可提供环境中障碍物的距离、角度以及多普勒速度信息。近年来，研究人员提出了用于处理FMCW数据的深度学习方法，在距离-多普勒图或距离-方位角图上的表现优于传统检测技术。然而，这些方法也有代价：每项新任务都需要针对高维输入数据训练一种深度神经网络架构，这会给数据带宽和处理预算带来压力。本文研究了能够从FMCW雷达数据中生成低维表示的无监督学习技术，并评估这些表示在多大程度上可复用于多个下游任务。为此，我们推出了一个新的原始雷达ADC数据集，这些数据由安装在室内飞行无人机平台上的雷达采集，并附有检测目标真值。我们通过真实雷达数据表明，利用学习到的表征，我们能够达到传统雷达处理技术的性能；此外，我们的模型可以使用不同的输入模态进行训练，例如仅包含连续发射的两个啁啾信号的原始ADC采样。**

补充材料

我们发布 下方链接中提供了本研究所用的数据集 ow[1].

一、引言

无人机在室内飞行比在室外飞行困难得多，因为缺少 GPS 等精确定位信息，而且对障碍物检测与避障的要求也更加严格 [1]。因此，如何根据传感器观测构建连贯的世界视图，是自主室内无人机面临的一项重要挑战。一种常被忽视、但对此很有用的传感器是调频连续波（FMCW）雷达。仅凭单个雷达帧即可稳健地估算距离、速度和角度，这为传统使用的加速度计、陀螺仪和摄像头传感器提供了极佳的补充信息。传统的雷达处理方法会通过傅里叶处理，将原始雷达ADC值转换为距离、速度和角度信息 [2]。然而，生成的数据格式仍具有很高的维度，因此雷达传感器与下游处理单元之间也需要高带宽连接。通常，这种傅里叶处理之后还会接着应用恒虚警率（CFAR）算法，生成一个检测目标列表，其中包含目标的距离、速度和到达角 [3]。

近年来，深度学习技术已被证明非常适用于各种传感器处理任务。雷达领域也是如此，其特征学习能力往往使其比经典算法更适用，表现优于基于手工特征提取的技术 [4]。此类深度神经网络（ DNN ）通常处理傅里叶处理数据，例如距离-方位-多普勒图 [5] 或微多普勒图 [6]。然而，这些方法的弱点在于，每项具体任务都需要在高维预处理雷达图上重新训练 DNN。

本文研究了能否利用无监督深度学习方法，生成可重复用于多种下游任务的低维雷达表示。此外，我们还研究了能否仅从两个啁啾信号的原始 ADC 数据中学习此类表示，而非使用雷达处理中通常采用的完整啁啾帧 [5], [6],，从而有望降低能耗和数据带宽需求。为此，我们聚焦于室内无人机飞行场景，并推出了一个新颖的大规模数据集，其中包含原始调频连续波雷达样本，以及多个下游目标检测任务的真实标注信息。结果表明，从距离-多普勒图和距离-角度图中学习到的低维无监督表征，能够有效编码环境中目标的距离、速度和角度信息。此外，仅用两个啁啾信号的数据训练得到的表征也包含相关的距离、速度和角度信息。

总而言之，我们的贡献如下：

- 我们提出了一个新颖的大规模数据集，其中包含在室内飞行无人机上采集的 RGBD 和原始调频连续波雷达数据 [1]。
- 我们提出一种通用的无监督学习方法，可在不同输入格式下获取雷达数据的低维表示。
- 我们在一组下游任务上评估这些表示的有效性，并将结果与传统雷达处理技术进行比较。
- 我们证明了，即使仅使用两个连续啁啾信号的原始ADC采样，我们的方法也能成功运行。

本研究获得了弗拉芒政府（人工智能研究计划）的资助。Ozan C¸atal 获得了弗拉芒研究基金会（FWO）提供的博士研究资助。

[1]https://thesmartrobot.github.io/数据集

本文的组织结构如下。第二节介绍相关工作。第三节解释数据集的采集过程。第四节介绍我们构建的各种神经网络模型。第五节展示实验结果。第六节给出结论。

II. 相关工作

调频连续波雷达已广泛用于距离、速度和到达角检测 [2], , 尤其是在汽车应用领域。近年来，人们越来越关注利用深度神经网络改进雷达处理，例如专注于雷达天线设计、雷达信号识别、基于高距离分辨率剖面的自动目标识别，以及杂波识别与抑制 [7]。

大多数相关工作集中于自动驾驶应用领域。例如，Major 等人 [5] 使用卷积神经网络处理距离-方位角-多普勒张量，以进行车辆检测。Patel 等人 [8] 同样采用卷积神经网络，以监督方式进行目标分类；而 Wheeler 等人 [4] 提出了一种变分自编码器架构，并针对自动驾驶数据中的距离-方位图进行微调，以学习准确的雷达传感器模型。在室内飞行无人机领域，雷达已被用作障碍物检测 [3] 和里程计估计 [9]的传感器。此外，研究者还提出了深度学习技术，利用微多普勒特征实现无人机定位和活动分类 [6]。

当前雷达深度学习方法的主要缺点是，它们基于高维雷达图运行，并且每遇到一项新任务都必须重新训练。与此不同，我们提出学习通用的低维雷达表征，以便在多种下游任务中重复使用。

III. 数据集

我们在仓库实验室环境中，使用 NXP HoverGames无人机采集了一套全新的室内无人机飞行数据集。这是首个同时包含 RGBD相机数据和 FMCW数据的同类数据集。此外，与更常见的后处理雷达图不同，我们记录了原始ADC雷达采样。图 2 展示了我们的无人机，它搭载了 TI IWR 1443 毫米波雷达和 Intel RealSense D435 相机。表 I 给出了所用的具体传感器配置参数。除 RGBD 和 FMCW数据外，我们还存储 PX4飞行控制器的内部扩展卡尔曼滤波器（EKF）状态，以及无线电遥控器发送的执行器指令（偏航-俯仰-横滚-推力）。所有数据均由机载 Jetson Nano 计算机记录，并与 5 FPS 的雷达帧率同步。我们还使用 Qualisys 基于标记点的动作捕捉系统（MOCAP）记录六自由度姿态，为第五节 A 中定义的部分下游回归任务提供真实信号。

数据是在三个录制场景中采集的：如图3所示，无人机由人工操控，在实验室内飞行。在第一个场景中，无人机在实验室内飞行，穿梭于模拟仓库布局的狭窄通道之间。在

TI IWR 1443 毫米波雷达	
啁啾数	128
发射天线数	2
接收天线数	4
每个啁啾的采样数	256
起始频率	77GHz
频率斜率	50e12
采样率	6.24e6
ADC 起始时间	11 μ秒
扫频结束时间	68 μ秒
空闲时间	40 μ秒
Intel RealSense D435 相机	
彩色分辨率（W × H）	640 × 480
深度分辨率（W × H）	640 × 480

表 I：传感器配置。

第二个场景中，无人机在开放空间内从一面墙壁飞向另一面墙壁，并由 MOCAP 系统进行跟踪。在第三个场景中，一个角反射器，即一个铝箔制成的金字塔形反射器（图1e中也有展示），被放置在开放空间的中心（即 MOCAP 参考坐标系的原点），无人机则悬停在角反射器前方。对于场景1至场景3，我们分别采集了11274、5005和2798帧数据，总计38GB。

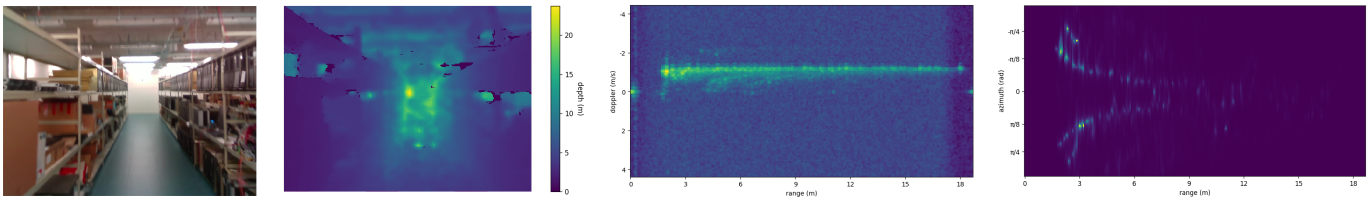
除了原始ADC采样外，我们还将经过后处理的距离-多普勒图和距离-方位角图纳入数据集。距离-多普勒图通过对原始ADC采样值在快时间和慢时间维度上进行二维傅里叶变换，然后对所有天线的幅度求平均来生成。对于距离-方位图，我们使用 Capon波束形成 [10], , 采用128个角度区间，从而生成与距离-多普勒图尺寸相同的距离-方位角图。这样，我们便可以像后文所述，对两种模态重复使用相同的神经网络架构。图1展示了采集的数据集示例，包括摄像头和深度数据，以及相应的雷达数据距离-多普勒图和距离-方位角图。

IV. 模型

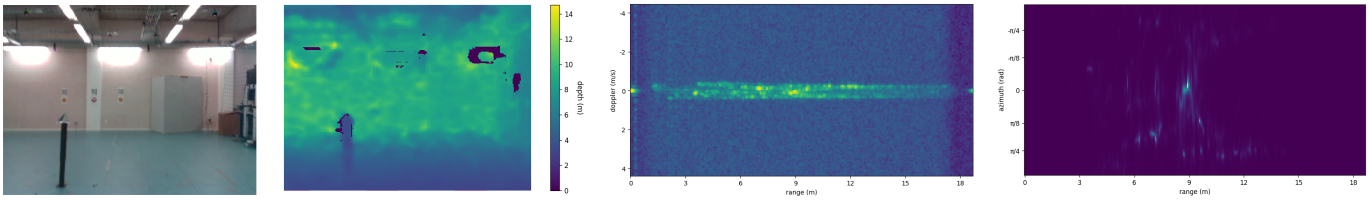
由于我们希望生成适用于各种下游任务的相关中间表示，因此提出了三种用于雷达处理的不同生成模型，均基于成熟的变分自编码器（VAE）框架 [11], [12]。高层数据流如图4所示。与汽车场景目标检测领域现有的相关工作类似，我们构建了一个能够处理距离-方位角（RA）图和距离-多普勒（RD）图的VAE模型。最后，我们还提出了一种新颖的雷达处理方法，采用生成建模方法，直接从原始ADC采样生成RA图和RD图。

A. 变分自编码器

我们提出的所有架构均基于用于生成建模的变分自编码器（VAE）框架 [11],[12]。VAE 使用两个神经网络——编码器和解码器网络——来摊销变分贝叶斯推断过程。通过最大化



(a) (b) (c) (d)



(e) 摄像头 (f) 深度 (g) 距离-多普勒 (h) 距离-方位角

图1：场景1（a、b、c、d）中穿行于通道时，以及场景3（e、f、g、h）中悬停在角反射器前方时，摄像头、深度、距离-多普勒和距离-方位角视图示例。

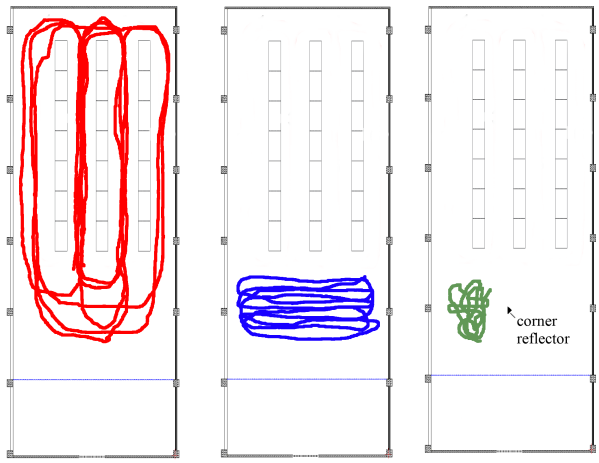
证据下界（ELBO），或等价地，通过最小化以下损失函数来共同优化这两个网络：

$$\mathcal{L} = E_q\big[\log p_\theta(x|z)\big] - D_{KL}\big[q_\phi(z|x)||p(z)\big], \qquad (1)$$

其中，$p(z)$表示一个（固定的）先验分布，$p_\theta(x|z)$表示学习得到的似然（解码器）分布，$q_\phi(z|x)$表示学习得到的变分后验（编码器）分布，x 和z 分别表示观测变量和潜变量。具体而言，编码器将高维传感器输入映射到低维状态空间，并通过编码器模型输出分布均值和标准差，将其参数化为多元各向同性高斯分布。通常选择标准正态分布作为先验分布$p(z) = \mathcal{N}(0, 1)$。



图2：我们使用一架搭载 TI 79GHz毫米波雷达和 Intel Realsense D435 RGBD摄像头的 NXP 无人机。当无人机处于摄像头视野内时，Qualisys动作捕捉系统会跟踪无人机参考坐标系。



(a) (b) (c)

图3：我们在三个场景中采集数据：(a) 场景1：沿通道飞行；(b) 场景 2：从一面墙飞向另一面墙；(c) 场景3：在角反射器前悬停。

B. 距离-多普勒变分自编码器

我们研究的第一个模型（图4a）以距离-多普勒图作为输入和目标输出。输入距离-多普勒图由原始雷达ADC采样经过距离-多普勒傅里叶处理生成 [3]。似然损失采用均方误差（均方误差）。该模型使用卷积神经网络进行参数化，具有 32 个潜在维度，架构如表II所述。

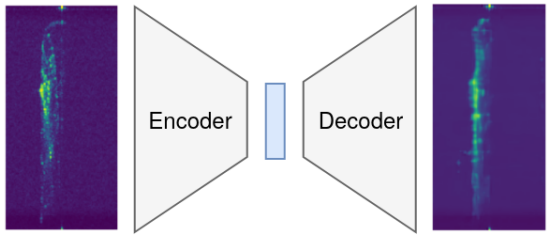
C. 距离-方位角变分自编码器

类似地，我们沿快时间方向进行快速傅里叶变换，并使用

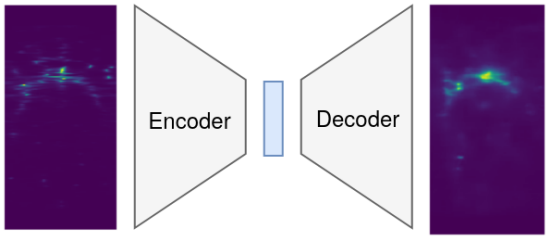
Capon方法进行波束形成，从原始ADC中提取距离-方位图 [10]，并将其作为RA模型的输入和目标（图4b）。由于输入数据的形状相似，RA模型可以与RD模型采用相同的架构。

D. 啁啾*VAE*

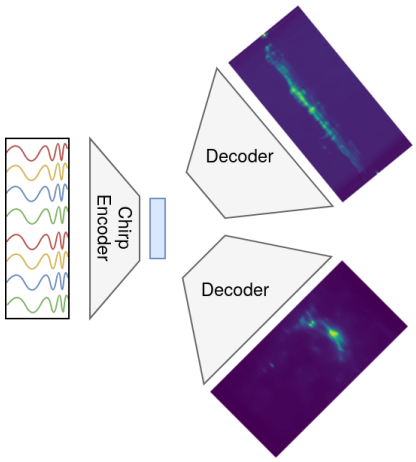
我们提出的第三种模型以最初的两个原始雷达啁啾为输入，并像B和C中那样将它们编码到潜在空间中。但在这种情况下，模型使用两个不同的解码器，将潜在值分别解码为距离-方位图或距离-多普勒图（图4c）。这样，模型就能自主学习生成这些图所需的相关特征，而不必



(a) RD 变分自编码器



(b) RA 变分自编码器



(c) 啁啾变分自编码器

图 4：提出的不同传感器模型。距离-多普勒（RD）变分自编码器（图 a）以距离-多普勒图作为输入。距离-方位角（RA）变分自编码器（图 b）以距离-方位图作为输入。啁啾变分自编码器（图 c）以连续发射的两个啁啾信号的 ADC采样值作为输入，并重建与该观测对应的距离-多普勒图和距离-方位图。

依赖预定义的傅里叶特征。该模型与距离-方位图模型和距离-多普勒图模型共用相同的解码器架构，但需要使用不同的编码器。其参数见表II。我们还在相同架构上尝试先对原始ADC采样进行距离FFT变换，并将该模型称为啁啾VAE + FFT（下文讨论中将如此称呼），然后提取所得信号的幅度和相位值。

E. 训练

我们使用Adam优化器 [13] 训练所有模型，初始学习率设为1e-4，并采用GECO [14] 优化技术。该技术在训练初期会提高重建项的权重，以避免后验坍塌。作为预处理步骤，我们对距离-多普勒图和距离-方位角图进行缩放，并使用Sigmoid函数将其压缩至0到1之间，作为神经网络的输入。我们仅使用场景1数据集训练模型，训练轮次为10k。

V. 实验结果

为了验证所学习表示的有效性，我们定义了四个下游任务，并为这些任务获取了真实标注信息。这些任务可通过传统雷达处理技术解决，重点是估计距离信息（即到墙壁或目标的距离）、速度信息（即向前移动的速度）和角度信息（即相对于目标的到达角）。为了在测试时评估不同方法在下游任务上的表现，我们固定编码器模型的权重，并额外训练一个具有两层、每层包含128个隐藏神经元的全连接神经网络，以回归任务

	层	神经元/滤波器	激活函数
RA/RD Encoder	卷积层	16	带泄漏的 ReLU
	卷积层	16	带泄漏的 ReLU
	卷积层	32	带泄漏的 ReLU
	卷积层	32	带泄漏的 ReLU
	线性层	1024	带泄漏的 ReLU
	线性层	64	无（均值）和 Softplus（标准差）
Chirp Encoder	卷积层	512	带泄漏的 ReLU
	卷积层	512	带泄漏的 ReLU
	卷积层	32	带泄漏的 ReLU
	线性层	512	带泄漏的 ReLU
	线性层	64	无（均值）和 Softplus（标准差）
Decoder	线性层	1024	带泄漏的 ReLU
	线性层	4096	带泄漏的 ReLU
	卷积层	32	带泄漏的 ReLU
	卷积层	32	带泄漏的 ReLU
	卷积层	16	带泄漏的 ReLU
	卷积层	16	带泄漏的 ReLU
	卷积层	1	无（RD）或 Sigmoid函数（RA）

表II：各模型的神经网络架构。所有卷积层均使用 3x3 卷积核。似然模型中的卷积层步幅和填充均为 1，以确保输入形状保持不变。上采样通过最近邻插值完成。编码器的输出表示一个 32 维各向同性高斯分布，包含 32 个均值和 32 个标准差。

目标值。随后，我们报告测试集性能，并与手工设计的雷达处理基线进行比较。下文将首先介绍不同任务、真实值的获取方式以及基线处理方法，之后讨论我们的结果。

A. 下游任务

1) 到墙的距离：对于第一个任务，我们使用在场景 2 中采集的数据。在该场景中，无人机径直飞向墙壁，掉头后再飞向另一侧。任务是回归无人机到墙壁的距离，如图 5a 所示。为了获得真实数据，我们使用动作捕捉系统的位姿信息来计算到墙壁的距离。作为雷达处理基线，我们检测距离-方位图中的最高峰，并根据距离单元和雷达距离分辨率计算距离。

2) 前向速度：除了估计到墙壁的距离外，我们还使用场景 2 中的数据来估计无人机飞向墙壁时的前向速度。真实值通过计算前后两个时间步之间的距离变化，并除以时间戳给出的时间间隔得出。作为传统雷达处理基线，我们检测距离-多普勒图中的最高峰，并根据多普勒单元估计速度。

3) 到角反射器目标的距离：对于目标检测，我们使用在场景3中采集的数据：角反射器放置在空间中央，无人机在反射器周围不同距离和角度的位置悬停。由于角反射器安装在 MOCAP 参考坐标系的原点处，因此可根据无人机位姿还原到目标的真实距离。作为传统雷达处理基线，我们跟踪距离-方位图中的最高峰（仅考虑 0 至 5 米范围内的距离）。

4) 到角反射器目标的角度：除目标距离外，我们还恢复了角反射器的到达角，如图 5b 所示。在此情况下，传统雷达处理基线会跟踪距离-方位图中反射器峰值的最大幅度所对应的角度单元。

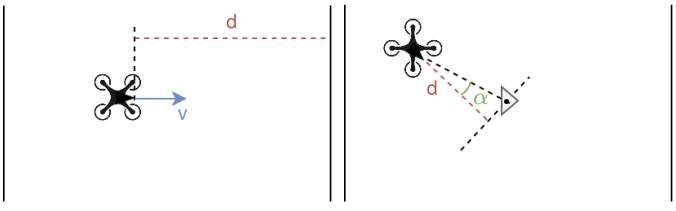


图5：我们考虑四项下游任务：(a) 估计到墙壁的距离 d (i) 和无人机向前速度 v (ii)，以及 (b) 估计到角反射器的距离 d (iii) 和角度 α (iv)。

B. 结果

对于所有任务，我们采用 5/6 比 1/6 的训练-测试集划分比例，并针对每个目标任务分别训练一个下游任务神经网络，训练 500 个训练轮次。我们报告测试集相对于真实值的均方根误差，以及中位数误差和四分位差。表 III 总结了结果。在距离和速度任务中，表现最佳的模型是 RDVAE，该模型基于距离-多普勒图进行训练。需要注意的是，总体而言，雷达处理方法提供了较强的基线，但其均方根误差更大。这是由于存在一些离群值，即频谱中检测到错误峰值的情况；这一点也体现为较低的四分位差。此外，对于距离估计任务，雷达处理基线相对于真实信号存在偏差，因为无人机向前移动时未能与对面的墙壁保持完全垂直对齐，从而高估了距离。这一点体现为显著的中位数误差。图 6 将传统雷达处理基线、RDVAE 和 CVAE 的结果与真实值进行了比较。这表明，对于较大的距离，雷达处理会略微高估距离预测，并且距离预测中存在一些离群值。

对于角度估计，在距离-方位图上训练的 RAVAE 模型具有最低的均方根误差。图7比较了真实角度随时间的变化，以及 CVAE、RAVAE 和雷达处理的结果。尽管雷达处理在大多数时间都与真实信号高度吻合，但偶尔出现的离群值仍会导致较大的均方根误差。

尽管 CVAE 模型的表现较差，但它们确实捕捉到了一些距离、速度和角度信息的特征（见图 6 和 7）。鉴于 CVAE 只需雷达发送和接收两个啁啾信号，且采用的编码器模型复杂度较低，因此与全分辨率距离-方位角-多普勒图相比，它们可以提供延迟更低、功耗更低的替代方案，但预测准确度也较低。

C. 讨论

值得注意的是，尽管无监督模型是在场景1的数据上训练的，而该场景的数据特征与

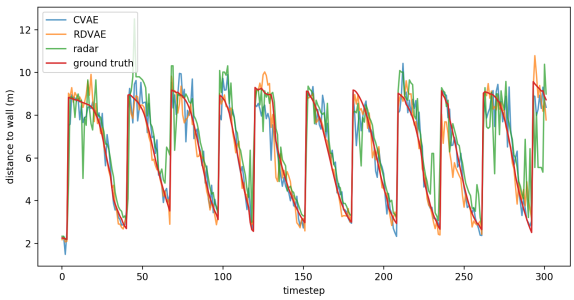


图 6：真实墙距与雷达处理、CVAE 和 RDVAE 的比较。

	距离 (i)			速度 (ii)			目标距离 (iii)			目标角度 (iv)		
模型	RMSE	Med.	四分位距	RMSE	中位数	四分位距	RMSE	Med.	四分位距	RMSE	Med.	四分位距
雷达	1.32	0.43	0.51	0.20	-0.02	0.28	0.48	0.20	0.14	0.14	0.03	0.07
RDVAE	**0.75**	-0.05	0.59	**0.14**	0.02	0.17	**0.19**	0.03	0.22	0.17	0.02	0.19
RAVAE	0.86	0.00	0.70	0.28	-0.06	0.37	0.23	0.04	0.25	**0.11**	-0.01	0.13
CVAE	0.84	0.00	0.75	0.48	-0.19	0.61	0.28	0.08	0.31	0.18	0.00	0.20
CVAE + 快速傅里叶变换	0.89	0.00	0.87	0.48	-0.16	0.57	0.24	0.06	0.32	0.18	0.01	0.20

表 III：实验结果。我们根据均方根误差、真实值与预测之间的中位数误差，以及误差的四分位差，对各模型在四项下游任务上的表现进行了比较。

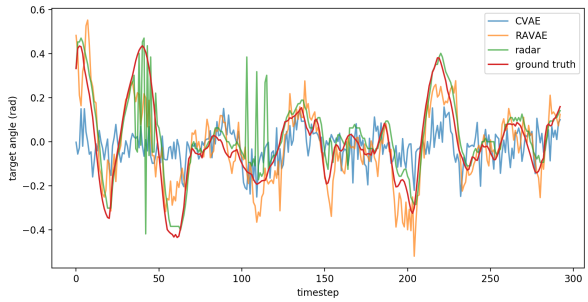


图7：目标的真实角度与雷达处理、CVAE 和 RAVAE 的结果对比。

场景2和场景3中记录的数据不同，表 III 的结果依然如此。与开放空间中的飞行相比，穿行于通道之间的飞行包含更多杂波和反射。之所以作此限制，是因为为了公平地开展评估，我们需要下游任务所需的真实定位信息。有趣的是，尽管存在这种差异，学习到的表征仍然捕获了完成下游任务所需的信息。未来工作的一个重要方向是在更多样化的环境中采集数据，以进一步评估我们学习到的表征在多大程度上能够泛化。此外，还可以考虑更复杂的场景和下游任务，例如检测移动障碍物，或在同步定位与建图（SLAM）场景中检测闭环。

尽管处理原始 ADC 数据的模型表现较差，但它们仍可能是一个值得探索的未来研究方向，因为所需的啁啾信号数量减少了 64 倍，预处理步骤也更少。例如，可以研究不同的啁啾编码器架构（如采用循环层的架构），以改进雷达表征。通过这种方式，在雷达处理过程中，可以实现自适应的功耗与精度之间的权衡：仅在需要提高系统精度时，才增加啁啾数。

VI. 结论

本文提出了一种学习调频连续波雷达数据低维表示的方法。我们针对距离-多普勒图、距离-方位角图或原始啁啾数据，分别试验了多种编码器-解码器架构。为了评估所得表征的有效性，我们将神经网络回归器与传统的手工设计雷达处理方法在多项下游任务上的表现进行了比较。为此，我们推出了一个新数据集，记录无人机在室内仓库环境中飞行时的摄像头 RGBD 数据和调频连续波雷达数据。据我们所知，本文是首批致力于解决如何学习鲁棒雷达表征这一问题的研究之一：我们开发了用于处理雷达数据的新型基于变分自编码器的神经网络架构，并在一组不同的下游任务上对其进行了评估。未来，我们将采集更多样化环境中的数据，以进一步研究这类表征在多种环境中的泛化能力，并试验其他啁啾编码器架构。

参考文献

[1] G. De Croon 和 C. De Wagter，“室内环境自主飞行的挑战”，载于*2018*年*IEEE/RSJ*智能机器人与系统国际会议（*IROS*），2018年，第1003–1009页。[2] M. A. Richards，雷达信号处理基础。纽约：麦格劳-希尔，2005年。[3] A. Safa、T. Verbelen、L. Keuninckx、I. Ocket、M. Hartmann、A. Bour- doux、F. Catthoor 和 G. G. E. Gielen，“一种在室内无人机避障方面优于有序统计恒虚警率的低复杂度雷达检测器”，*IEEE*应用地球观测与遥感选题期刊，第14卷，第9162–9175页，2021年。[4] T. A. Wheeler、M. Holder、H. Winner 和 M. Kochenderfer，“深度随机雷达模型”，2017年1月。 [在线]。可访问：http: //arxiv.org/abs/1701 09180 。[5] B. Major、D. Fontijne、A. Ansari、R. T. Sukhavasi、R. Gowaikar、M. Hamilton、S. Lee、S. Grechnik 和 S. Subramanian，“利用距离-方位角-多普勒张量上的深度学习进行汽车雷达车辆检测”，2019年。[6] P. K. Rai、H. Idsøe、R. R. Yakkati、A. Kumar、M. Z. Ali Khan、P. K. Yalavarthy 和 L. R. Cenkeramaddi，“利用毫米波调频连续波雷达对无人飞行器进行定位和活动分类”，*IEEE*传感器期刊，第21卷，第14期，第16 043–16 053页，2021年。[7] Z. Geng、H. Yan、J. Zhang 和 D. Zhu，“雷达深度学习：综述”，*IEEE Access*，第9卷，第141 800–141 818页，2021年。[8] K. Patel、K. Rambach、T. Visentin、D. Rusev、M. Pfeiffer 和 B. Yang，“基于深度学习的汽车雷达频谱目标分类”，载于*2019*年*IEEE*雷达会议（*RadarConf*），2019年，第1–6页。[9] M. Mostafa、S. Zahran、A. Moussa、N. El-Sheimy 和 A. Sesay，“用于全球导航卫星系统拒止环境下无人机辅助导航的雷达与视觉里程计集成系统”，《传感器》，第18卷，第9期，2018年。[10] J. Li、P. Stoica 和 Z. Wang，“关于稳健Capon波束形成和对角加载”，*IEEE*信号处理汇刊，第51卷，第7期，第1702–1715页，2003年。[11] D. P. Kingma 和 M. Welling，“自编码变分贝叶斯”，*arXiv*预印本，2014年。[12] D. J. Rezende、S. Mohamed 和 D. Wierstra，“ 深度生成模型中的随机反向传播与近似推断 ”，载于第 *31* 届国际机器学习会议论文集，第32卷，第2期。机器学习研究论文集，2014年6月22–24日，第1278–1286页。[13] D. P. Kingma 和 J. Ba，“ Adam：一种随机优化方法”，2017年。[14] D. J. Rezende 和 F. Viola，“驯服变分自编码器”，2018年。