使用毫米波雷达进行物体识别的系统性研究

Maloy Kumar Devnath、Avijoy Chakma、Mohammad Saeid Anwar、Emon Dey、Zahid Hasan、Marc Conn*、Biplab Pal、NirmalyaRoy
信息系统系，*计算机工程系马里兰大学巴尔的摩县分校（UMBC），美国{maloyd1、achakma1、saeid.anwar、edey1、zhasan3、mconn1、bpal1、nroy}@umbc.edu

arXiv:2305.02085v1 [cs.CV] 3 May 2023

摘要

毫米波（MMW）雷达凭借其不受光照和天气影响的传感能力，正成为智能环境中的一种关键传感技术。这些能力已得到广泛探索，并与智能车辆系统相结合，通常部署于工业级毫米波雷达中。然而，工业级毫米波雷达往往价格昂贵，难以用于可部署的社区智能环境应用。另一方面，商用毫米波雷达还存在一些尚未得到充分研究的潜在基础性挑战，这些挑战涉及物体识别、活动识别、实时人员跟踪、物体定位等任务。这些任务通常伴随图像和视频数据，而个人相对容易获取、理解并进行标注。然而，图像和视频数据受光照和天气影响，容易受到遮挡效应的干扰，并且会不可避免地引发个人隐私顾虑。因此，有必要研究一种替代性传感机制，以验证商用毫米波雷达是否能够成为可行的替代方案，从而消除对这些依赖并保护隐私。在推广毫米波雷达之前，需要针对其在不同运行环境下的实际可行性和性能回答若干问题。为回应这些问题，我们使用商用毫米波雷达——德州仪器的汽车毫米波雷达（AWR2944）——采集了一个数据集，并在本研究中利用多种深度学习算法，报告了实现物体识别性能最优的实验设置。此外，我们稳健的数据采集流程使我们能够系统性地研究并识别跨环境场景下物体识别任务的潜在挑战。我们探索了克服这些潜在挑战的可行方法，并报告了广泛的实验结果。

索引词

毫米波雷达、跨环境、跨距离、跨高度、机器人学、物体识别、智能感知、领域适应。

一、引言

图像和视频等视觉数据已广泛用于构建智能环境，以支持各种应用，包括远程监控、安全管理、物体识别、移动物体跟踪、自主智能体等 [1], [2]。然而，成像作为一种感知机制容易受到光照和天气等环境因素的影响，而且摄像机拍摄到的画面可能会侵犯个人隐私。在某些情况下，隐私是一项不可妥协的约束，因此，对以下与视觉数据相关的问题，答案可能并不乐观。

1）养老院的住户是否会感到舒适，并同意被多台摄像机全天候监视？2）如果有人夜间因身体不适而躺倒在厨房地板上，基于摄像机的系统会如何响应？3）能否通过图像识别出草地游乐场中的微小危险物质?

上述顾虑促使我们探索主动感知机制，例如基于雷达的技术，这种技术有望绕过隐私和环境依赖方面的限制。值得注意的是，具备各种能力的雷达技术已被探索用于众多应用，例如远程监控 [3], 安全管理 [4], 物体识别 [5],移动物体跟踪 [6], [7],自主智能体（无人地面车辆） [8] 以及其他许多领域。我们发现，这些雷达技术通常价格昂贵、难以在短时间内开发完成，而且需要大量领域知识 [3] ，这成为社区部署的一项阻碍因素。毫米波雷达是近期加入雷达技术领域的一项技术，它以短脉冲形式发射短波长（30-300GHz）的电磁波，并接收投射路径上物体反射回来的脉冲 [9] ，如图 1 所示。毫米波雷达已可商用，并能够集成到研究级可编程自主智能体和车辆中 [8], [10]–[12]。然而，毫米波雷达并非完全不受限制，因此我们开展这项系统性研究，探讨其背后的挑战。

第二节讨论的大多数文献都涉及大型物体 [13] ，忽略了不同环境条件下较小的物体，而后者会带来若干挑战。当我们使用稀疏的毫米波雷达点云数据时，这些挑战会更加严峻。首先，**物体尺寸和形状的影响** ——诸如断裂的

通讯作者：*Maloy Kumar Devnath*

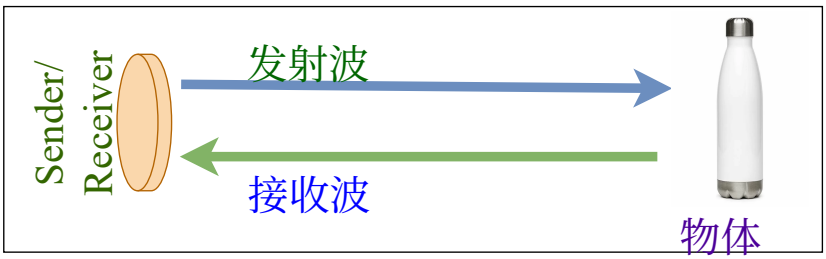

图 1：毫米波雷达的基本原理。

金属叉齿、家庭环境中的宠物、电子设备和挂绳等危险物体通常体型较小，因此用于接收和反射雷达信号的表面积也较小。其次，**运行环境** ——物体通常由反射特性各异的材料构成。当雷达向物体发射毫米波时，产生的反射信号具有不同的信噪比。周围物体的反射信号会使最终接收的信号更加复杂，进而增加物体识别的难度。第三，**雷达位置与距离** ——雷达的位置以及与物体之间的距离也是影响因素。如图 2 所示，智能手机的俯视图和侧视图之间的表面积变化显而易见。此外，随着雷达与物体之间的距离增加，发射信号会扩散到更广的区域，导致接收信号衰减。目前，商用毫米波雷达在不同形状、环境和动态条件下的物体识别性能尚不明确。

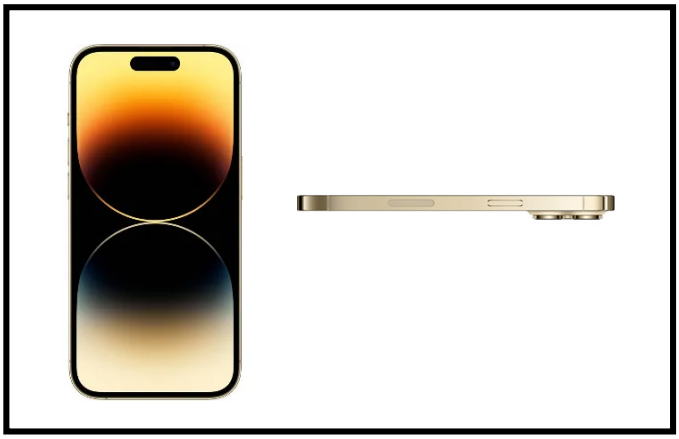

图 2：智能手机的顶视图和侧视图。

本研究的贡献如下：
1) 我们开发了用于识别小尺寸物体的模型，利用低分辨率、稀疏的毫米波雷达点云数据，在三种具有不同设置的室内和室外环境中开展研究，包括静态或动态雷达投影，以及不同的高度或距离。2) 我们采用领域自适应技术，大规模提升深度学习模型的鲁棒性，具体针对利用毫米波雷达获取的低分辨率、稀疏点云数据中的小物体识别。据我们所知，这是首项针对这类物体探索领域自适应技术的研究。3) 我们利用 TI AWR2944 毫米波雷达采集的大规模数据集，在晴朗的室外环境、光线充足的室内环境以及黑暗的室内环境中开展实验，验证了所提出系统的有效性。具体而言，我们重点开展可行性研究，以识别不同环境设置（距离、高度、光照和背景）下尺寸各异的小物体，例如一角硬币、铅笔、塑料片、25美分硬币、无人地面车辆（UGV）、水瓶、木材、铅笔和纸张，并采集了约五小时的毫米波数据集 [14]。我们基于领域自适应（DA）的方法有效应对了训练数据与测试数据之间动态因素变化带来的影响，并取得了 0.898 的 F1 分数。

本文的结构安排如下：第二节讨论毫米波雷达的近期研究成果。第三节介绍数据采集与处理技术。第四节详细阐述模型训练机制。第五节报告实验设置、结果与发现，第六节总结全文。

II. 相关工作

在本节中，我们简要讨论基于毫米波雷达的方法：首先，讨论将毫米波雷达作为独立传感器单元使用的相关文献；其次，讨论毫米波雷达与其他传感器单元关联使用的相关文献。

A. 基于毫米波雷达的方法

毫米波雷达广泛用于各种研究，包括人体运动行为检测 [15], 周期性心率测量 [16], 导航 [17], 多人物体跟踪 [7], 姿态检测 [18] 与估计 [19], 人体活动识别 [20], 安全防护 [4], 自动驾驶 [11], [21], 人脸与情绪识别 [22], [23]。 [15] 感知用户的微多普勒信息并检测其运动行为。mBeats [16]以非侵扰的方式测量不同姿势下的心率。 [19] 利用两个雷达数据点进行人体姿态估计。利用两个雷达点生成热图，并采用卷积神经网络将二维热图转换为人体姿态。 [20]提出了 RadHAR，这是一种低成本的人体活动识别框架，利用来自毫米波雷达的稀疏且非均匀点云。 [4] 提出了一种使用毫米波雷达进行说话人验证的安全方法，以防止对抗性攻击并增强家庭安全。作者利用雷达捕捉声带振动和唇部运动来识别说话人。 [21]提出了一种新的毫米波雷达点云分类算法，以提高自动驾驶复杂场景中的人车分类准确率。

B. 毫米波雷达与其他传感器模态

除了作为独立的传感器模态进行部署外，毫米波雷达还被广泛用作基于视觉的传感器模态，主要用于克服基于视觉的方法在无光照环境下可见性方面的关键局限性。[24] 提出了一种基于融合的方法，利用毫米波雷达进行障碍物检测，并将提取的特征与视觉传感器的特征进行融合。 [25] 提出了一种新型雷达-摄像头融合系统，该系统考虑了来自异构传感器的两种不同坐标系统的误差范围。作者采用了一种新型融合扩展卡尔曼滤波器，以适应异构传感器。 [26] 提出了一种名为 milliEye 的框架，这是一种轻量级的毫米波雷达与摄像头融合系统，旨在边缘平台上实现鲁棒目标检测。与现有的传感器融合方法相比，milliEye 具有多项关键优势。 [5]提出了一种名为 RODNet 的深度雷达目标检测网络，该网络通过摄像头与雷达融合算法进行交叉监督。RODNet 考虑了各种驾驶场景下的目标检测。

C. 与现有方法的差异

汽车领域的高级驾驶辅助系统（ADAS）和自动驾驶应用利用毫米波雷达 [11] 实现更加以用户为中心的功能。例如，毫米波雷达可以识别道路上的车辆、行人等障碍物，并向驾驶员发出通知。Gao 等人利用不同场景下的到达角、多普勒速度等数据源，构建了一个包含各种物体的大型原始雷达数据集 [27]。 [6] 通过将从毫米波雷达获取的位置、速度和雷达散射截面（RCS）信息转换为图像，检测骑行者、行人和车辆。 [11] 利用距离-速度热图来区分车辆和行人。此外， [13] 提出了 mmwave-yolo，利用雷达散射截面数据检测人员、锥桶、自行车、标志牌、围栏和骑手。以往大多数研究都集中于利用毫米波雷达数据检测汽车、人员和自行车。以往研究主要关注较大的目标，而我们的研究则考察通常存在于室内或室外环境中的较小物体。

本研究考察了径向距离、信噪比以及噪声的统计特性。能够实现物体识别的毫米波雷达，可能是智能家居行业一项颇具前景的技术，可用于能源优化、安全防护和人机交互。因此，我们希望进一步了解毫米波雷达这一独特模态识别物体的能力。从实现角度来看，我们考虑了两种场景。首先，在雷达静止时，我们研究了尺寸较小的物体，例如一角硬币、铅笔、塑料片、木材和25美分硬币。对于毫米波雷达的动态状态，我们考虑了五种不同的物体：无人地面车辆（UGV）、水瓶、塑料片、纸张和衣物。在静止状态下，我们设想在地面或绿地上寻找物体。当雷达垂直发射信号时，需要额外的时间来接收信号。如果雷达处于运动状态，接收信号将很困难。因此，雷达静止时，我们将其水平放置。移动中的雷达会发射水平信号。在运动状态下，雷达以垂直方向接收信号。因此，雷达处于动态状态时，我们将其垂直放置。我们希望根据毫米波雷达的位置和状态，测量其性能表现。毫米波雷达的位置和状态发生变化时，所考虑的物体也会有所不同。由于物体与波长的尺寸比以及环境条件各不相同，使用毫米波雷达检测小型物体还面临一些额外的技术挑战，例如需要较高的信噪比、存在混淆等。

由于我们获取的是时间序列毫米波雷达数据，因此采用了 1D 卷积神经网络（卷积神经网络）来识别物体。其他研究人员使用了 2D CNN [6] ，而非 1D CNN，但鉴于我们数据的特性，1D CNN 的表现令人满意。1D CNN 的准确率达到了 95%，相关内容将在第五节中介绍。

III. 数据集

毫米波是频率范围为 30–300 GHz （1 毫米至 1 厘米）的短波长电磁波 [9]。这种雷达可精确测量物体的距离、速度和角度，且不受或仅受少量干扰 [9]。本节介绍这项系统性研究的数据采集流程和数据预处理。

A. 数据采集

首先，我们将毫米波雷达视为静态设备。我们使用一款集成在名为 TurtleBot3 的商用低成本机器人套件中的毫米波雷达 [1]，如图3(a)所示。其次，我们将毫米波雷达视为动态设备。图3(b)展示了数据采集时雷达的垂直安装位置。TurtleBot3 与毫米波雷达之间通过 Raspberry Pi 4B 接口进行通信。雷达的采样频率为 76–81 *GHz*，波长约为 4 毫米（约 0.16 英寸）。毫米波雷达将发射信号与雷达投影路径上的物体反射的信号混合后，可提供三轴径向距离、信噪比（SNR）和噪声。



(a) (b) (c)

图3：（a）红色毫米波雷达与TurtleBot3集成，位于一支黑色铅笔上方，由黑色电缆供电，并使用蓝色充电器充电；（b）红色毫米波雷达与TurtleBot3集成后，发射水平信号以识别物体；（c）在Lablight下以恒定速度移动雷达，以84英寸的距离进行数据采集。

本研究考察了高度和光照条件对静态雷达数据采集的影响。研究考虑了两种不同的高度：将TurtleBot3放置在地面上，此时雷达与地面垂直相距7英寸；以及将其放置在一定高度，使雷达距地面53英寸。研究使用了由四种不同材料制成的五种不同物体（一角硬币（10美分美国硬币）、二十五美分硬币（25美分美国硬币）、铅笔、塑料片和木材），并在三种不同光照条件下，针对每种物体以不同角度采集两分钟的数据：Sunny、带灯光的室内环境（Lablight）以及无灯光的室内环境（夜间）。Sunny条件下在室外利用自然光进行数据采集，另外两种条件下则在有白光或无白光的实验室内进行。图4和图5展示了不同光照条件下静态雷达的数据分布。为研究距离和光照条件对移动雷达的影响，考虑了两种不同的距离：将TurtleBot3放置在地面上，此时雷达与物体水平相距42英寸；以及将其放置在某一位置，使物体距离雷达84英寸。研究使用了由四种不同材料制成的五种不同物体（无人地面车辆、水瓶、塑料片、纸张和衣物），并且数据
在三种不同的光照条件下，针对每种物体，以不同角度采集两分钟的数据。雷达以每秒0.025米的匀速，沿不同角度朝向物体来回移动，如图3(c)所示。当毫米波雷达处于动态状态时，物体的样本数量较少，因为接收器无法捕获所有信号。根据雷达垂直或水平发射信号的不同，我们将五种不同的物品分别放置在雷达下方或前方。总体而言，为了继续开展这项系统性研究，需要六组数据集。图6和图7展示了移动雷达在不同光照条件下的数据分布。

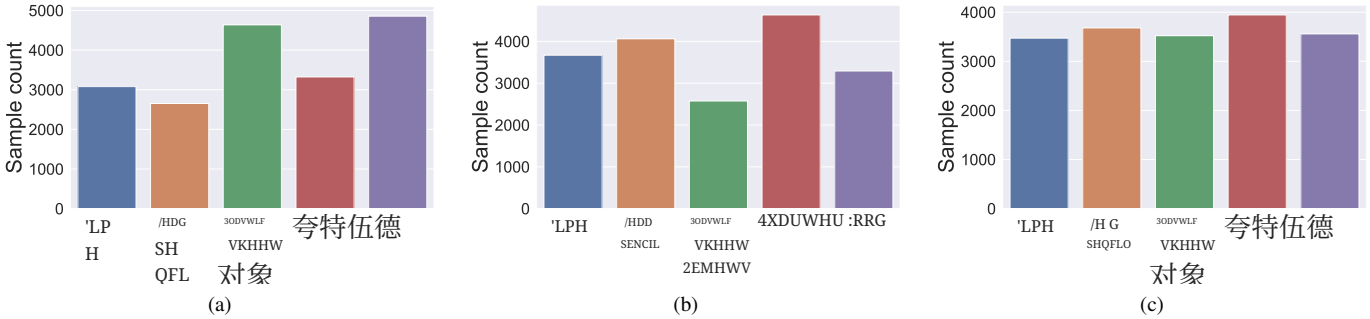

(a) (b) (c)

图 4：晴天条件下的数据分布 （L）环境、Lablight（M）环境和夜间（R）环境下，高度为 7 英寸时的情况（雷达处于静止状态）.

B. 数据预处理

从毫米波雷达数据中计算多个统计特征，例如标准差、方差、均值、最小值和最大值，并进一步使用 Sci-kit Python 中的标准缩放器对提取的特征进行标准化处理。

[1]https://emanual.robotis.com/docs/en/platform/turtlebot3/overview/

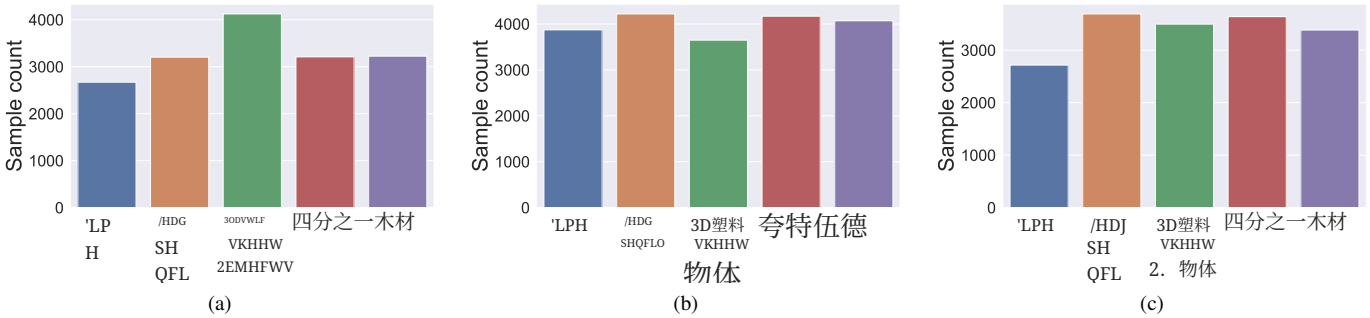

图 5：Sunny 环境下的数据分布 （左），Lablight（中）和夜间（右）环境下，高度为 53 英寸时的数据（雷达静止时） .

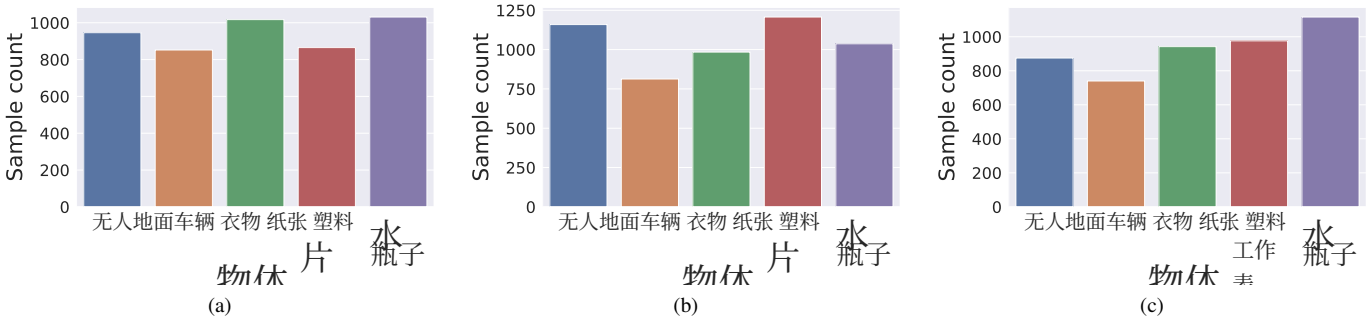

图 6：Sunny（左）、Lablight（中）和夜间（右）环境下，距离为 42 英寸时的数据分布（雷达动态时）。

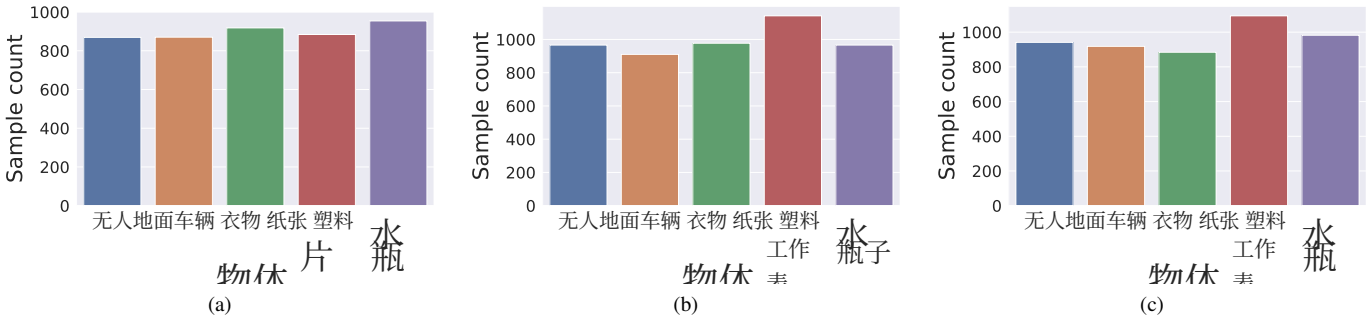

图 7：距离为 84 英寸时，Sunny（左）、Lablight（中）和夜间（右）环境下的数据分布（雷达处于动态状态时）。

库 [28]。标准化数据集正以分层方式按 70–30% 的比例进行划分，其中 70% 的数据用于训练，30% 用于测试。这种分层方式确保训练数据和测试数据能够代表每个类别。无论雷达处于静态还是动态状态，训练数据都会直接馈送至全连接层（FCL）。为了在较远距离或较高高度下识别动态或静态雷达中的物体，我们采用 1D 卷积神经网络（CNN）以实现更好的识别效果。为了生成 1D 卷积神经网络（CNN）的输入，我们将 10 个样本合并以创建一个 40×16 帧。随后，将该40×16 帧展平，以馈送至 1D 卷积神经网络（CNN）层。为了创建 40×16 帧，我们首先从数据集提取第 1 行至第 40 行的样本，然后提取第 2 行至第 41 行的样本，其余数据样本也依此类推。此处，40 行表示由毫米波雷达采集的 4 秒数据。为确保一致性，我们采用窗口化处理从同一物体获取的连续数据。每个窗口包含 40 行，对应 4 秒的毫米波雷达数据采集。我们的分析表明，准确识别需要 4 秒的数据。

在下一节中，我们将介绍用于可行性研究的深度学习模型。

IV. 研究方法

为探索使用低分辨率、稀疏点云数据进行物体识别的可行性，我们采用了两种不同的深度学习框架：一种使用 FCL，另一种基于卷积神经网络。接下来，我们使用领域自适应方法 [29] 来提高基于卷积神经网络的深度学习模型的鲁棒性。我们在第五节中介绍了 FCL 和卷积神经网络的结果。

1）全连接层的训练机制：如图 8(a) 所示，我们使用一个三层全连接多层感知机（MLP）作为物体识别器，以监督方式训练模型。前两层各包含 16 个计算单元，后接一个修正线性单元（ReLU）；最后一层后接 Softmax 层。我们将提取的特征输入模型，并按照公式 1 所述，采用分类交叉熵损失以监督方式进行训练。

$$L_{cce} = -\sum_{i=1}^{C} t_i log(p_i) \tag{1}$$

其中，C 是类别（物体）的总数，t_i 是真实标签，p_i 是物体识别器输出的 Softmax 概率。

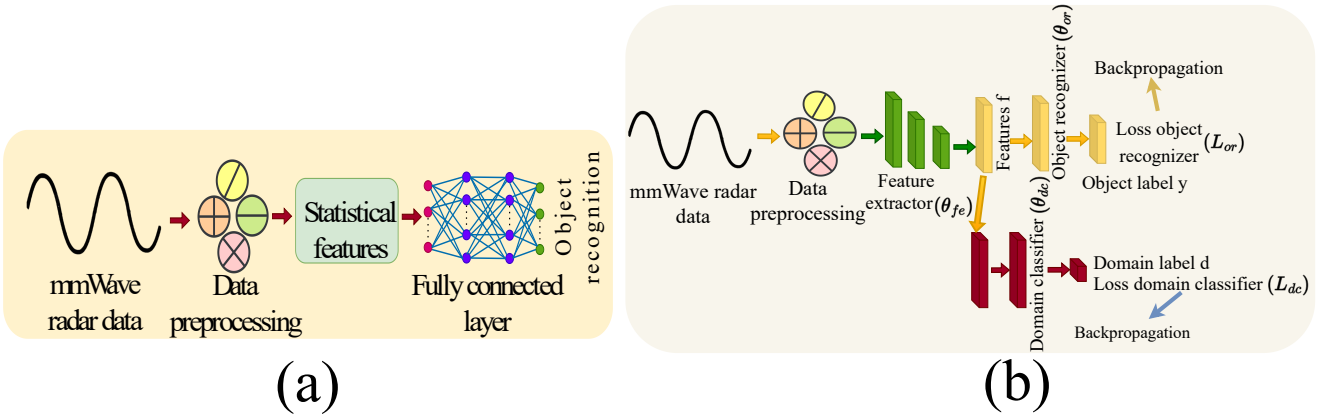

图 8：使用毫米波雷达进行物体识别的整体流程。(a) 将处理后的毫米波雷达数据输入 FCL 进行物体识别；(b) 将处理后的毫米波雷达数据输入卷积神经网络进行特征提取，并使用 FCL 识别物体。

2）基于卷积神经网络的深度学习模型训练机制：基于卷积神经网络的深度学习框架如图 8(b) 所示，可分为三个不同的模块：特征提取模块（绿色）、物体识别模块（黄色）和领域判别器模块（栗色）。特征提取模块由三个不同的 1D 卷积（Conv1D）层组成，每层均带有 ReLU 激活层。另一方面，物体识别器模块包含两个全连接层。最后，领域自适应模块包含一个全连接层，并在最后一层设有两个输出。为便于查阅，我们在表 I 中提供了架构设置的详细信息。

表 I：架构超参数。

超参数	数值
卷积滤波器数量	1x311 ，1x146 ，1x64
卷积滤波器维度	1x20,1x20,1x20
步幅	2
物体识别器模块中的单元数	64,32,16,5
领域自适应模块中的单元数	64,32,2

该框架在识别不同物体方面展现出良好的效果，领域自适应机制也有助于提升深度学习模型的适应性。在可行性研究中，我们使用了特征提取器和物体识别器模块。我们利用收集到的带标签数据集，以监督方式训练了网络。我们采用了按批次计算的分类交叉熵损失函数，具体如公式 1 所述。

接下来，我们采用域对抗方法 [29]，提升深度学习模型在物体识别方面的鲁棒性。我们使用相同的卷积神经网络模型识别物体，并添加一个域分类器（图 8(b) 中以栗色显示）。在本研究中，域分类器和特征提取器都采用对抗策略。这两个模块均接收来自有标签和无标签数据集的特征。域分类器尝试预测输入特征的来源，而特征提取器则致力于抵消这一目标。目标数据集是一个没有可用标签的开放数据集，而源数据集带有标签。在适应过程中，虽然这两个模块都会处理有标签和无标签数据的样本，但物体识别器仅使用来自源域的有标签数据集。当模型以半监督方式

运行时，使用的目标域标签较少。我们采用文献 [29],中的梯度反转层实现，如公式 2、3 和 4 所示，以实现这一策略。

$$\theta_{fe} = \theta_{fe} - \mu \left(\frac{\partial L_{or}^{i}}{\partial \theta_{fe}} - \frac{\partial L_{dc}^{i}}{\partial \theta_{fe}} \right) \tag{2}$$

其中，$\frac{\partial L_{or}}{\partial \theta_{fe}}$ 是损失函数物体识别器 L_{or} 相对于特征提取器 θ_{fe}的梯度，$\frac{\partial L_{dc}}{\partial \theta_{fe}}$ 是损失函数域分类器 L_{dc} 相对于特征提取器 θ_{fe} 的梯度，μ 是学习率。

$$\theta_{or} = \theta_{or} - \mu \frac{\partial L_{or}^{i}}{\partial \theta_{or}} \tag{3}$$

其中，$\frac{\partial L_{or}}{\partial \theta_{or}}$ 是损失函数 L_{or} 相对于物体识别器 θ_o的梯度。 r.

$$\theta_{dc} = \theta_{dc} - \mu \frac{\partial L_{dc}^{i}}{\partial \theta_{dc}} \tag{4}$$

其中，$\frac{\partial L_{dc}}{\partial \theta_{dc}}$ 是损失函数 L_{dc} 相对于域分类器 θ_d的梯度。 c.

V. 系统性研究

我们在本节报告实验结果。所有实验均在配备 NVIDIA GeForce RTX 3060 显卡的设备上进行。在本系统性研究的各项实验中，鉴于数据分布不平衡 [30]，我们采用微平均 F1（micro-F1）作为评估指标。微平均 F1 分数不会偏向占多数的样本。

A. 当毫米波雷达静止时

1) 环境的影响：本研究探讨了不同的表面材料如何影响反射的雷达信号，并最终影响物体的识别。雷达从较高的仰角向表面发射信号，并接收其传播路径上各种物体反射的信号。由于表面可能由不同的材料构成，信号的反射率也会发生变化。我们在保持距离固定的情况下，在三种不同的环境中进行物体识别实验。我们在固定高度下，从相同的环境中收集训练样本和测试样本。实验结果如图 9(a) 和图 9(b) 所示。对于毫米波雷达的 7 英寸和 53 英寸距离，我们采用了 FCL 和卷积神经网络（CNN）。FCL 和 CNN 的识别准确率均约为 85%。

核心要点：

- 晴朗的室外环境比室内环境（有光照和无光照的实验室环境）具有更好的识别性能。这一结论对于 FCL 和卷积神经网络方法均成立。这里，室外环境由混凝土表面构成，而室内环境的表面则是办公室地毯，通常由尼龙、烯烃或聚丙烯制成。
- 在室内环境中，随着高度增加，FCL 的性能会进一步下降，但卷积神经网络凭借其复杂的特征学习能力，能够保持性能。我们推测，随着高度增加，投射的雷达信号覆盖的面积会比高度较低时更大。覆盖面积增大后，反射信号会受到实验室周围物体的影响，而这些物体无法被 FCL 识别。卷积神经网络则可以利用更复杂的特征恢复性能，如图 9(b) 所示。

2）跨环境的影响：在本实验中，我们研究了不同环境下采集的数据所带来的影响。与前一项研究类似，在训练和测试期间，我们使用来自相同高度、但采集环境不同的数据集。以两个高度为 53 英寸的数据集为例，一个来自晴朗环境，另一个来自 Lablight 环境。我们使用晴朗环境的数据集训练模型，并在 Lablight 环境中对其进行测试。本研究的实验结果汇总于图 9(a) 和图 9(b) 中。

关键要点：

- 当训练和测试数据集的环境不同时，性能会显著下降，而当高度增加时，性能下降得更加明显。图 9(a) 和图 9(b) 表明，在跨环境评估中，高度 53 的表现甚至比高度 7 更差。为解决这一问题，我们采用了无监督域自适应（UDA）和半监督域自适应（SSDA）方法，并使用了来自目标域的 10% 和 20% 标注数据。图 9(a) 和图 9(b) 显示，SSDA 能够显著提升性能，而 UDA 带来的性能提升较小。在训练样本来自晴朗环境、测试样本来自夜间环境的情况下，使用 SSDA 后，F1 分数从 0.443 提升至 0.822（如图 9(a) 所示）。该方法同样适用于其他跨环境场景。

3）跨高度的影响：在跨环境研究中，我们发现，不同环境导致的数据分布异质性会严重影响模型性能。本研究旨在探究使用从不同高度采集的相似环境数据样本进行训练和测试时，模型的性能表现。实验结果见表 II。

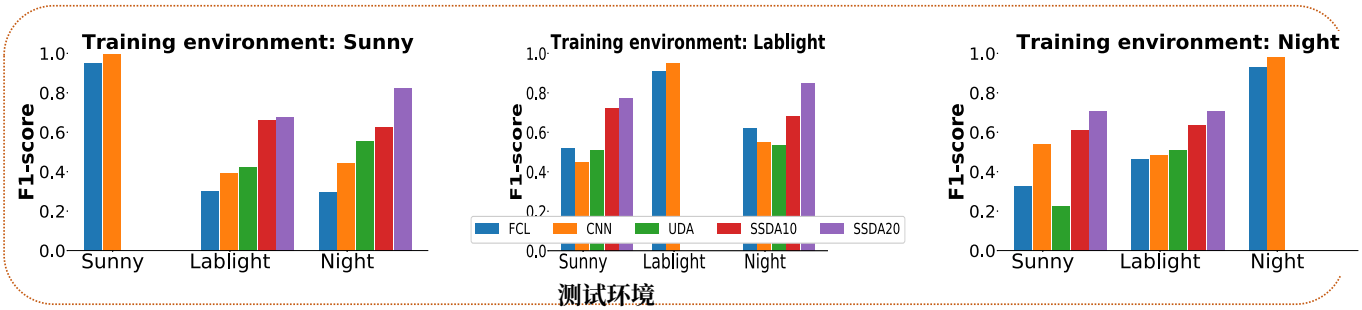

(a)

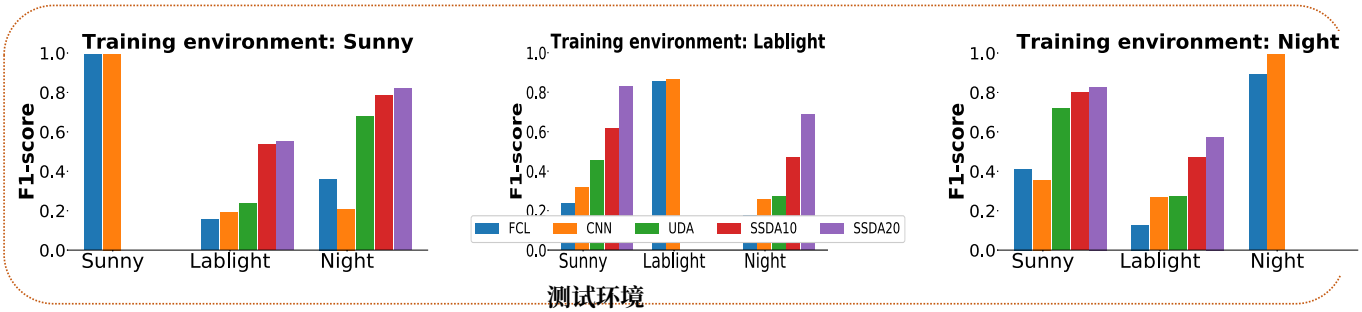

(b)

图 9：在两种条件（相同环境和跨环境）下，不同深度学习模型在相似高度下的性能：(a) 垂直高度为 7 英寸时；(b) 垂直高度为 53 英寸时。

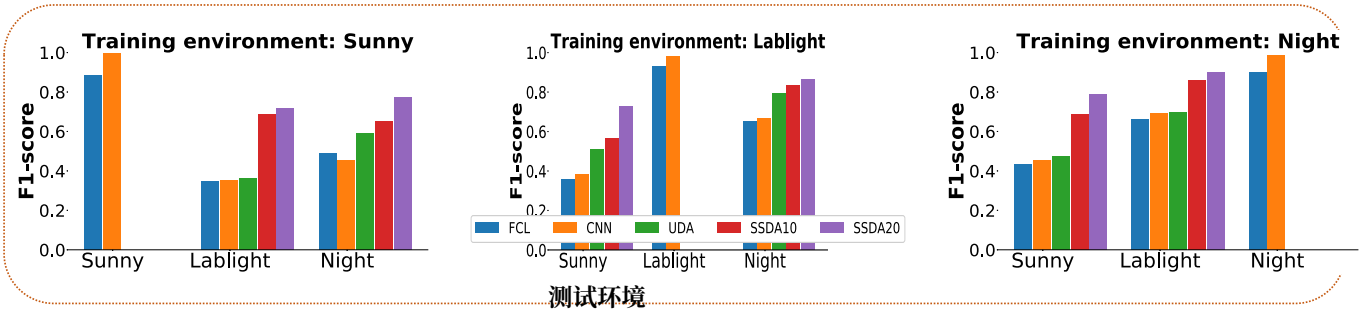

(a)

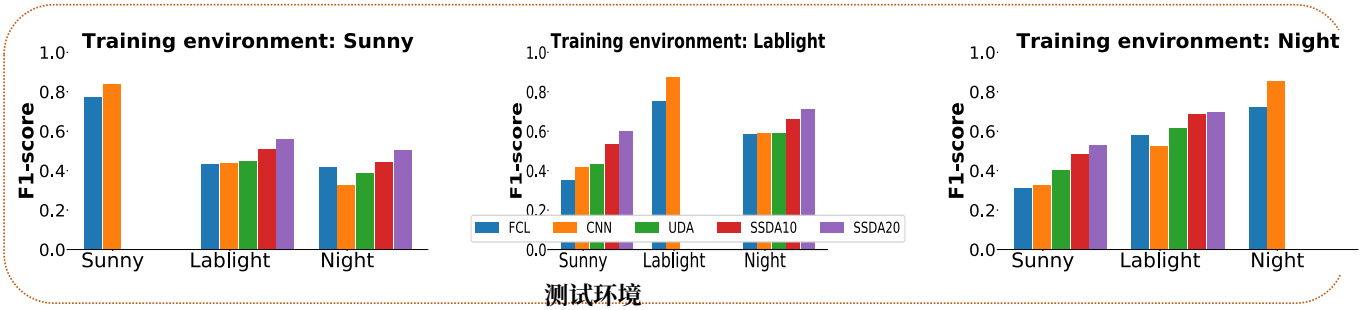

(b)

图 10：不同深度学习模型在相似距离下两种条件（相同环境和跨环境）中的性能。(a) 水平距离为 42 英寸时；(b) 水平距离为 84 英寸时。

核心要点：

• 与跨环境类似，跨高度也会产生次优结果。我们观察到，在用于模型训练和测试的跨高度与跨环境设置中，呈现出相似的模式。表 II 显示，SSDA 能显著提升性能，而 UDA 的提升幅度较小。F1 分数从 0.238 上升至 0.834（SSDA 10%），并

0.878（SSDA 20%）（如表 II 所示），训练样本和测试样本来自晴朗环境，但高度不同。它也适用于其他情况。

表 II：每　　在相同环境和不同高度下，不同深度学习模型的性能。

训练环境	测试环境	F1 分数（FCL）	F1 分数（卷积神经网络）	F1 分数（UDA）	F1 分数（SSDA 10%）	F1 分数（SSDA 20%）
Sunny（53）	Sunny(7)	0.158	0.238	0.312	0.834	0.878
夜间(53)	夜间(7)	0.346	0.217	0.250	0.531	0.799
Lablight(53)	Lablight(7)	0.262	0.329	0.371	0.495	0.587
Sunny(7)	Sunny（53）	0.107	0.193	0.342	0.645	0.909
夜间(7)	夜间(53)	0.198	0.296	0.410	0.537	0.588
Lablight(7)	Lablight(53)	0.276	0.301	0.380	0.437	0.488

Sunny(53)表示正在采集样本　　来自晴朗环境，其中距离为 53　　英寸。

B. 毫米波雷达处于动态状态时

1）环境的影响：我们在保持距离固定的情况下，考虑在三种不同环境中识别物体。我们考虑从相同环境中，以固定距离采集训练样本和测试样本。研究结果如图 10(a) 和图 10(b) 所示。对于距离为 42 英寸和 84 英寸的毫米波雷达，无论雷达处于静态还是动态状态，FCL 和卷积神经网络的识别性能均高于 92%。

主要结论：

- 在距离为 42 英寸时，使用 FCL 的情况下，实验室照明环境（室内）的识别性能优于室外环境（有光和无光的实验室环境）。使用卷积神经网络时，各种环境下的 F1 分数相近。这是意料之中的，因为卷积神经网络比 FCL 更强大。

- 使用 FCL 且距离为 84 英寸时，F1 分数不理想。不过，与其他条件相比，晴朗环境下的 F1 分数更高。距离为 84 英寸时使用卷积神经网络，可以学习复杂特征；如图 10(b) 所示，在实验室照明环境下，F1 分数从 0.754 提高到 0.873。这一提升也适用于其他情况，因为雷达在动态状态下难以捕获足够的信息。

2）跨环境的影响：在此，我们测试如何利用来自不同环境的数据得出结论。本研究在训练和测试中使用与前一项研究相同的数据集和距离，但不同之处在于周围环境发生了显著变化。我们考虑两组 42 英寸数据，一组采集自晴朗环境，另一组采集自实验室照明环境。使用在晴朗环境中采集的数据训练模型，然后在人工照明条件下进行测试。图 10(a) 和图 10(b) 展示了实验结果。

主要结论：

- 当训练数据集和测试数据集所处环境不同时，性能会显著下降。图 10(a) 和图 10(b) 展示了深度学习模型的性能。出现这种情况是可以预料的，因为尽管距离相同，数据分布仍会因环境而异。为解决这一问题，我们采用了 UDA 和 SSDA 方法，并使用了来自目标域的 10% 和 20% 带标签数据。图 10(a) 和图 10(b) 表明，SSDA 能显著提升性能，而 UDA 带来的提升相对较小。在使用夜间环境的训练样本、并以实验室照明环境的测试样本进行测试后，F1 分数从 0.691 提升至 0.898（见图 10(a)）。这一结论同样适用于其他跨环境场景。

3）跨距离的影响：我们观察到，由于不同环境造成的数据分布异质性，模型性能显著下降。在此，我们研究当训练和测试数据样本具有相同的环境条件、但采集距离不同时，模型的 F1 分数会发生什么变化。表 III 展示了实验结果。

主要结论：

- 与跨环境类似，跨距离也会导致次优结果。跨距离和跨环境下的训练与测试条件呈现出相似的趋势。应用 UDA 和 SSDA 后，性能有所提升。夜间环境下，F1 分数从 0.521 提升至 0.768 （见表 III ）。此处，训练样本采集自 84 英寸处，而测试样本采集自 42 英寸处。接下来，我们将在下文介绍未来研究计划的进展情况。

VI. 讨论

我们探讨了开发和实现利用毫米波雷达的深度学习模型所面临的问题。这些问题包括数据集中的潜在噪声、使用点云雷达数据进行实时实现的挑战，以及该系统对日常生活的潜在影响。

表 III：相同环境设置下，不同深度学习模型在跨距离条件下的性能。

训练环境	测试环境	F1 分数（FCL）	F1 分数（卷积神经网络）	F1 分数（UDA）	F1 分数（SSDA 10%）	F1 分数（SSDA 20%）
Sunny（84）	Sunny（42）	0.492	0.514	0.494	0.542	0.670
夜间（84）	夜间（42）	0.571	0.521	0.583	0.702	0.768
Lablight（84）	Lablight(42)	0.460	0.491	0.512	0.603	0.644
Sunny(42)	Sunny(84)	0.405	0.457	0.461	0.500	0.570
夜间(42)	夜间(84)	0.466	0.526	0.543	0.563	0.631
Lablight(42)	Lablight(84)	0.411	0.422	0.445	0.518	0.532

Sunny(42) 表示从晴朗环境中采集的样本，其中距离为 42 英寸。

- 在数据采集过程中，周围的物体可能会向数据集中引入噪声。尽管这些物体可能被视为噪声，但我们认为，我们的模型具有足够的鲁棒性，能够在存在噪声的情况下识别真实物体。然而，未来我们或许可以通过减少这些周围物体引入的噪声来提高模型的性能。
- 将物体识别流程集成到实时系统中可能相对简单，但仍需考虑各种实现方面的挑战，例如功耗以及对周围物体产生的噪声的检测。这些挑战构成了实现实时应用的具体障碍。
- 我们的深度学习方法仅使用由毫米波雷达生成的经过处理的稀疏点云数据。如果我们引入不同类型的毫米波雷达数据，可能会导致处理和计算方面的困难，并可能需要对模型的超参数进行重大调整。
- 毫米波雷达技术有望同时识别熟悉和陌生的物体、活动及健康问题，并可能对日常生活产生深远影响。鉴于隐私顾虑对摄像头安装位置的限制，雷达可作为识别犯罪活动或其他日常活动的理想替代方案。

我们的研究即将接近尾声，接下来将总结当前的局限性和未来的研究方向。

VII. 结论

我们的研究表明，使用毫米波雷达进行静态物体识别取得了良好的效果。我们在各种条件下评估了所提出模型的性能，发现该模型在环境均一的数据上表现良好，但在环境异质的数据上表现欠佳。为解决这一问题，我们引入了领域自适应技术以提高准确率。然而，当前模型仅专注于识别静态物体。为应对现实世界中的应用需求，我们需要开发更先进的技术，以同时识别已知或未知的物体、活动和健康问题。该技术具有广泛的实际应用，尤其适用于因隐私问题而限制摄像头部署的领域，例如安保、监视和监控。

致谢

本研究获得美国陆军资助项目 #W911NF2120076 以及美国国家科学基金会本科生研究体验（REU）资助项目 # CNS-2050999 的支持。我们感谢 Kelly Sherbondy 博士在本项目中的合作。

参考文献

[1] Barry Brumitt、Brian Meyers、John Krumm、Amanda Kern 和 Steven Shafer。《Easyliving：智能环境技术》。载于 *Handheld and Ubiquitous Computing: Second International Symposium, HUC 2000 Bristol, UK, September 25–27, 2000 Proceedings 2*，第 12–29 页。Springer，2000 年。[2] Emon Dey、Jumman Hossain、Nirmalya Roy 和 Carl Busart。《Synchrosim：面向异构多机器人系统的集成协同仿真中间件》。载于 *2022 18th International Conference on Distributed Computing in Sensor Systems (DCOSS)*，第 334–341 页。IEEE，2022 年。[3] Mostafa Alizadeh、George Shaker、Jo˜ao Carlos Martins De Almeida、Plinio Pelegrini Morita 和 Safeddin Safavi-Naeini。《使用毫米波 FMCW 雷达远程监测人体生命体征》。*IEEE Access*，7：54958–54968，2019 年。[4] Yudi Dong 和 Yu-Dong Yao。《基于毫米波雷达的物联网智能家居安全说话人验证》。*IEEE Internet of Things Journal*，8 3511，2021 5 3500( )：–。[5] Yizhou Wang、Zhongyu Jiang、Yudong Li、Jenq-Neng Hwang、Guanbin Xing 和 Hui Liu。《Rodnet：一种通过摄像头-雷达融合物体三维定位进行交叉监督的实时雷达物体检测网络》。*IEEE Journal of Selected Topics in Signal Processing*，15(4)：954–967，2021 年。[6] Ruidong Xu、Yuan Zhu、Ke Lu 和 Hao An。《基于计算机视觉的毫米波雷达物体检测》。载于 *2022 4th International Conference on Advances in Computer Technology, Information Science and Communications (CTISC)*，第 1–8 页。IEEE，2022 年。[7] Peijun Zhao、Chris Xiaoxuan Lu、Jianan Wang、Changhao Chen、Wei Wang、Niki Trigoni 和 Andrew Markham。《mid：使用毫米波雷达跟踪和识别人群》。载于 *2019 15th International Conference on Distributed Computing in Sensor Systems (DCOSS)*，第 33–40 页。IEEE，2019 年。[8] Robin Amsters 和 Peter Slaets。《Turtlebot 3 作为机器人学教育平台》。载于 *Robotics in Education: Current Research and Innovations 10*，第 170–181 页。Springer，2020 年。[9] Cesar Iovescu 和 Sandeep Rao。《毫米波雷达传感器基础》。*Texas Instruments*，2020 年。[10] David R Green、Jason J Hagon、Cristina G´omez 和 Billy J Gregory。《使用低成本无人机进行环境监测、制图与建模：来自海岸带的示例》。载于 *Coastal management*，第 465–501 页。Elsevier，2019 年。[11] Onur Toker 和 Suleiman Alsweiss。《用于自动驾驶车辆行人识别的毫米波雷达方法》。载于 *2020 SoutheastCon*，第 1–2 页。IEEE，2020 年。

[12] Riadul Islam、Maloy K Devnath、Manar D Samad 和 Syed Md Jaffrey Al Kadry。Ggnb：用于 CAN 总线的基于图的高斯朴素贝叶斯入侵检测系统。*Vehicular Communications*，33:100442，2022。[13] Atsutake Kosuge、Satoshi Suehiro、Mototsugu Hamada 和 Tadahiro Kuroda。mmwave-yolo：一种基于毫米波成像雷达的实时多类别目标识别系统，应用于高级驾驶辅助系统。*IEEE Transactions on Instrumentation and Measurement*，71:1–10，2022。[14] Maloy Kumar Devnath、Avijoy Chakma、Mohammad Saeid Anwar、Emon Dey、Zahid Hasan、Marc Conn、Biplab Pal 和 Nirmalya Roy。毫米波目标识别数据集（mord），2023。[15] Renyuan Zhang 和 Siyang Cao。利用毫米波雷达，通过卷积神经网络实时检测人体运动行为。*IEEE Sensors Letters*，3(2):1–4，2018。[16] Peijun Zhao、Chris Xiaoxuan Lu、Bing Wang、Changhao Chen、Linhai Xie、Mengyu Wang、Niki Trigoni 和 Andrew Markham。利用机器人搭载的毫米波雷达感知心率。载于*2020 IEEE* 国际机器人与自动化会议（*ICRA*），第 2812–2818 页。IEEE，2020。[17] Chris Xiaoxuan Lu、Stefano Rosa、Peijun Zhao、Bing Wang、Changhao Chen、John A Stankovic、Niki Trigoni 和 Andrew Markham。透烟观测：利用低成本毫米波雷达实现鲁棒室内建图。载于第 *18* 届移动系统、应用与服务国际会议论文集，第 14–27 页，2020。[18] Arindam Sengupta、Feng Jin、Renyuan Zhang 和 Siyang Cao。mm-pose：利用毫米波雷达和卷积神经网络实时估计人体骨骼姿态。*IEEE Sensors Journal*，20(17):10032–10044，2020。[19] Guangzheng Li、Ze Zhang、Hanmei Yang、Jin Pan、Dayin Chen 和 Jin Zhang。利用毫米波雷达捕捉人体姿态。载于*2020 IEEE* 普适计算与通信国际会议研讨会（*PerCom* 研讨会），第 1–6 页，2020。[20] Akash Deep Singh、Sandeep Singh Sandha、Luis Garcia 和 Mani Srivastava。Radhar：从毫米波雷达生成的点云中识别人体活动。载于第 *3* 届 *ACM* 毫米波网络与感知系统研讨会论文集，第 51–56 页，2019。[21] Zihao Zhao、Yuying Song、Fucheng Cui、Jiang Zhu、Chunyi Song、Zhiwei Xu 和 Kai Ding。基于点云特征的核支持向量机，用于毫米波雷达中的人车分类。*IEEE Access*，8:26012–26021，2020。[22] Muralidhar Reddy Challa、Abhinav Kumar 和 Linga Reddy Cenkeramaddi。利用毫米波雷达成像进行人脸识别。载于*2021 IEEE* 智能电子系统国际研讨会（*iSES*）（前身为 *iNiS*），第 319–322 页。IEEE，2021。[23] Xiaochao Dang、Zetong Chen 和 Zhanjun Hao。基于深度学习的毫米波雷达情绪识别方法。*IET Radar, Sonar & Navigation*，2022。[24] Shuo Chang、Yifan Zhang、Fan Zhang、Xiaotong Zhao、Sai Huang、Zhiyong Feng 和 Zhiqing Wei。利用毫米波雷达和视觉传感器进行障碍物检测的空间注意力融合。*Sensors*，20(4):956，2020。[25] Renyuan Zhang 和 Siyang Cao。通过与摄像头融合，提升毫米波雷达跟踪和检测的可靠性。*IEEE Access*，7 137079，2019 137065：–。[26] Xian Shuai、Yulin Shen、Yi Tang、Shuyao Shi、Luping Ji 和 Guoliang Xing。millieye：一种用于鲁棒目标检测的轻量级毫米波雷达与摄像头融合系统。载于物联网设计与实现国际会议论文集，第 145–157 页，2021。[27] Xiangyu Gao、Guanbin Xing、Sumit Roy 和 Hui Liu。毫米波汽车雷达测试平台实验。载于*2019* 年第 *53* 届阿西洛马会议：信号、系统与计算机，第 1–6 页，2019。[28] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss、V. Dubourg、J. Vanderplas、A. Passos、D. Cournapeau、M. Brucher、M. Perrot 和 E. Duchesnay。Scikit-learn：Python 中的机器学习。*Journal of Machine Learning Research*，12:2825–2830，2011。[29] Yaroslav Ganin 和 Victor Lempitsky。通过反向传播实现无监督域自适应。载于国际机器学习会议，第 1180–1189 页。PMLR，2015。[30] Rebeen Ali Hamad、Masashi Kimura 和 Jens Lundstr¨om。针对智能家居环境中的深度学习，不平衡数据处理方法的效能。*SN Computer Science*，1(4):204，2020。