基于注意力的分布式雷达感知实现透明且韧性的活动识别

Mina Shahbazifar，Zolfa Zeinalpour-Yazdi，MatthiasHollick，Arash Asadi，以及 Vahid Jamali

arXiv:2601.02874v1 [eess.SP] 6 Jan 2026

摘要—**分布式雷达传感器能够实现稳健的人类活动识别。然而，随着协同节点数量的增加，如何从大型数据集中进行特征提取以及实现透明的数据融合，带来了新的挑战。我们提出了一种端到端框架，可直接处理原始雷达数据。每个雷达节点采用轻量级二维卷积神经网络（CNN）来提取局部特征。随后，自注意力融合模块对节点间关系进行建模，并执行自适应信息融合。局部特征提取将输入维度最多降低 480×。这显著降低了通信开销和时延。注意力机制通过量化每个雷达节点的贡献，提供了固有可解释性。混合监督对比损失进一步提升了特征可分性，尤其适用于细粒度且不平衡的活动类别。在真实世界的分布式超宽带（UWB）雷达数据集上的实验表明，所提出的方法在取得高于基线方法的平均准确率的同时，将模型复杂度降低了 70.8%。总体而言，该框架实现了透明、高效且低开销的分布式雷达感知。**

索引词—**分布式雷达传感器、活动识别、可解释性、注意力机制、传感器融合。**

I. 引言

The 对智能环境系统日益增长的需求，推动了人们对无线活动识别的浓厚研究兴趣。研究人员探索了各种信号表示和神经网络架构，以从无线信号中提取有意义且可付诸行动的见解 [1], [2]。尤其是，深度神经网络因能够从复杂数据中自动学习判别性特征而备受关注 [3]。研究人员探索了多种信号模态（如 WiFi 和毫米波），其中 UWB 雷达凭借极短的脉冲，能够提供更高的时间和空间分辨率 [4]。要在实际场景中部署活动识别，尤其是在工业环境中的高风险作业区域等敏感场景下，连续感知对于确保用户活动无论身处何处或朝向如何，都能得到可靠识别[5], [6]。在这方面，分布式感知已成为实现稳健活动识别的一种颇具吸引力的解决方案 [7]。然而，扩大协同工作的感知节点数量会带来两个关键挑战：首先，增加雷达会显著增大数据量并提高预处理成本，尤其是在生成多普勒特征或点云时。其次，实现稳健且可解释的融合会变得困难，因为每个雷达节点的信号质量都会因目标位置、朝向和传播条件的变化而呈现依赖于几何形态的差异。

先前研究。 当前解决方案试图应对这些挑战，但只取得了部分成效。大多数分布式雷达系统在进行学习或分类之前，仍依赖繁重的预处理，包括生成距离-多普勒（RD）图 [8]–[10],多普勒频谱 [5], [7], [11], [12], 和点云 [13]–[14]。这些基于离散傅里叶变换（DFT）的处理流程需要执行旁瓣抑制[15], [16], 等额外操作，从而增加了计算开销。此外，这类表示可能会舍弃有用的原始信息，妨碍对依赖几何结构的变化进行建模 [15]。

第二类研究聚焦于融合。现有方法通常采用早期、中间或后期融合机制，但每种机制都存在固有局限。早期融合需要将所有节点的原始测量数据传输至中央处理器，导致通信带宽需求显著增加，并使系统对噪声较大或质量较低的节点高度敏感 [12], [15], [17], [18]。后期融合通过整合高层决策来降低带宽需求，但会限制不同视角之间的交互，并将计算负载转移至各个传感器，从而限制对互补信息的利用能力 [7], [8], [14], [19]。中间融合提供了更均衡的权衡：各雷达先提取局部特征，再进行联合整合；然而，由于各个节点的贡献彼此交织，最终的表示往往缺乏可解释性 [5], [7], [13]。

我们的解决方案。 为应对这些挑战，我们提出了一种可直接处理原始雷达数据的端到端框架。该模型采用轻量级二维卷积神经网络编码器模块，在每个雷达节点提取局部表示。随后，自注意力融合模块对节点间关系进行建模，并自适应地融合来自不同视角的信息。训练完成后，卷积神经网络编码器会部署在各个节点上。只有紧凑且语义丰富的特征会被传输至融合处理器。这种设计降低了通信开销和推理延迟。注意力机制具有固有可解释性 [20], [21]。注意力权重能够明确量化

Shahbazifar、Hollick 和 Jamali 的研究得到了德国黑森州 LOEWE计划在 emergenCITY 中心内的共同资助 [LOEWE/1/12/519/03/05.001(0016)/72]。
M. Shahbazifar 和 Z. Zeinalpour-Yazdi 任职于伊朗亚兹德 8915818411 的亚兹德大学电气工程系（电子邮箱：minashahbaz- ifar@stu.yazd.ac.ir；zeinalpour@yazd.ac.ir）。V. Jamali 和 M. Shahbazifar 任职于德国达姆施塔特 64283 的达姆施塔特工业大学弹性通信系统组（电子邮箱：vahid.jamali@tu-darmstadt.de；m.shahbazifar@rcs.tu-darmstadt.de）。M. Hollick 任职于德国达姆施塔特 64289 的达姆施塔特工业大学安全移动网络实验室（电子邮箱：mhollick@seemoo.tu- darmstadt.de）。A. Asadi 任职于荷兰代尔夫特 2628 CD 的代尔夫特理工大学无线通信与感知实验室（电子邮箱：A.Asadi@tudelft.nl

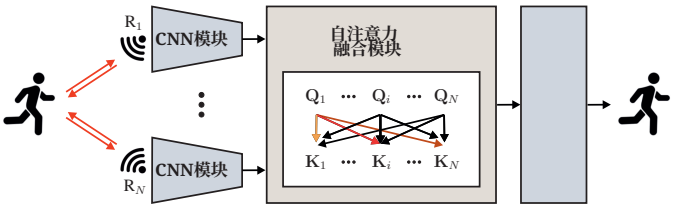


图 1：所提出的分布式雷达识别模型由用于局部特征提取的二维卷积神经网络模块、用于自适应且可解释融合的自注意力模块，以及最终的分类模块组成。

每个雷达节点对最终决策的贡献。这免去了使用事后可解释性方法的必要。此外，混合监督对比损失提升了特征可分性。这对于细粒度和不平衡活动类别尤其有益 [22], [23]。我们的主要贡献如下：

- **端到端原始数据框架**。我们提出了一种基于分布式 UWB 雷达的连续活动识别端到端框架，可直接处理原始雷达数据，无需进行多普勒特征和点云等代价高昂的预处理。该架构包括用于局部特征提取的二维卷积神经网络模块、用于自适应节点间融合的自注意力模块，以及用于分类的全连接模块（图 1）。训练时采用混合监督对比损失，以增强细粒度且不平衡活动类别的特征可分性。
- **可解释的基于注意力的多节点融合**。我们为分布式雷达感知引入了一种基于注意力的融合机制。自注意力模块对节点间关系进行显式建模，并生成一个权重矩阵，用以量化各雷达节点的贡献。消融实验表明，注意力导出的重要性分数能够反映各节点对最终决策的实际影响。这赋予了该方法固有的可解释性，而早期融合、中间融合或后期融合方案均不具备这一特性。

- **通信效率**。通过在每个节点部署训练好的轻量级二维卷积神经网络编码器，传输至中央处理器的是语义丰富的压缩特征，而非原始数据，从而显著降低了通信开销和时延。我们证明了，与传统下采样方案相比，该方法效果更佳。

II. 系统与信号模型

系统模型。 N 单基地超宽带雷达节点部署在感兴趣区域周围，以便无论目标的位置和朝向如何，都能进行活动识别。雷达信号以正交方式传输，从而支持同时运行。每部雷达均以相同的脉冲重复间隔（PRI）发射脉冲，并与其他节点保持同步。雷达收集后向散射回波，其中包含来自不同视角的目标运动所产生的运动调制特征。雷达节点将数据转发至融合处理器，以执行识别任务。

信号模型。 超宽带信号通常组织为二维快时间 $\times$ 慢时间矩阵，其中快时间表示距离单元，慢时间则捕捉脉冲间变化，例如目标运动。令 $y[n,m]$ 表示该矩阵的第 (n,m) 个元素，对应于第 n个脉冲的第 m个快时间采样点。根据 [4], 第 m个发射脉冲，其载波角频率为 ω_c，可建模为：

$$x(t, mT) = p(t, mT)\,\sin(\omega_c t), \tag{1}$$

其中， $p(t,\ mT)$ 为短时脉冲， T 为 PRI。以快时间采样周期 T_s 采集的该采样点处接收回波表示为：

$$y[n,m] = \alpha(n,m)\,p(nT_s - t_D, mT)\,e^{j\omega_c t_D(n,m)}, \tag{2}$$

其中， $\alpha(n,\ m)$ 和 $t_D(n,\ m)$ 分别表示衰减因子和传播时延。这两个量均受目标的朝向、位置以及所执行活动类型的影响。

III. 提出的方法框架

本节概述所提出的端到端框架。我们首先描述输入结构，随后介绍由三个部分组成的模型架构：*(i)* 用于逐雷达特征提取的二维卷积神经网络模块，*(ii)* 用于建模节点间依赖关系并强调信息丰富节点的自注意力融合模块，以及*(iii)* 用于最终分类的全连接层。接着，我们介绍混合监督式对比学习目标，最后说明估计节点重要性的方法。

A. 模型输入表示

对于每个固定长度的慢时间窗口，复数样本将转换为极坐标形式 $\left(|y[n,m]|,\ \angle y[n,m]\right)$，并排列成一个三维张量，其各维分别对应距离单元（快时间） $\times$ 窗口长度（慢时间） $\times$ 2 （幅度/相位），使模型能够捕捉场景中的空间和时间变化。

B. 模型架构

特征提取模块。快速时间维度和慢速时间维度分别作为高度和宽度，极坐标表示作为通道维度。在每个雷达处采用三个二维卷积神经网络层，以捕获时空模式。每一层之后均接入批归一化（BN）和 ReLU 激活，以提高优化稳定性和非线性表示能力。添加一个 1×1卷积层，以增强通道级特征交互。最后，采用平均池化将深度和空间信息压缩为紧凑且具有判别性的表示，从而提升计算效率和实际可用性。

每个雷达节点都通过采用权重共享策略 [7] 的同一模块进行处理。这有助于降低模型复杂度并增强模型可扩展性。提取的特征首先被展平为大小为 d_{model} 的数组，然后在各节点间拼接，形成S 输出，其

形状 $N \times d_{\text{model}}$ 与自注意力输入兼容，并被传递至融合模块。

融合模块。每个雷达从不同的视角观测活动，具体取决于目标的位置和朝向，这会影响分辨率以及其获取的信息。将节点视为一个序列后，我们采用自注意力机制，在节点之间动态聚合信息，并为信息量更高的节点分配更大的权重。该机制的核心在于连接所有节点，使模型能够发现节点间隐藏的关系。这通过三个可学习的线性投影实现，将输入特征映射为查询（$\mathbf{Q}$）、键（$\mathbf{K}$）和值（$\mathbf{V}$）。通过这种方式，节点缺失的信息可以从其他节点获取，并从不同视角补全自身信息。借助注意力权重，每个节点都会关注能够提供最具互补信息的节点，并根据权重组合它们的值。在具有 H 个头的多头注意力中，不再使用单一的一组 $\mathbf{Q}$、$\mathbf{K}$、$\mathbf{V}$，而是每个头都维护自己的一组：

$$\mathbf{Q}_h = \mathbf{S}\mathbf{W}_h^Q, \quad \mathbf{K}_h = \mathbf{S}\mathbf{W}_h^K, \quad \mathbf{V}_h = \mathbf{S}\mathbf{W}_h^V. \tag{3}$$

每个头的注意力权重和输出如下：

$$\boldsymbol{\alpha}_h = \text{softmax}\left(\frac{\mathbf{Q}_h \mathbf{K}_h^\top}{\sqrt{d_k}}\right), \quad \mathbf{S}_h = \boldsymbol{\alpha}_h \mathbf{V}_h. \tag{4}$$

随后将所有头的输出拼接起来，并进行线性投影，以形成融合特征矩阵，$\mathbf{S}_a$。对所有头的注意力权重取平均，得到形状为 $N \times N$ 的矩阵，该矩阵表示整体节点间注意力，$\boldsymbol{\alpha}$。添加残差连接以促进梯度流动。将融合特征展平为数组 $\mathbf{s}_a$ ，以便为下一个模块做好准备。

分类器模块。分类器由两个全连接层组成，并使用一个 dropout 层来缓解过拟合。Softmax函数生成类别概率，最终输出 $\hat{}y$ 对应于预测概率最高的类别。

C. 学习与优化

受 [22], 启发，我们采用混合损失函数，以提升模型在不平衡分布下对细粒度活动类别的鲁棒性：

$$\min_{\theta_c, \theta_a, \theta_d} \mathcal{L}_{\text{hybrid}} = \mathcal{L}_{\text{CE}}(y, \hat{y}) + \gamma \cdot \mathcal{L}_{\text{SCL}}(y, \mathbf{s}_a), \tag{5}$$

其中， $\mathcal{L}_{\text{CE}}$ 是交叉熵损失， $\mathcal{L}_{\text{SC}}$ 是针对子空间$\mathbf{s}_a$的监督式对比损失，通过拉近同类嵌入并推远不同类嵌入来增强特征可分性。对于一个包含 B个样本的批次：

$$\mathcal{L}_{\text{SC}} = \frac{1}{B} \sum_{i=1}^{B} \frac{-1}{|\mathcal{P}(i)|} \sum_{j \in \mathcal{P}(i)} \log \frac{\exp(\mathbf{z}_i \cdot \mathbf{z}_j / \tau)}{\sum_{k \neq i} \exp(\mathbf{z}_i \cdot \mathbf{z}_k / \tau)}, \tag{6}$$

其中， $\mathcal{P}(i) = \{j \mid y_j = y_i, j \neq i\}$ 是与锚点 i 属于同一类别的正样本集合，$\mathbf{z}_i$ 是样本 i经过 L2 归一化后的嵌入表示，而 τ 是温度参数，用于控制分布的尖锐程度。分子 $\exp(\mathbf{z}_i \cdot \mathbf{z}_j/\tau)$ 促进类内聚合，而分母 $\sum_{k \neq i} \exp(\mathbf{z}_i \cdot \mathbf{z}_k/\tau)$ 则通过惩罚与负样本 [23] 的相似性来强化类间分离 。

D. 注意力权重与节点重要性

权重矩阵 $\boldsymbol{\alpha}$ 编码了节点两两交互[20], [21]。每一行 $\boldsymbol{\alpha}_{i,:}$表示节点 i 分配给其他节点的注意力权重概率分布，而每一列$\boldsymbol{\alpha}_{:,j}$则量化节点 j接收到的总注意力，可作为其重要性或注意力中心性的衡量指标。节点 j 的全局重要性定义为：

$$I(j) = \sum_{i=1}^{N} \boldsymbol{\alpha}_{i,j}. \tag{7}$$

较高的 $I(j)$ 表示该节点对模型决策有更大的影响力，这一概念用于可解释性分析 [21], [24]。

IV. 实验与结果

本节评估所提出的架构。首先概述数据集和实现细节，包括网络参数和训练参数。随后将模型性能与基线进行比较，并展示 t-SNE 可视化结果，以及针对节点归因可解释性的消融实验。最后，我们考察模型的压缩能力及其在实时部署中的应用。

数据集描述。我们使用来自 [25],的公开数据集，其中包含 14 名参与者在不同地点和朝向下完成的九种人体活动，数据由五部超宽带雷达采集，每部雷达包含 480 个快时间采样点。该数据集存在类别不平衡和活动相似性，活动分布如下：1）行走 29.7%，2）静止站立 14.8%，3）坐下 5.1%，4）从坐姿站起 4.7%，5）从坐姿弯腰 11.8%，6）从站姿弯腰 12.9%，7）行走时跌倒 3.3%，8）从地面站起 11.6%，以及 9）站立时跌倒 5.3%。

训练与网络参数。评估了不同的输入窗口大小，结果显示窗口长度为 30 时效果最佳，最终输入形状为 $480 \times 30 \times 2$。模型参数详见表 I。

表 I：网络架构

模块	层结构
特征提取	二维卷积 6，卷积核 (7,3)，填充 (3,1)，批归一化，ReLU 二维卷积 8，卷积核 (3,3)，填充 1，批归一化，ReLU 二维卷积 6，卷积核 (3,3)，填充 1，批归一化，ReLU 二维卷积 6 ，卷积核 1 自适应平均池化 (5,4)
融合	多头注意力 4 个头， $d_k = d_v = 24$ 残差连接
分类器	全连接层 64，ReLU 随机失活率=0.3 全连接层 9

使用 Adam优化器进行训练，学习率为 3×10^{-3} ，最多训练 100 个训练轮次。为防止过拟合，采用耐心值为 10 个训练轮次的早停策略。如果连续 10 个训练轮次的损失没有改善，则将学习率减半。参数 γ 和 τ 分别设为 1 和 0.5，

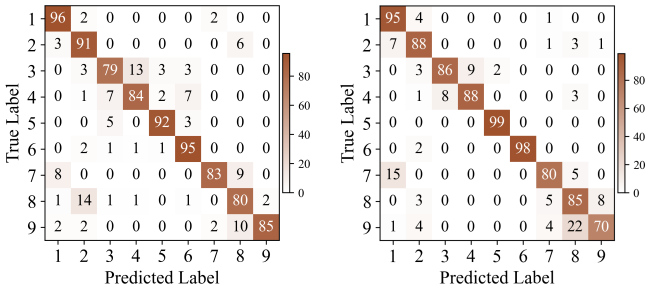


图2：所提模型 (a) 和基线 CNN-RNN (b) 的混淆矩阵（百分比） [7]。

表 II：与基线模型的性能比较

模型	最高测试结果	平均测试结果	输入类型	参数
CNN-RNN [7]	90.8%	85.1%	多普勒频谱	72K
所提出的方法	92.53%	88.54%	原始数据	21K

这些设置基于经验观察得出。采用留一人交叉验证（LOPO）进行评估，并按 4:1 划分训练集和验证集，每次留出一名参与者作为未见测试数据。为缓解纳入所有参与者时的类别不平衡问题，使用加性高斯噪声（尺度 = 0.1）进行数据增强。

A. 系统性能基准测试

我们将所提出的框架与 [7] 中介绍的 CNN–RNN模型进行了比较。如混淆矩阵（图2）所示，对于样本分布较大的类别，两个模型都取得了较高的准确率。我们的模型在若干类别（如 1、2、7 和 9）上表现更好，而基线模型在其他类别（如 3、4、5、6 和 8）上表现更好。值得注意的是，对于具有相反运动的类别（如 3 与 4、8 与 9），两个模型都出现了最多的相互误分类。总体而言，所提出的框架呈现出更有利的性能趋势。表 II 报告的结果显示，最大和平均测试准确率均有所提高。值得注意的是，所提出的方法降低了模型复杂度，并消除了耗费大量资源的预处理。由于数据集更大且采用了混合优化，训练需要更多资源，但这种开销仅限于离线训练。相比之下，对部署至关重要的推理延迟显著降低：我们的模型规模缩小了 3.4× 倍，在同一台英特尔第11代酷睿i5-11400H处理器上，每个样本的处理时间为 0.013 秒，而基线模型为 0.049 秒。

B. 特征嵌入可视化

我们使用t分布随机邻域嵌入（t-SNE）来可视化特征嵌入。如图3所示，图（a）显示原始输入数据中的类别存在大量重叠；图（b）展示融合特征空间中清晰的类别分离，凸显了有效的特征判别。在图（c）中，分类器输出形成了与各个类别相对应的清晰簇。与图2（a）一致，在t-SNE空间中类别分离度的提升（即重叠减少）对应于混淆矩阵中更高的分类准确率。对于存在重叠运动的类别（例如7和

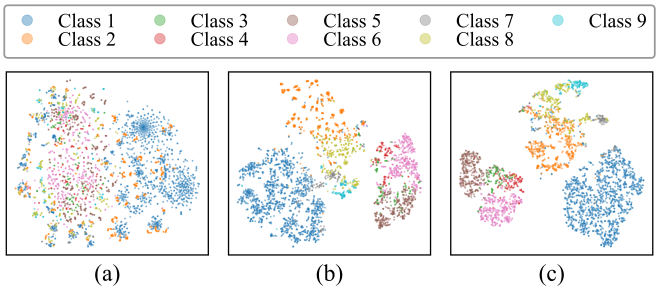


图 3：对 (a) 原始输入特征、(b) 融合特征进行 t-SNE 可视化表示，以及（c）最终全连接层的输出。

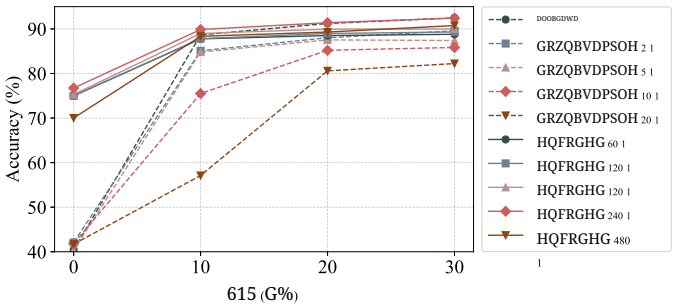


图4：在不同信噪比条件下，对比基于编码器的特征压缩与传统下采样方法。

9），更精细的分割可以进一步提高各类别准确率和总体准确率。

C. 数据通信开销

在实际部署中，信道噪声、时延和带宽受限等通信瓶颈可能会显著降低推理性能。为此，每个雷达节点传输由轻量级二维卷积神经网络模块提取的紧凑特征，而不是原始测量数据。我们将这种基于编码器的压缩方案与传统下采样方法进行对比评估。通道深度固定为6时，大小为（5×2）、（5×4）、（5×8）、（10×4）和（10×8）的特征图分别对应压缩因子 480×、 240×、 120×、 120×和 60×。作为对比，我们评估了 2×、 5×、 10×和 20× 的快时间下采样比例。如图4所示，得益于其提取抗噪特征的能力，基于编码器的传输实现了显著更高的压缩率，并且对信道噪声具有明显更好的鲁棒性。其中，（5×4）特征图表现最佳。此外，在不进行额外降维（例如主成分分析）的情况下，将部分推理过程置于本地执行，可以降低总体时延。

D. 消融实验与节点重要性

我们进行了消融实验，系统地移除部分输入，以评估模型对这些输入的依赖程度。根据注意力权重计算出的重要性（第 III-D 节），将各个节点的数据消融为零值或随机数据。如图 5 所示，消融重要性较高的节点会导致预测准确率大幅下降。条形图展示了重要性最高的雷达的分布，这表明

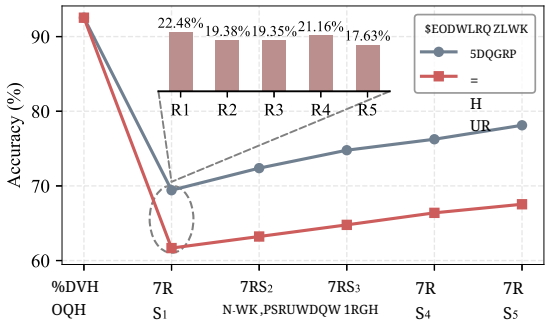


图5：节点重要性的消融实验，条形图展示了各雷达中最重要节点的分布。

模型会自适应地优先利用来自所有来源的信息。这种节点级归因对于防止训练过程中的过拟合或偏差，并确保模型在在线阶段（例如雷达发生故障，或雷达朝向或位置发生变化时）正常运行至关重要。

V. 结论

我们提出了一种基于分布式雷达进行连续活动识别的端到端框架，可直接处理原始数据，从而省去开销高昂的离散傅里叶变换预处理。轻量级二维卷积神经网络在每个雷达节点本地提取紧凑的语义特征，降低了向融合处理器传输数据所产生的通信开销。基于多头注意力的中间融合提升了模型对目标位置和朝向变化的鲁棒性，同时提供了可解释的节点级重要性。与基线方法相比，所提出的方法在模型复杂度更低的情况下取得了更高的准确率。消融研究验证了各个架构组件的作用。所提出的特征压缩策略优于传统下采样，表明其适用于实际的低时延分布式雷达感知。

致谢

作者感谢达姆施塔特工业大学提供的 Lichtenberg II 高性能计算机算力资源。该资源由德国联邦教育与研究部（BMBF）和黑森州资助。

参考文献

[1] J. Liu, H. Liu, Y. Chen, Y. Wang, 和 C. Wang, 《用于人体活动的无线感知：综述》，*IEEE*《通信调查与教程》，第22卷，第3期，第1629–1645页，2019年。[2] J. Zhang, R. Xi, Y. He, Y. Sun, X. Guo, W. Wang, X. Na, Y. Liu, Z. Shi, 和 T. Gu, 《基于毫米波的人体感知综述：技术、平台与应用》，*IEEE*《通信调查与教程》，第25卷，第4期，第2052–2087页，2023年。[3] R. Zhang, X. Jing, S. Wu, C. Jiang, J. Mu, 和 F. R. Yu, 《用于人体检测的无设备无线感知：深度学习视角》，*IEEE*《物联网期刊》，第8卷，第4期，第2517–2539页，2020年。[4] L. Ren, Y. S. Koo, Y. Wang, 和 A. E. Fathy, 《使用超宽带脉冲多普勒雷达进行非接触式心跳检测》，载于*2015*年*IEEE*生物医学无线技术、网络与传感系统专题会议（*BioWireleSS*）。IEEE，2015年，第1–3页。[5] S. Waqar, M. Muaaz, 和 M. P¨atzold, 《使用分布式多输入多输出雷达系统和深度学习进行与方向无关的人类活动识别》，*IEEE*《传感器期刊》，第23卷，24 929，2023 20，24 916 no. pp. – 。

[6] N. C. Kruse, F. Fioranelli, 和 A. Yarovoy, 《利用雷达点云和点云Transformer网络进行连续人体活动分类》，载于2023年第20届欧洲雷达会议（EuRAD）。IEEE，2023年，第302–305页。[7] S. Zhu, R. G. Guendel, A. Yarovoy, 和 F. Fioranelli, 《利用分布式雷达传感器网络和CNN–RNN架构进行连续人体活动识别》，IEEE地球科学与遥感汇刊，第60卷，第1–15页，2022年。[8] R. G. Guendel, M. Unterhorst, E. Gambi, F. Fioranelli, 和 A. Yarovoy, 《利用分布式雷达识别任意方向上的连续人体活动》，载于2021年IEEE雷达会议（RadarConf21）。IEEE，2021年，第1–6页。[9] Y. Zhao, R. G. Guendel, A. Yarovoy, 和 F. Fioranelli, 《利用视觉Transformer和卷积神经网络进行基于分布式雷达的人类活动识别》，载于2021年第18届欧洲雷达会议（EuRAD）。IEEE，2022年，第301–304页。[10] R. G. Guendel, N. C. Kruse, F. Fioranelli, 和 A. Yarovoy, 《利用多径进行基于雷达网络的人类活动识别》，IEEE地球科学与遥感汇刊，第62卷，13，2024 1pp. – 。[11] S. Rani, A. Chowdhury, A. Gigie, T. Chakravarty, 和 A. Pal, 《通过微多普勒特征，利用空间分布式雷达设置进行动作识别》，载于2020年ACM普适与泛在计算国际联合会议及2020年ACM可穿戴计算国际研讨会附属论文集，2020年，第278–253页。[12] R. G. Guendel, F. Fioranelli, 和 A. Yarovoy, 《用于连续人体活动分类的分布式雷达融合与循环网络》，IET雷达、声呐与导航，第16卷，第7期，第1144–1161页，2022年。[13] P. Zheng, A. Zhang, J. Chen, J. Zhang, 和 F. Qi, 《利用分布式雷达传感器系统及带双视图注意力的混合神经网络进行与方向无关的人体行为识别》，IEEE《传感器期刊》，2024年。[14] N. C. Kruse, F. Fioranelli, 和 A. Yarovoy, 《利用点云Transformer网络进行人体活动分类的雷达点云处理方法》，IEEE雷达系统汇刊，第2卷，第1–12页，2023年。[15] Y. Liu, F. Wang, N. Wang, 和 Z.-X. Zhang, 《点之外的回波：释放原始雷达数据在多模态融合中的潜力》，神经信息处理系统进展，第36卷，53 982，2023 53 964pp. – 。[16] Y. Zhang, Y. Zheng, K. Qian, G. Zhang, Y. Liu, C. Wu, 和 Z. Yang, 《Widar3.0：利用Wi-Fi实现零投入跨域手势识别》，IEEE模式分析与机器智能汇刊，第44卷，第11期，第8671–8688页，2021年。[17] A. Dey, S. Rajan, G. Xiao, 和 J. Lu, 《利用多域多层融合补丁学习进行基于雷达的人类活动识别》，IEEE仪器与测量汇刊，第73卷，第1–14页，2024年。[18] C. Eckrich, A. M. Zoubir, 和 V. Jamali, 《前传受限的分布式雷达感知》，arXiv预印本 arXiv:2409.17753，2024年。[19] L. Qu, X. Li, T. Yang, 和 S. Wang, 《利用多域融合视觉Transformer进行基于雷达的连续人体活动识别》，IEEE《传感器期刊》，2025年。[20] P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lio, Y. Bengio 等, 《图注意力网络》，stat，第1050卷，48 550，2017 20，10no. pp. – 。[21] L. Hu, X. Wang, Y. Liu, N. Liu, M. Huai, L. Sun, 和 D. Wang, 《迈向稳定且可解释的注意力机制》，IEEE知识与数据工程汇刊，2025年。[22] P. Wang, K. Han, X.-S. Wei, L. Zhang, 和 L. Wang, 《基于对比学习的混合网络用于长尾图像分类》，载于IEEE/CVF计算机视觉与模式识别会议论文集，2021年，第943–952页。[23] P. Khosla, P. Teterwak, C. Wang, A. Sarna, Y. Tian, P. Isola, A. Maschinot, C. Liu, 和 D. Krishnan, 《监督式对比学习》，神经信息处理系统进展，第33卷，第18 661–18 673页，2020年。[24] Z. Ying, D. Bourgeois, J. You, M. Zitnik, 和 J. Leskovec, 《Gnnexplainer：为图神经网络生成解释》，神经信息处理系统进展，第32卷，2019年。[25] R. Guendel, M. Unterhorst, E. Gambi, F. Fioranelli, 和 A. Yarovoy, 《使用由五个节点组成的分布式雷达网络采集的任意方向连续人体活动数据集》，2021年，4TU.ResearchData。 [在线]。可通过以下网址访问：https://doi.org/10.4121/ 16691500.v1