

多天线 Wi-Fi 基于人类活动识别的 DOPPLER 辐射场引导天线选择以提高泛化能力

Navid Hasanzadeh¹ and Shahrokh Valaee¹, Fellow, IEEE

¹Department of Electrical & Computer Engineering, University of Toronto, Toronto, ON, Canada

navid.hasanzadeh@mail.utoronto.ca, valaee@ece.utoronto.ca.

ABSTRACT

随着 IEEE 802.11bf 任务组对 WLAN 标准进行高级传感方面的修订, 使用 Wi-Fi 信道状态信息 (CSI) 进行远程传感的兴趣激增。最近的研究表明, 通过从 CSI 导出的多普勒辐射场 (DoRFs) 学习统一的三维运动表示显著提高了基于 Wi-Fi 的人体活动识别 (HAR) 的泛化能力。尽管有这些进展, CSI 信号仍然受到不同步接入点 (AP) 时钟和来自环境及硬件来源的加性噪声的影响。因此, 即使使用现有的预处理技术, 用于 DoRFs 的 CSI 数据和多普勒速度投影仍容易受到噪声和异常值的影响, 限制了 HAR 性能。为了解决这一挑战, 我们提出了一种针对多天线 AP 的新框架来抑制噪声并基于 DoRF 拟合误差识别最具信息量的天线, 这些误差捕捉到多普勒速度投影之间的一致性。在一个具有挑战性的小型手部手势识别数据集上的实验结果表明, 所提出的基于 DoRF 引导的 Wi-Fi 人体活动识别方法显著提高了泛化能力, 为稳健的实际传感部署铺平了道路。

Index Terms— 人类活动识别, Wi-Fi 感应, 多普勒辐射场, 信道状态信息

1. 介绍

Wi-Fi 感应正迅速迈向日常使用, 这得益于 IEEE802.11bf 了如 DoRF 之类方法的一般化能力。这些噪声源以高度修正案, 该修正案定义了 WLAN 感应的标准协议, 并开放了对低于 7GHz [1] 频段的无许可证访问。通过利用现有的 Wi-Fi 基础设施, 消除穿戴设备的需求, 并缓解与摄像头相关的隐私问题, Wi-Fi 感应为传统的感应方法提供了一种实用且易于访问的替代方案 [2]。在不久的将来, 家中的、学校的、医院的和工作场所的 Wi-Fi 设备可以无缝执行人类活动识别 (HAR), 革新医疗保健、智能环境和沉浸式数字体验。

基于 Wi-Fi 的 HAR 通过分析由反射和散射引起的信道状态信息 (CSI) 变化来追踪运动 [3, 4]。虽然先前的

研究要么使用 CSI 幅度要么是相位 [5, 6, 7, 8, 9] 与机器学习技术相结合, 但这些方法仅在静态环境中表现出可靠的性能。它们对环境变化的敏感性导致了有限的准确性和较差的泛化能力, 尤其是在未见过的用户或位置上 [10]。

最近的方法从 Wi-Fi CSI 中提取多普勒速度以捕捉运动引起的频率偏移, 同时抑制静态成分 [11, 12]。MORIC [13] 扩展了这一想法, 通过将多普勒投影建模为球面上虚拟相机的视角, 每个相机通过冯·米塞斯-费舍尔分布总结多径效应。这种结构化的表示提高了泛化能力, 但仍受限于随机和不完整的视角。受机器视觉中神经辐射场 (NeRFs) [14] 的启发, 多普勒辐射场 (DoRFs) [15] 通过从一维多普勒投影重建运动的统一三维潜在表示来解决这个问题。DoRF 将分散的视角整合到一个连贯的整体模型中, 模拟所有视角下的观测结果, 并使未见过的用户和环境具有更强的泛化能力。

尽管 DoRF 取得了进展, CSI 信号中的噪声仍可能在多普勒投影及由此产生的 DoRF 中引入虚假变化, 导致机器学习模型在 HAR 中错误分类活动, 尤其是在活动非常相似的情况下。事实上, 即使是动作方面的轻微误导也可能显著降低手部手势识别等细粒度任务的性能。因此, 与计算机视觉中的 NeRF 不同, 在用于三维重建的图像通常噪声较低的情况下, CSI 数据中的高噪声水平严重限制

非线性的方式扭曲 CSI 相位, 产生由多径干扰、本地振荡器漂移和无线网络接入点 (AP) 单个 Wi-Fi 天线的锁相环 (PLL) 不完美引起的突然相位偏移和尖峰。因此, 传统的信号处理方法往往无法有效检测和抑制这些伪影。即使像 CSI 比率模型 [16] 这样先进的技术, 尝试在 Wi-Fi 接入点 (AP) 中的天线对之间消除共通噪声, 也未能成功, 因为某些噪声模式仅在一个天线上出现而不在其他天线上。

本工作通过使用 DoRF 本身来优化运动表示, 从而减轻了 CSI 噪声对基于 DoRF 的 Wi-Fi 活动识别的影响。在第一阶段, 独立地在每个 AP 上训练一个 DoRF 模型,

并动态识别并丢弃具有高拟合误差的天线作为噪声源，使选择过程能够自动适应不同的噪声水平和环境条件。在第二阶段，在剩余的天线上训练 DoRF 模型，并使用它们的运动表示进行活动分类。实验结果表明，所提出的基于两阶段 DoRF 的活动识别方法产生的运动表示更能抵抗噪声，并显著提高了对未见用户的泛化能力，在具有挑战性的细粒度人体手势识别方面超过了现有方法。

2. 多普勒辐射场

本节总结了从 Wi-Fi CSI 导出多普勒投影的过程及其在构建 DoRFs 作为人类运动的紧凑信息表示中的应用。

对于一个具有 N 正交频分复用 (OFDM) 子载波的 Wi-Fi 系统，这些子载波以 Δf 的间隔围绕中心载波频率 f_c ，在子载波 n 和时间 s 处的信道响应被建模为

$$H_n(s) = \sum_{l=0}^{L-1} \beta_l(s) e^{-j2\pi \left(f_c - (n - \frac{N}{2})\Delta f\right) \tau_l(s)}, \quad (1)$$

其中 $H_n(s)$ 是复数 CSI， $\beta_l(s)$ 和 $\tau_l(s)$ 表示第 l 个多径分量的幅度和延迟，而 L 是路径总数。延迟谱是通过在子载波上应用一个 N 点逆离散傅里叶变换 (IDFT) 获得的：

$$h(s, \tau) = \frac{1}{N} \sum_{n=0}^{N-1} H_n(s) e^{j2\pi n \Delta f \tau}. \quad (2)$$

这种转换将 CSI 分解为延迟 $\text{bins} \tau_i = i/(N\Delta f)$ ，其中相位对齐会在每个 τ_i 处引起能量的建设性叠加，从而隔离出各个多径分量的贡献。人体运动通过向第 i 条路径引入额外的延迟来扰动信道：

$$\Delta \tau_i = \frac{\mathbf{v}(s)^\top \mathbf{m}_i}{c} t, \quad (3)$$

其中 $\mathbf{m}_i \in \mathbb{R}^3$ 是相对于移动目标该路径的平均到达方向， $\mathbf{v}(s)$ 是在 s 附近短暂时间段内的三维速度矢量， c 是电磁波的传播速度， t 是运动过程中经过的时间。因此，通道响应在 τ_i 处经历了一个与时 $\mathbf{v}(s)^\top \mathbf{m}_i$ 成比例的时变相移，将每个 $\mathbf{m}_i$ 视为类似一维相机从不同角度捕捉运动投影的虚拟观测点。

延迟 $\text{bin} \tau_i$ 的功率谱密度 (PSD) 是通过对它的自相关性进行傅里叶变换获得的：

$$S(f; \tau_i) = \int_{-\infty}^{\infty} \mathbb{E}[h^*(s; \tau_i) h(s+t; \tau_i)] e^{-j2\pi f t} dt. \quad (4)$$

该频谱在多普勒偏移 $f^* = \mathbf{v}(s)^\top \mathbf{m}_i / \lambda$ 处达到峰值，波长为 $\lambda = c/f_c$ ，给出径向速度

$$v_r(s; \tau_i) = \mathbf{v}(s)^\top \mathbf{m}_i. \quad (5)$$

收集所有径向速度得到多普勒场

$$\mathcal{V}_r(s) = \{v_r(s; \tau_i)\}_{i=0}^{N-1},$$

这代表了真实速度的多视角投影。令 $\mathbf{V}_r \in \mathbb{R}^{T \times N}$ 为在 T 时间实例中编译这些多普勒速度的矩阵，其条目为 $V_r(s, i) = v_r(s; \tau_i)$ 。速度 $\mathbf{v}(s) \in \mathbb{R}^3$ 作为场景内集体质心运动的近似值。每个投影满足

$$v_r(s; \tau_i) = \mathbf{v}(s)^\top \mathbf{r}_i + n(s, i),$$

其中 $\mathbf{r}_i \in \mathbb{S}^2$ 是一个未识别的方向单位向量，而 $n(s, i)$ 则考虑了观测噪声。矩阵形式下，这变为 $\mathbf{V}_r = \mathbf{V} \mathbf{R}^\top + \mathbf{N}$ ，其中 $\mathbf{V} \in \mathbb{R}^{T \times 3}$ 包含速度， $\mathbf{R} \in \mathbb{R}^{N \times 3}$ 包含方向，而 $\mathbf{N}$ 是噪声矩阵。

$\mathbf{V}$ 和 $\mathbf{R}$ 的推理被表述为一个正则化优化问题：

$$\begin{aligned} \min_{\mathbf{V}, \mathbf{R}} \quad & \frac{1}{2} \sum_{s=0}^{T-1} \sum_{i=0}^{N-1} [\mathbf{V}_r(s, i) - \mathbf{v}(s)^\top \mathbf{r}_i]^2 \\ & + \mu \sum_{s=0}^{T-1} \|\mathbf{v}(s)\|^2 + \gamma \sum_{i=0}^{N-1} \|\mathbf{r}_i\|^2 \\ \text{subject to} \quad & \|\mathbf{r}_i\| = 1, \quad i = 0, \dots, N-1. \end{aligned} \quad (6)$$

这里， μ 和 γ 对速度和方向的过度幅度进行惩罚，以减轻过拟合并增强数值稳定性。这个非凸问题通过算法 1 中详细描述交替最小化方案来解决。

虽然恢复的速度序列 $\mathbf{V}$ 提供了运动的紧凑摘要，但它仍然依赖于帧，并且缺乏均匀的方向覆盖。为了获得视点不变性，速度被重新投影到球面上大约均匀分布的一组单位向量上。设 $\{\mathbf{d}_k\}_{k=1}^K \subset \mathbb{S}^2$ 表示这些方向。沿着 $\mathbf{d}_k$ 的径向分量是

$$\mathbf{P}(s, k) = \mathbf{v}(s)^\top \mathbf{d}_k, \quad k = 1, \dots, K,$$

其构成了 DoRF 矩阵 $\mathbf{P} \in \mathbb{R}^{T \times K}$ 。在 $\{\mathbf{d}_k\}$ 上的投影聚合产生了一个有序且鲁棒的运动描述符，适用于下游的行为识别模型。

3. 方法

本节描述了 CSI 相位预处理以及一个两阶段程序，该程序利用 DoRF 收敛行为自动选择可靠的天线来减轻 CSI 噪声对基于 DoRF 的 Wi-Fi 人体活动识别的影响。

3.1. CSI 预处理

硬件缺陷，如采样频率和符号定时偏移 (SFO、STO)，会在原始 CSI 中引入线性相位误差，从而降低活动识别




Fig. 1: 图表总结了提出的基于 Wi-Fi 的 HAR 框架。CSI 被转换为多普勒速度投影，这些投影驱动 DoRF 引导的天线选择，仅保留具有一致表示的天线。选定的投影形成 DoRFs，并进行均匀采样以获得多视图表示。然后特征提取器和分类器识别活动。

的性能。在本工作中，借鉴 [17]，通过跨子载波解缠并减去拟合的线性趋势来消除主要硬件偏差模型下的相位。然后使用清理后的 CSI 进行延迟-多普勒变换、DoRF 构建和天线选择。

3.2. DoRF-指导的天线选择

令 APs 的索引为 $q \in \{1, \dots, Q\}$ 。AP q 具有天线 $\mathcal{A}_q = \{1, \dots, M_q\}$ 和多普勒投影 $\mathbf{V}_r^{(q)} \in \mathbb{R}^{T \times N_q}$ 。 $\mathbf{V}_r^{(q)}$ 的列（延迟箱/路径）通过已知映射 $g_q: \{1, \dots, N_q\} \rightarrow \mathcal{A}_q$ 与天线关联。应用算法 1 到每个 AP 得出 $\mathbf{V}^{(q)} \in \mathbb{R}^{T \times 3}, \mathbf{R}^{(q)} \in$

Algorithm 1 DoRF 构造的交替优化

Require: 多普勒投影 $\mathbf{V}_r \in \mathbb{R}^{T \times N}$ ，容差 ϵ ，正则化项

μ, γ, λ

1: 初始化 $\mathbf{R} = [\mathbf{r}_1, \dots, \mathbf{r}_N] \in \mathbb{R}^{3 \times N}$ 为单位列

2: repeat

3: **速度更新:**

$$\mathbf{V} \leftarrow \mathbf{V}_r \mathbf{R}^\top (\mathbf{R} \mathbf{R}^\top + \lambda \mathbf{I}_3)^{-1} \in \mathbb{R}^{T \times 3}$$

4: **方向更新:**

$$\begin{aligned} \tilde{\mathbf{R}} &\leftarrow (\mathbf{V}^\top \mathbf{V} + \gamma \mathbf{I}_3)^{-1} \mathbf{V}^\top \mathbf{V}_r \in \mathbb{R}^{3 \times N} \\ \mathbf{r}_i &\leftarrow \tilde{\mathbf{r}}_i / \|\tilde{\mathbf{r}}_i\| \quad \forall i \end{aligned}$$

5: **预测:**

$$\hat{\mathbf{V}}_r \leftarrow \mathbf{V} \mathbf{R}$$

6: **损失:**

$$\mathcal{L} = \frac{1}{TN} \|\hat{\mathbf{V}}_r - \mathbf{V}_r\|_F^2 + \frac{\mu}{T} \|\mathbf{V}\|_F^2 + \frac{\gamma}{N} \|\mathbf{R}\|_F^2$$

7: until $\mathcal{L} < \epsilon$ or maximum iterations

8: **DoRF 构造:** 令 $\mathbf{D} \in \mathbb{R}^{3 \times K}$ 是单位球面上的均匀网格; 计算

$$\mathbf{P} \leftarrow \mathbf{V} \mathbf{D} \in \mathbb{R}^{T \times K}$$

9: return $\mathbf{P} \in \mathbb{R}^{T \times K}$, $\mathbf{V} \in \mathbb{R}^{T \times 3}$, $\mathbf{R} \in \mathbb{R}^{3 \times N}$

$\mathbb{R}^{3 \times N_q}$ 和 $\hat{\mathbf{V}}_r^{(q)} = \mathbf{V}^{(q)} \mathbf{R}^{(q)}$ 。对于索引集为 $\mathcal{I}_{q,a} = \{i : g_q(i) = a\}$ 的天线 $a \in \mathcal{A}_q$ ，定义每个天线的归一化 DoRF 收敛误差

$$\mathcal{E}_{q,a} = \frac{\sum_{i \in \mathcal{I}_{q,a}} \|\mathbf{V}_r^{(q)}(:, i) - \mathbf{V}^{(q)} \mathbf{r}_i^{(q)}\|_2^2}{\sum_{i \in \mathcal{I}_{q,a}} \|\mathbf{V}_r^{(q)}(:, i)\|_2^2 + \delta}, \quad \delta > 0, \quad (7)$$

，其中 $\mathbf{r}_i^{(q)}$ 是 $\mathbf{R}^{(q)}$ 的第 i 列。将所有 AP 的天线误差收集到 $\{\mathcal{E}_{q,a}\}$ 中，总数为 $M_Q = \sum_q M_q$ 。按非递减顺序排列它们得到 $\tilde{e}_{(1)} \leq \dots \leq \tilde{e}_{(M_Q)}$ 。一个膝点指数 k^* 是通过最远点（三角形）方法在 $(i, \tilde{e}_{(i)})$ 上找到的：设 $A = (1, \tilde{e}_{(1)})$ ， $B = (M_Q, \tilde{e}_{(M_Q)})$ ， $u = B - A$ 。 $X_i = (i, \tilde{e}_{(i)})$ 到直线 AB 的垂直距离是

$$d_i = \frac{|u_x(\tilde{e}_{(i)} - \tilde{e}_{(1)}) - u_y(i - 1)|}{\sqrt{u_x^2 + u_y^2}}, \quad u = (u_x, u_y), \quad (8)$$

和 $k^* = \arg \max_i d_i$ 。全局选择的天线集是

$$\mathcal{S} = \{(q, a) : \mathcal{E}_{q,a} \leq \tilde{e}_{(k^*)}\}, \quad (9)$$

这适应变化的噪声水平和环境条件，而无需每个 AP 的阈值。

3.3. 每天线 DoRF 拟合和活动分类

结构化的 DoRF $\mathbf{P} \in \mathbb{R}^{T \times M \times 2M}$ ，通过均匀球形采样 ($2M^2$ 个方向) 获得，作为 MORIC [13] 的输入。每个方向上的多普勒投影都由一个特征提取器独立编码，该提取器应用随机卷积核后进行时间池化，生成向量 $\mathbf{f}_{s,i} \in \mathbb{R}^d$ 用于 $i = 1, \dots, 2M^2$ 。由于拟合 DoRF 球体上的多普勒方向可能在顺序和旋转上有所不同，MORIC 通过沿投影轴应用逐元素最大池化来实现不变性，

$$\mathbf{f}_s = \max_{i=1, \dots, 2M^2} \mathbf{f}_{s,i}.$$

。

MORIC 然后将汇集的特征向量通过具有非线性激活函数的浅层全连接层，生成活动类别概率。




Fig. 2: UTHAMO 数据集中六名参与者执行的四种手势的示例。

4. 实验

4.1. 数据

UTHAMO 数据集 [18] 用于评估该方法。六名参与者执行了四种手势——圆、左右、上下和推—拉，如图 2 所示。数据是在一个静止的室内办公室 ($6\text{m} \times 5.6\text{m}$) 收集的；楼层平面图见图 4。CSI 记录于 2.4 GHz，使用 Nexmon 工具包 [19]，在一个 Raspberry Pi 发射器和五个 ASUS RT-AC86U Wi-Fi 路由器（每个有三个天线）之间，这些路由器围绕用户放置，从而产生每个天线 64 个子载波。每个手势包含 20 次试验，每次持续 5s，采样频率为 100 Hz。

Algorithm 2 DoRF-指导的天线选择与重拟合

Require: 每个 AP q : 多普勒投影 $\mathbf{V}_r^{(q)}$, 映射 g_q ; 小 $\delta > 0$

- 1: **阶段 1: 全局天线选择**
 - 2: (a) **每 AP 的 DoRF 拟合:** 对每个 q , 运行算法 1 在 $\mathbf{V}_r^{(q)}$ 上以获得 $\mathbf{V}^{(q)}$, $\mathbf{R}^{(q)}$ 和 $\hat{\mathbf{V}}_r^{(q)} = \mathbf{V}^{(q)}\mathbf{R}^{(q)}$.
 - 3: (b) **每天线误差:** 对每个天线 $a \in \mathcal{A}_q$, 通过 (7) 计算 $\mathcal{E}_{q,a}$.
 - 4: (c) **跨所有接入点池化和排序:** 形成多重集 $\{\mathcal{E}_{q,a}\}$, 排序以获得 $\tilde{e}_{(i)}$, 通过 (8) 计算距离 d_i .
 - 5: (d) **膝点阈值与选择:** 设 $\tau = \tilde{e}_{(k^*)}$, 集合 $\mathcal{S} = \{(q, a) : \mathcal{E}_{q,a} \leq \tau\}$.
 - 6: **阶段 2: 按天线 DoRF 重新拟合 (在选定的天线上)**
 - 7: (e) **重新拟合 DoRFs:** 对每个 $(q, a) \in \mathcal{S}$, 在 $\mathbf{V}_r^{(q)}(:, \mathcal{I}_{q,a})$ 上运行算法 1 以获得每根天线的 $\text{DoRF}\mathbf{P}^{(q,a)} \in \mathbb{R}^{T \times K}$.
 - 8: (f) **导出特征:** 存储或聚合 $\{\mathbf{P}^{(q,a)}\}_{(q,a) \in \mathcal{S}}$ 以供下游分类.
 - 9: return 选定集 $\mathcal{S}$ 和每根天线的 DoRFs $\{\mathbf{P}^{(q,a)}\}$.
-

4.2. 训练和测试程序

默认的超参数来自 [13], 用于 MORIC 架构。它采用了 $K = 2$ 个注意力头, $D = 1,000$ 个随机核, 隐藏大小为 256, 以及减少的特征维度 $D' = 128$ 。训练使用了 AdamW 优化器 [20] (学习率 1×10^{-4} , 批量大小 64), 采用交叉熵损失和标签平滑 $\alpha = 0.1$ 。最多使用了 2,500 个周期, 在验证集上连续 200 个周期没有改进则提前停止。DoRF 按照每根天线构建, 并合并形成 MORIC 输入, 使用统一网格 $M = 8$ 和交替优化中的提前停止阈值 $\varepsilon = 0.01$ 。泛化能力通过留一验证 (LOSO) 交叉验证进行评估, 选择验证损失最低的模型进行最终评估。被丢弃天线的 DoRF 用零向量替换以保持输入大小一致。

4.3. 结果

表 1 概述了在 UTHAMO 数据集上对四个类别 HAR 的未见用户泛化情况。仅幅度 CSI 基线 AMAP 和 CMAP 表现接近随机水平, 而多普勒和相位感知方法如 CapsHAR 和 CSI Ratio 只提供了从 33.7% 到 36.1% 的小幅提升。MORIC 使用多普勒速度投影将平均准确率提高到 56.3%, 而 DoRF 的构建将其进一步提高到 58.9%。提出的 DoRF 引导天线选择后进行 DoRF 再拟合具有 $65.3\% \pm 8.3\%$ 的准确率, 优于所有最先进的方法, 证明了其在保留产生可靠和一致运动信息的天线方面的有效性。

图 3 展示了在 UTHAMO 设置中天线和接入点之间的平均 DoRF 拟合误差。AP5 和 AP4 表现出最低的误差, 并捕捉到更一致的多普勒投影。其余的接入点具有较高的误差, 表明噪声更大。这种模式反映了部署几何结构, 因为手势是在 AP5 和 AP4 的视线范围内进行的, 这些视线对准了 Raspberry Pi 发射器, 而其他接入点没有与用户的动作发生交叉。这些结果突显了所提出的方法能够自适应




Fig. 3: 每个天线的 Per-AP DoRF 拟合误差, 所有样本的平均值。




Fig. 4: UTHAMO 数据收集设置的平面图。

应地忽略捕捉到较少运动相关信息的接入点贡献的潜力。

5. 结论

本工作介绍了一种新颖的基于 DoRF 引导的 Wi-Fi 人体活动识别框架，适用于具有多天线的接入点，旨在解决小规模手势识别这一挑战性任务，在此任务中，运动信号微弱且极易受噪声影响。该方法利用每个天线的 DoRF 拟合误差来量化与运动相关的多普勒信息以及跨天线的一致性，并丢弃提供弱或不一致线索的天线。通过仅保留最具信息量的天线，它保存了关键的运动动态并提供了稳健的运动表示。实验表明，在跨用户泛化方面有显著改进，确立了所提出的框架作为细粒度 Wi-Fi 感知的稳健解决方案。

Table 1: 使用多个 Wi-Fi 接入点进行四类手部动作识别的泛化结果，平均值基于六名用户。

方法	准确率 (%)	
	平均值	标准差
AMAP [21]	26.3	2.8
CMAF [21]	28.1	2.9
CapsHAR [6]	33.7	6.1
CSI Ratio Model [16]	36.1	5.1
MORIC [13]	56.3	9.1
DoRF [15]	58.9	8.1
提出的方法 (DoRF + 抗. 选)	65.3	8.3

6. REFERENCES

- [1] Rui Du, Haocheng Hua, Hailiang Xie, Xianxin Song, Zhonghao Lyu, Mengshi Hu, Yan Xin, Stephen McCann, Michael Montemurro, Tony Xiao Han, et al., “An overview on ieee 802.11 bf: Wlan sensing,” *IEEE Communications Surveys & Tutorials*, 2024.
- [2] Ahmed Y Radwan, Mustafa Yildirim, Navid Hasan-zadeh, Hina Tabassum, and Shahrokh Valaee, “A tutorial-cum-survey on self-supervised learning for wi-fi sensing: Trends, challenges, and outlook,” *IEEE Communications Surveys & Tutorials*, 2025.
- [3] Hojjat Salehinejad and Shahrokh Valaee, “Lite-HAR: Lightweight human activity recognition from WiFi signals with random convolution kernels,” in *ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2022, pp. 4068–4072.
- [4] Jianyang Ding, Yong Wang, Qian Xie, and Jiajun Niu, “A multiple wifi sensors assisted human activity recognition scheme for smart home,” *IEEE Sensors Journal*, 2024.
- [5] Siamak Yousefi, Hirokazu Narui, Sankalp Dayal, Stefano Ermon, and Shahrokh Valaee, “A survey on behavior recognition using WiFi channel state information,” *IEEE Communications Magazine*, vol. 55, no. 10, pp. 98–104, 2017.
- [6] Radomir Djogo, Hojjat Salehinejad, Navid Hasan-zadeh, and Shahrokh Valaee, “Fresnel zone-based voting with capsule networks for human activity recognition from channel state information,” *IEEE Internet of Things Journal*, pp. 1–1, 2024.
- [7] Kyongseok Jang, Chao Sun, Junhao Zhou, Yongbin Seo, Youngok Kim, and Seyeong Choi, “A study on the lightweight and fast response GRU techniques for indoor continuous motion recognition based on wi-fi csi,” *IEEE Access*, 2025.
- [8] Yong Zhang, Dingchao Wu, Yujie Wang, Yang Zhang, Guangkun Jiand, and Jiaqiu Ai, “CSI-GLSTN: A location-independent csi human activity

- recognition method based on spatio-temporal and channel feature fusion,” *IEEE Transactions on Instrumentation and Measurement*, 2024.
- [9] Cheng Peng, Linqing Gui, Biyun Sheng, Zhengxin Guo, and Fu Xiao, “RoSeFi: A robust sedentary behavior monitoring system with commodity WiFi devices,” *IEEE Transactions on Mobile Computing*, vol. 23, no. 5, pp. 6470–6489, 2023.
- [10] Domonkos Varga, “Exposing data leakage in Wi-Fi CSI-based human action recognition: A critical analysis,” *Inventions*, vol. 9, no. 4, pp. 90, 2024.
- [11] Francesca Meneghello, Domenico Garlisi, Nicolò Dal Fabbro, Ilenia Tinnirello, and Michele Rossi, “Sharp: Environment and person independent activity recognition with commodity ieee 802.11 access points,” *IEEE Transactions on Mobile Computing*, vol. 22, no. 10, pp. 6160–6175, 2022.
- [12] Yi Zhang, Yue Zheng, Kun Qian, Guidong Zhang, Yunhao Liu, Chenshu Wu, and Zheng Yang, “Widar3. 0: Zero-effort cross-domain gesture recognition with wi-fi,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 11, pp. 8671–8688, 2021.
- [13] Navid Hasanzadeh and Shahrokh Valaee, “MORIC: CSI delay-doppler decomposition for robust wi-fi-based human activity recognition,” *arXiv preprint arXiv:2506.12997*, 2025.
- [14] Ben Mildenhall, Pratul P Srinivasan, Matthew Tan-cik, Jonathan T Barron, Ravi Ramamoorthi, and Ren Ng, “NeRF: Representing scenes as neural radiance fields for view synthesis,” *Communications of the ACM*, vol. 65, no. 1, pp. 99–106, 2021.
- [15] Navid Hasanzadeh and Shahrokh Valaee, “DoRF: Doppler radiance fields for robust human activity recognition using wi-fi,” *arXiv preprint arXiv:2507.12132*, 2025.
- [16] Dan Wu, Youwei Zeng, Fusang Zhang, and Daqing Zhang, “Wifi csi-based device-free sensing: from fresnel zone model to csi-ratio model,” *CCF Transactions on Pervasive Computing and Interaction*, vol. 4, no. 1, pp. 88–102, 2022.
- [17] Navid Tadayon, Muhammed Tahsin Rahman, Shuo Han, Shahrokh Valaee, and Wei Yu, “Decimeter ranging with channel state information,” *IEEE Transactions on Wireless Communications*, vol. 18, no. 7, pp. 3453–3468, 2019.
- [18] Navid Hasanzadeh, Radomir Djogo, Hojjat Salehinejad, and Shahrokh Valaee, “UTHAMO: A multi-modal wi-fi csi-based hand motion dataset,” 2025.
- [19] Francesco Gringoli, Matthias Schulz, Jakob Link, and Matthias Hollick, “Free your CSI: A channel state information extraction platform for modern wi-fi chipsets,” in *Proceedings of the 13th International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization*, 2019, WiNTECH ’19, p. 21 – 28.
- [20] Ilya Loshchilov and Frank Hutter, “Decoupled weight decay regularization,” *arXiv preprint arXiv:1711.05101*, 2017.
- [21] Hojjat Salehinejad, Navid Hasanzadeh, Radomir Djogo, and Shahrokh Valaee, “Joint human orientation-activity recognition using wifi signals for human-machine interaction,” in *ICASSP 2023-2023 IEEE international conference on acoustics, speech and signal processing (ICASSP)*. IEEE, 2023, pp. 1–5.