

基于原型网络的跨环境通道状态信息人体活动识别模型改进

陆许明¹, 黄缘昊¹, 陈翔²

(1. 五邑大学电子与信息工程学院, 广东 江门 529020; 2. 中山大学电子与信息工程学院, 广东 广州 510800)

摘 要: 随着 Wi-Fi 设备的普及, Wi-Fi 传感在医疗、家庭安全和监控等方面实现了广泛的应用, 相对于传统摄像头, 监控摄像头能够更好地保护使用者的隐私。目前, 深度学习技术在人类活动识别领域的作用越来越重要, 深度学习技术能从 Wi-Fi 数据包收集的信道状态信息 (CSI) 对事件进行分类。然而, 大多数模型需要大量 CSI 数据提供支持, 且模型在不同环境测试时的准确性较差。为了应对这个问题, 提出了一个基于原型网络的跨环境信道状态信息人活动识别模型 (HYHCPNet)。它通过利用已训练环境与未训练环境特征差异, 有效地提高了模型在不同环境中的准确率。实验结果表明, 所提方案显著优于最先进的人体活动识别方法, 实现了更高的识别精度和更少的训练时间。

关键词: 无线通信; 信道状态信息; 人体活动识别; 少样本学习

中图分类号: TP393.0

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025238

HYHCPNet: cross environment channel state information human activity recognition model based on prototypical network

LU Xuming¹, HUANG Yuanhao¹, CHEN Xiang²

1. School of Electronic and Information Engineering, Wuyi University, Jiangmen 529020, China

2. School of Electronic and Information Engineering, Sun Yat-sen University, Guangzhou 510800, China

Abstract: With the popularity of Wi-Fi devices, in medical, home security, and surveillance fields, traditional cameras Wi-Fi sensing is widely used. Compared to traditional cameras, surveillance cameras better protect users' privacy. At present, the role of deep learning technology in human activity recognition is becoming increasingly important. Deep learning technology can classify events based on channel state information (CSI) collected from Wi-Fi packets. However, most models require a large amount of CSI data to provide support. These models have poor accuracy when tested in different environments. To address this issue, cross environment channel state information human activity recognition model based on prototypical network (HYHCPNet) was proposed. The accuracy of the model was effectively improved in different environments by utilizing the differences in features between the trained and untrained environments. Experiments show that the proposed scheme significantly outperforms state-of-the-art human activity recognition methods, achieving higher recognition accuracy and less training time.

Keywords: wireless fidelity, channel state information, human activity recognition, few shot learning

收稿日期: 2025-08-04; 修回日期: 2025-09-15

通信作者: 陈翔, chenxiang@mail.sysu.edu.cn

基金项目: 2022 年度广东省教育厅广东普通高校重点领域专项基金资助项目 (No.2022ZDZX1033); 2025 年度五邑大学广东省百校联百县助力“百县千镇万村高质量发展工程”行动基金资助项目 (No.BQW2025011)

Foundation Items: 2022 Guangdong Provincial Department of Education Key Fields Project for General Higher Education Institutions (No.2022ZDZX1033), 2025 Wuyi University Guangdong Province “Hundred Schools Supporting Hundred Counties” Action Project (No.BQW2025011)

0 引言

无线通信 (Wi-Fi, wireless fidelity) 设备普遍存在于家庭、学校、医院等不同场所, 作为当前数字时代不可或缺的基础设施之一, 已经成为人类活动识别 (HAR, human activity recognition) 研究领域的重要组成部分。通过捕捉和分析 Wi-Fi 信号在环境中的微小变化, 如信号强度、相位差异等, 研究者能够非侵入性地监测和推断用户在不同空间内的活动模式, 如行走、坐下、站立甚至是更细微的手势动作。这种技术不仅为智能家居、健康监测、安全监控等领域提供了全新的视角和解决方案, 还极大地促进了人机交互的智能化与个性化发展。此外, 相对于传统摄像头, 监控摄像头能够更好地保护使用者的隐私。因此, Wi-Fi 在 HAR 研究中的应用正日益受到重视, 并展现出巨大的潜力和广阔的应用前景。

不同环境下的识别稳定性对于 HAR 是非常重要的, 如果模型不能很好地应用于新的环境中, 那可能会直接影响到老人的生命健康或者家庭安全。虽然现有的工作提出了推广到多种环境下的基于 CSI 的传感, 但它们效果并不理想, 尤其是在 20 MHz 信道环境下的准确率还有待提升。

为了应对现有的挑战, 本文提出了一个基于原型网络的跨环境信道状态信息人活动识别模型 (HYHCPNet) 来提高模型在新环境下的准确率。这种训练策略不需要从测试环境中提取大量的样本。相反, 它只需要利用原型网络在测试环境中提供的一组支持集。

本文的主要工作如下。

1) 提出了一种基于原型网络 (ProtoNet, prototypical network) 的 HAR 训练策略, 成功地进行了简短的学习, 以识别新环境中的人类活动。所提方案可以以最小的成本提高跨环境人类活动的识别准确性。

2) 为了评估所提方案的性能, 进行了许多实验。实验结果表明, 所提方案比单纯的原型网络感知方法具有更高的识别性能。

3) 使用现成的 Wi-Fi 设备实现了 HYHCPNet 的雏形, 并通过将人类活动识别作为一个用例来展示其对新环境的通用性。在 2 个不同的传播环境中进行了广泛的数据收集活动, 有一个人类受试者。评估了不同样本数量对性能的影响, 并将 HYHCPNet

与基于 ProtoNet 和匹配网络 (MatNet, matching network) 的方法进行了比较。实验结果表明, 与基于 ProtoNet 和 MatNet 的方法相比, 在未知环境中进行测试, HYHCPNet 准确率超过了 ProtoNet 和 MatNet。

值得注意的是, 相对于 ProtoNet, HYHCPNet 只需要额外提取一个来自源环境数据的中心点。此外, 在新环境中的对数据的要求与 ProtoNet 是一致的。

1 相关工作

Wi-Fi 传感技术的核心理念在于, 当物体穿越 Wi-Fi 信号覆盖区域时, 它们不仅作为物理障碍物, 还通过其独特的反射、散射和吸收特性, 微妙地改变了 Wi-Fi 信号的传播模式。这一过程影响了信号的相位、振幅等属性, 为环境感知提供了丰富的信息。通过巧妙设计的算法对接收到的 Wi-Fi 信号进行解析与处理, 能够捕捉到环境中物体的存在状态、运动轨迹乃至其形状大小等细节信息, 从而实现不需要额外传感器的高精度环境监测与跟踪。因此, Wi-Fi 传感已被广泛应用于传感应用中, 如智能家居^[1]、无设备监控^[2]、活动识别^[3]和医疗保健应用^[4]等。

研究者们提出了若干个 HAR 的实验方法。尽管它们已经取得了一部分进展, 但是这些通过专注于预处理的方法^[4]或采用复杂机器学习的方法^[5]在新环境中发挥的作用比较有限。文献[6]提出了少样本学习 (FSL, few-shot learning) 来解决信道状态信息 (CSI) 学习, 使用一种基于长短期记忆网络的技术, 称为 MatNet^[7], 但是其增加了该方法的计算复杂度, 并限制了该方法的适应性。文献[8]建立了一个识别模型并应用于一个新的环境, 而不需要测试环境的样本。然而, 它的识别精度在很大程度上取决于对抗学习在训练中使用的先前已见环境的样本数量。当测试环境无法提供较多的先前已见环境样本时, 该方法无法完成成功的识别。文献[9]使用稀疏自编码器 (SAE, stacked autoencoder) 提出了一种活动识别方案, 它从 CSI 信号中提取特征, 然后将学习到的特征输入回归函数中对行为进行分类。文献[10]利用生成对抗网络 (GAN, generative adversarial network) 生成人工示例, 虽然成功地提高了预测的准确性, 但是还不足以推广到新环境中。文献[11]设计了一个 Wi-Fi 传感框架 ReWiS, ReWiS 的核心在于采用定制的 ProtoNet 对有限的数据进行

学习和推广,降低数据采集和标记的成本。该方法在不同环境下的 HAR 取得了一定的成果,但是在一个发送机、一个接收机、20 MHz 环境下的识别准确率不是非常理想。

基于上述情况,本文采用了一种先进的少样本学习方法,即 ProtoNet,来识别人类活动的类型,只需要利用与原型网络所需同等数量的特征,以及一个独特的跨环境映射模块。

2 方法

2.1 数据采集

假设一个人在 Wi-Fi 网络覆盖的室内环境中移动,不可避免的是,一些 Wi-Fi 信号会被散射、衍射、反射或吸收,导致幅度和相位的变化。由于这些变化涉及人类活动的不同特征,因此可以利用 Wi-Fi 信号中的 CSI 测量来实现 HAR。本文使用 USRPB210 软件无线电设备,在服务器搭建的 Ubuntu 环境下,运用 PicoScenes 这一 CSI 收集工具收集了一批 2 个不同环境的 4 个不同类别的动作用的 CSI。所有测试都使用一个发送器、一个接收器与 20 MHz 通道。

本文实验使用的数据采集和测试环境如图 1 所示,参与实验的 1 名受试者在 2 个不同的环境中进行活动,受试者的年龄在 20~30 岁。每个人执行 4 种活动:空房间、跳、站立、行走,每个活动总共被执行约 40 次。该数据集根据环境的不同被划分为训练数据集和测试数据集。




图 1 本文实验使用的数据采集和测试环境

假设在对一个动作提取一个样本 \mathbf{S} 时,有 P 个数据包, F 个特征,那么该样本的表达式为

$$\mathbf{S} = \begin{pmatrix} s_{1,1} & \cdots & s_{1,F} \\ \vdots & & \vdots \\ s_{P,1} & \cdots & s_{P,F} \end{pmatrix} \quad (1)$$

其中, $s_{p,f}$ 表示样本 \mathbf{S} 中第 p 个数据包的第 f 个特征。

2.2 数据处理

数据处理阶段的目的是减少 CSI 矩阵的大小。CSI 矩阵 \mathbf{S} 表示原始的 CSI 测量值, \mathbf{S} 的规模相当大,直接利用 \mathbf{S} 来使用神经网络进行训练和分类需要消耗大量的算力和时间。为了解决这些问题,本文采用奇异值分解 (SVD, singular value decomposition) 对数据帧进行最小化预处理。SVD 包括 2 个主要功能:消除 CSI 矩阵 \mathbf{S} 中较不重要的变量和特征提取。

首先,利用 SVD,将式(1)中的数据帧矩阵分解为 3 个矩阵的乘积。

$$\mathbf{S} = \mathbf{U}_{P \times P} \mathbf{D}_{P \times F} \mathbf{V}_{F \times F}^T \quad (2)$$

$$\mathbf{S}^T = \mathbf{V} \mathbf{D}^T \mathbf{U}^T \quad (3)$$

其中, \mathbf{D} 的对角线值包含数据帧的奇异值, \mathbf{V} 和 \mathbf{U} 称为 \mathbf{S}^T 左、右奇异向量。

其次,将 \mathbf{S}^T 与右奇异向量 \mathbf{U}^T 相乘 $\mathbf{S}' = \mathbf{S}^T \cdot \mathbf{U}^T$ 。

通过计算数据帧 \mathbf{S}' 的皮尔逊相关系数 (PCC, Pearson correlation coefficient) 来提取子载波之间的线性相关关系。

$$\text{corroef}(\mathbf{S}') = \begin{pmatrix} cS'_{1,1} & \cdots & cS'_{1,F} \\ \vdots & & \vdots \\ cS'_{F,1} & \cdots & cS'_{F,F} \end{pmatrix} \quad (4)$$

同时,为了压缩矩阵的大小剔除 $\text{corroef}(\mathbf{S}')$ 矩阵的主对角线元素。

$$\mathbf{CD} = \begin{pmatrix} cd_{1,1} & \cdots & cd_{1,P-1} \\ \vdots & & \vdots \\ cd_{P,1} & \cdots & cd_{P,P-1} \end{pmatrix} = \begin{pmatrix} cS'_{1,2} & cS'_{1,3} & \cdots & cS'_{1,P} \\ cS'_{2,1} & cS'_{2,3} & & \\ \vdots & & & \\ cS'_{P-1,1} & & & cS'_{P-1,P} \\ cS'_{P,1} & & \cdots & cS'_{P,P-1} \end{pmatrix} \quad (5)$$

最后,剔除矩阵最后一行得到的矩阵表达式为

$$\mathbf{Data} = \begin{pmatrix} da_{1,1} & \cdots & da_{1,P-1} \\ \vdots & & \vdots \\ da_{P-1,1} & \cdots & da_{P-1,P-1} \\ cS'_{1,2} & cS'_{1,3} & \cdots & cS'_{1,P} \\ cS'_{2,1} & cS'_{2,3} & & \\ \vdots & & & \\ cS'_{P-1,1} & & \cdots & cS'_{P-1,P} \end{pmatrix} \quad (6)$$

2.3 分类器

本文首先讨论了关于 ProtoNet 的初步情况,然

后提出了HYHCPNet学习策略。

2.3.1 原型网络

在 Wi-Fi 传感等应用中，收集和标记大数据集是困难的，因此有监督学习的准确度受到严重限制。基于此，一些研究者开始使用原型网络，其目标是在有限的样本数量下快速适应新的数据。ProtoNet 是一种在深度学习领域，特别是在 FSL 中广泛应用的模型。它通过学习类别的“原型”来表示每个类别，进而实现对新样本的分类。这种方法在处理只有少量标记样本的学习任务时尤为有效，因为它能够通过少量的样本快速适应新的类别。

原型网络的核心思想是为每个类别学习一个“原型”，这个原型是该类别所有样本在特征空间中的代表。在训练过程中，模型学习如何将输入样本映射到一个特征空间，并在这个空间中计算样本与各个类别原型之间的距离。分类时，模型将新样本映射到同一特征空间，并根据其与各个原型的距离来判断其类别。

原型网络在工作时使用一个深度神经网络（通常是卷积神经网络）来提取输入样本的特征。这个网络被称为特征提取器。在特征空间中，每个类别的原型是该类别所有样本特征的均值。这个均值向量代表了该类别在特征空间中的中心位置。对于一个新的样本，模型首先提取其特征，然后计算这个特征与每个类别原型之间的距离。常用的距离度量包括欧氏距离和余弦相似度。最后，模型将新样本归类为与其距离最近的原型所对应的类别。

2.3.2 HYHCPNet 训练策略

文献[11]利用原型网络在少样本学习方面表现出了良好的结果。然而该模型的网络结构比较简单，在模型的训练中可能无法很好地发挥半监督的

优势。为了解决这个问题，本文提出了 HYHCPNet。该模型通过利用原型网络在新旧环境中都需要使用一个支持集的特点，这使本文在跨域姿态检测的问题下保留半监督学习鲁棒性的同时，利用深度学习的办法更全面地比较不同环境间的特征，使模型对跨环境的人类行为特征的描述更加准确。

图 2 为 HYHCPNet 训练框架，即在支持集中存在 4 个类和 5 个示例。

1) 嵌入模块训练

嵌入模块仅在源环境中被训练。嵌入训练使用包括 4 个卷积块的卷积神经网络（CNN, convolutional neural network）进行训练。每个卷积块包含一个 64 通道 3×3 大小的卷积核、批归一化层、一个 ReLU 激活函数，在每个块之后应用一个 2×2 的最大池化层。在第 4 个块之上建立一个全局平均池化层来生成特征嵌入。首先，嵌入模块训练中使用 Adam 优化器进行训练。其次，学习率初始化为 10^{-3} ，一共进行 2 000 次训练，当训练轮次完成 1 000 次时学习率减半。最后，通过 softmax 损失函数完成训练。

2) 跨环境映射模块训练策略

HYHCPNet 的训练步骤如下。

步骤 1 嵌入模块在源环境训练过程中，每轮训练后在支持集上对 K 个类别分别计算中心点并提取，提取后求平均值，本文称为“源中心集”。

步骤 2 在新的环境中，同样地随机抽取支持集与查询集，本文使用在源环境中完成训练的嵌入模块对支持集与查询集进行特征提取。

步骤 3 对新环境上的支持集特征，同样的，对 K 个类别分别计算中心点，本文称为“新中心集”。

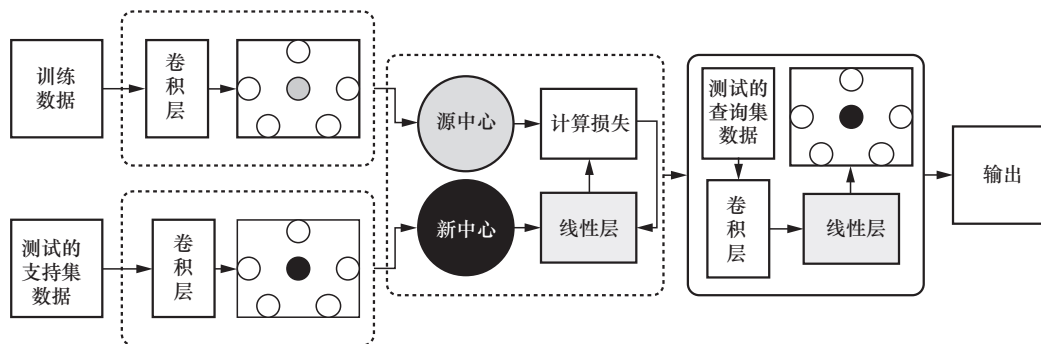


图 2 HYHCPNet 训练框架

步骤 4 如图 3 所示, 使用一层线性层学习从“新中心集”到“源中心集”的映射关系。对应不同的样本数量, 详细参数参见第 3 节。




图3 HYHCPNet跨环境映射模块

步骤 5 利用已训练的线性层对新环境下的查询集特征进行映射。

步骤 6 比较新环境下映射后的查询集特征与“新中心集”特征的损失并完成分类。统计准确率, 进入步骤 4。

步骤 7 进入步骤 2, 一共提取 1 000 次作为一次测试。

3 仿真分析

本节评估 HYHCPNet 的性能, 并将其与 ProtoNet 与 MatNet 比较。值得注意的是, HYHCPNet 与文献[11]中使用的 ProtoNet 相比有一个关键的区别。HYHCPNet 使用了一种量身定制的新训练策略, 可以更好地探索 ProtoNet 的特性。通过这种训练策略, 可以使用测试环境中的一个支持集来完成识别任务。

表 1 比较了 3 种在 20 MHz 通道下 1-样本和 5-样本场景中的平均识别率, 置信水平为 95%。HYHCPNet 在 1-样本和 5-样本场景中均使用一层线性层学习从“新中心集”到“源中心集”的映射关系。这个线性层输入 input=576、输出 output=576, 初始化权重为 576×576 的单位矩阵, 训练时使用 Adam 优化器进行训练, 初始学习率设置 10^{-3} , Scheduler 使用 MultiStepLR。1-样本场景时, 当训练轮次达到 2、5、45 时, 学习率减小至原来的 10%, 一共训练 65 轮, HYHCPNet 的准确率比 ProtoNet 高 0.4%。5-样本场景时, 当训练轮次达到 9 时, 学习率减小至原来的 10%, 一共训练 200 轮,

HYHCPNet 的准确率比 ProtoNet 和 MatNet 分别高 2.6% 和 0.9%。

表 1 样本数量 K 对准确性的影响

模型	1-样本	5-样本
MatNet	54.3%±3.11%	71.6%±2.65%
ProtoNet	53.1%±3.38%	69.9%±3.09%
HYHCPNet (本文)	53.5%±3.75%	72.5%±2.95%

为了平衡预测为正类的准确率 (Precision) 和实际正类的召回率 (Recall) 的权重, 本文进一步引入了 F1 分数 (F1 score) 作为算法的评估指标。F1 分数是模型性能的核心指标, 通过准确率和召回率的调和平均数实现, 其数值范围为 0~1, 值越高表示模型性能越好。它平衡了精确率和召回率, 适用于需要兼顾两者重要性的场景。F1 分数有效地规避了准确性等单一指标的局限性, 为模型性能提供了更全面的评估。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (7)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8)$$

$$\text{F1 score} = \frac{2(\text{Precision} \cdot \text{Recall})}{\text{Precision} + \text{Recall}} \quad (9)$$

其中, TP、TN 和 FP 分别代表真阳性、真阴性和假阳性。

表 2 为样本数量对每个动作的预测准确性和 F1 分数的影响。每个模型对 1-样本场景和 5-样本场景所有动作的平均预测精度如图 4 所示, 1-样本场景变为 5-样本场景时, 准确率和 F1 分数分别提升 19.1% 和 19%。总体而言, 样本数量能提升跳跃、立定、行走等各项活动的预测准确率。由表 2 可以看出, HYHCPNet 无论是 1-样本场景还是 5-样本场景, 其表现均显著优于作为 ProtoNet。这是因为本文设计了定制化训练策略, 充分发挥了 ProtoNet 的特性以确保可靠的感知性能。因此, 即使每个活动仅从测试环境中获取一个样本, 也能有效建立感知系统与测试环境之间的桥梁。在 5-样本场景的总体评估指标中, HYHCPNet 相对于 ProtoNet 和 MatNet, 准确率分别提升 2.6% 和 0.9%, F1 分数分别提升 2.8% 和 2%。对于准确率, HYHCPNet 在动作跳跃、立定、行走上相对于 ProtoNet 分别提升了 0.8%、1.1%、9.5%, 相对于 MatNet 分别提升了

表2 样本数量对每个动作的预测准确性和F1分数的影响

	样本场景	空房间		跳跃		立定		行走		平均	
		准确率	F1分数	准确率	F1分数	准确率	F1分数	准确率	F1分数	准确率	F1分数
HY-HCPNet	1-样本	0.640 76	0.669 88	0.339 92	0.371 01	0.613 39	0.610 68	0.545 33	0.485 67	0.534 85	0.534 31
	5-样本	0.861 85	0.879 21	0.509 09	0.562 89	0.747 71	0.777 39	0.783 43	0.679 17	0.725 52	0.724 67
ProtoNet	1-样本	0.670 46	0.683 78	0.337 15	0.365 14	0.597 41	0.601 91	0.520 13	0.471 30	0.531 29	0.530 53
	5-样本	0.871 30	0.840 03	0.501 14	0.538 66	0.736 22	0.770 04	0.688 37	0.639 54	0.699 26	0.697 07
MatNet	1-样本	0.760 25	0.652 73	0.359 12	0.411 40	0.532 85	0.611 62	0.520 01	0.476 57	0.543 06	0.538 08
	5-样本	0.940 50	0.817 75	0.424 53	0.536 86	0.718 54	0.765 54	0.781 80	0.697 71	0.716 34	0.704 46

8.5%、2.9%、0.2%。对于F1分数，HYHCPNet在状态空房间、跳跃、立定上相对于ProtoNet分别提升了3.9%、2.4%、0.7%，相对于MatNet分别提升了6.1%、2.6%、1.2%。虽然MatNet在跳跃动作上的准确率只有42.5%，但是总体上MatNet的准确率依然高于ProtoNet的原因是MatNet在行走动作上的准确率远高于ProtoNet。值得注意的是，HYHCPNet在提升了ProtoNet在跳跃动作上准确率的同时，在行走动作上的准确率超过了MatNet。

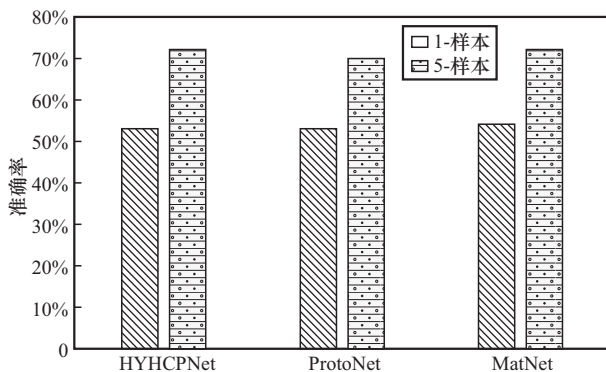


图4 每个模型对1-样本场景和5-样本场景所有动作的平均预测精度

4 结束语

本文提出了HYHCPNet，一个新的跨环境人体姿态识别深度学习Wi-Fi传感框架。HYHCPNet在单天线单接收机、20 MHz环境下训练，这使它能够在更广泛场景。HYHCPNet利用ProtoNet的定制版本建立了CSI数据从新环境到旧环境的映射关系。本文进行了广泛的数据收集活动，评估了改进的组件对性能的影响，并将HYHCPNet与ProtoNet和MatNet进行了比较。实验结果表明，与现有的单天线低分辨率方法相比，在不同环境下测试时，1-样本场景和5-样本场景下HYHCPNet精度比

ProtoNet提高了0.4%、2.6%。在5-样本场景下HYHCPNet精度比MatNet提高了0.9%。

值得注意的是，本文只使用了一层线性层来学习环境间的映射关系。未来，将把更有效的深度学习识别方法研究作为对这项工作的延伸，这将是一项相当具有挑战性的任务。

参考文献：

- [1] JIANG H B, CAI C, MA X Q, et al. Smart home based on Wi-Fi sensing: a survey[J]. IEEE Access, 2018, 6: 13317-13325.
- [2] ZHANG J, WEI B, HU W, et al. WiFi-ID: human identification using Wi-Fi signal[C]//Proceedings of the 2016 International Conference on Distributed Computing in Sensor Systems (DCOSS). Piscataway: IEEE Press, 2016: 75-82.
- [3] CHEN Z H, ZHANG L, JIANG C Y, et al. Wi-Fi CSI based passive human activity recognition using attention based BLSTM[J]. IEEE Transactions on Mobile Computing, 2018, 18(11): 2714-2724.
- [4] ZENG Y W, WU D, XIONG J, et al. MultiSense: enabling multi-person respiration sensing with commodity WiFi[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2020, 4(3): 1-29.
- [5] MA Y S, ARSHAD S, MUNIRAJU S, et al. Location and person-independent activity recognition with WiFi, deep neural networks, and reinforcement learning[J]. ACM Transactions on Internet of Things, 2021, 2(1): 1-25.
- [6] SHI Z G, ZHANG J A, XU R Y, et al. Environment-robust device-free human activity recognition with channel-state-information enhancement and one-shot learning[J]. IEEE Transactions on Mobile Computing, 2022, 21(2): 540-554.
- [7] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[J]. Advances in Neural Information Processing Systems, 2016, 29: 3630-3638.
- [8] JIANG W, MIAO C, MA F, et al. Towards environment independent device free human activity recognition[C]//Proceedings of the 24th Annual International Conference on Mobile Computing and Networking. New York: ACM Press, 2018: 289-304.
- [9] GAO Q H, WANG J, MA X R, et al. CSI-based device-free wireless localization and activity recognition using radio image features[J]. IEEE Transactions on Vehicular Technology, 2017, 66(11): 10346-10356.
- [10] XIAO C J, HAN D J, MA Y S, et al. CsiGAN: robust channel state

information-based activity recognition with GANs[J]. IEEE Internet of Things Journal, 2019, 6(6): 10191-10204.

- [11] BAHADORI N, ASHDOWN J, RESTUCCIA F. ReWiS: reliable Wi-Fi sensing through few-shot multi-antenna multi-receiver CSI learning [C]//Proceedings of the 2022 IEEE 23rd International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM). Piscataway: IEEE Press, 2022: 50-59.

[作者简介]



陆许明 (1985-), 男, 广东韶关人, 博士, 五邑大学高级工程师, 主要研究方向为无线通信和物联网应用。



黄缘昊 (2001-), 男, 江西抚州人, 五邑大学硕士生, 主要研究方向为深度学习和模式识别。



陈翔 (1980-), 男, 湖南长沙人, 中山大学教授、博士生导师, 主要研究方向为 5G/6G 无线通信、卫星通信、大数据和物联网。