

## 基于 CSI 小样本学习的场景鲁棒性跌倒检测系统

曾钰婷<sup>1</sup>, 毕宿志<sup>1,2</sup>, 郑莉莉<sup>1</sup>, 林晓辉<sup>1</sup>, 王晖<sup>3</sup>

(1. 深圳大学电子与信息工程学院, 广东 深圳 518060; 2. 鹏城实验室宽带通信研究部, 广东 深圳 518066;  
3. 深圳信息职业技术学院, 广东 深圳 518172)

**摘要:** 采用小样本学习技术设计了基于 CSI 的场景鲁棒性跌倒检测系统 (FDFL, fall detection system based on few-shot learning)。现有基于 Wi-Fi 无线信道状态信息 (CSI, channel state information) 的跌倒检测方法跨场景应用性能退化明显, 通常需要在每个应用场景采集并标记大量的 CSI 样本, 给大规模部署造成极高的成本。为此, 引入了小样本学习的方法, 可以在陌生场景标注样本数量不足的情况下仍然保持高准确率的跌倒检测性能。所提 FDFL 主要分为源域的元训练和目标域的元学习两个阶段。源域的元训练阶段包含数据预处理和分类训练两个部分, 数据预处理阶段将采集的原始 CSI 幅度和相位数据进行去噪、分段等操作; 分类训练阶段利用大量处理好的源域数据样本训练一个基于卷积神经网络的 CSI 特征提取器。在目标域的元学习阶段, 基于元训练模块中训练的特征提取器对目标域中采样的少量标注样本进行有效的特征提取, 进而训练生成一个轻量型机器学习分类器对跨场景下的跌倒行为进行检测。通过多个不同场景下的实验, FDFL 在只需要目标域少量样本下即可以实现对跌倒、坐着、步行、坐下的四分类任务达到 95.52% 的平均识别准确率, 并且对测试环境、人员目标、设备位置等因素的变化保持鲁棒的检测准确性。

**关键词:** 无线感知; 跌倒检测; CSI; 跨域检测; 小样本学习

**中图分类号:** TN391.7

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2023.00339

## Scenario-adaptive wireless fall detection system based on few-shot learning

ZENG Yuting<sup>1</sup>, BI Suzhi<sup>1,2</sup>, ZHENG Lili<sup>1</sup>, LIN Xiaohui<sup>1</sup>, WANG Hui<sup>3</sup>

1. College of Electronics and Information Engineering, Shenzhen University, Shenzhen 518060, China  
2. Pengcheng Laboratory Broadband Communication Research Department, Shenzhen 518066, China  
3. Shenzhen Institute of Information Technology, Shenzhen 518172, China

**Abstract:** A scenario robust fall detection system based on few-shot learning (FDFL) in wireless environment was designed. The performance of existing fall detection methods based on Wi-Fi channel state information (CSI) degrades significantly across scenarios, which requires collecting and marking a large number of CSI samples in each application scenario, resulting in high cost for large-scale deployment. Therefore, the method of few-shot learning was introduced,

收稿日期: 2022-11-28; 修回日期: 2023-03-16

通信作者: 毕宿志, bsz@szu.edu.cn

**基金项目:** 国家自然科学基金资助项目 (No.62271325); 鹏城实验室宽带通信研究部重点研究计划项目; 广东省教育厅科技重点专项 (No.2020ZDZX3050); 广东省基础与应用基础研究基金资助项目 (No.2022A1515011219, No.2022A1515010973); 深圳市科创委基础研究项目 (No.20220810142637001, No.JCYJ20210324093011030, No.JCYJ20190808120415286); 智慧城市物联网国家重点实验室 (澳门大学) 开放课题项目 (No.SKL-IoTSC(UM)-2021-2023/ORPF/A03/2022)

**Foundation Items:** The National Natural Science Foundation of China (No.62271325), The Major Key Project of PCL Department of Broadband Communication, The Key Project of Department of Education of Guangdong Province (No.2020ZDZX3050), The Guangdong Basic and Applied Basic Research Foundation (No.2022A1515011219, No.2022A1515010973), The Shenzhen Science and Technology Program (No.20220810142637001, No.JCYJ20210324093011030, No.JCYJ20190808120415286), The Open Research Project Programme of the State Key Laboratory of Internet of Things for Smart City (University of Macau) (No.SKL-IoTSC(UM)-2021-2023/ORPF/A03/2022)

which can maintain the performance of fall detection with high accuracy when the number of annotated samples in unfamiliar scenes is insufficient. The proposed FDFL was mainly divided into two stages, source domain meta-training and target domain meta-learning. The meta training stage of the source domain consists of two parts: data preprocessing and classification training. In the data preprocessing stage, the collected original CSI amplitude and phase data were denoised and segmented. In the classification training stage, a large number of processed source domain data samples were used to train a CSI feature extractor based on convolutional neural network. In the meta-learning stage of the target domain, the limited labeled data sampled in the target domain was effectively extracted based on the feature extractor trained in the meta-training module, and then a lightweight machine learning classifier was trained to detect the fall behavior under the cross-scene. Through several experiments in different scenarios, FDFL can achieve an average accuracy of 95.52% for the four classification tasks of falling, sitting, walking and sit down with only a small number of samples in the target domain, and maintain robust detection accuracy for changes in test environment, personnel target and equipment location.

**Key words:** Wi-Fi sensing, fall detection, CSI, cross-domain detection, few-shot learning

## 0 引言

中国疾控中心的数据显示, 跌倒已经成为中国 65 岁及以上老年人受伤致死的首要原因<sup>[1]</sup>。跌倒的医疗结果很大程度上取决于发现是否及时, 现有的商用跌倒检测系统主要分为 3 类, 即视频式跌倒检测系统、基于环境传感器的跌倒检测系统、穿戴式跌倒检测系统<sup>[2-6]</sup>。视频式跌倒检测系统是在人体活动区域内安装视频传感器, 采集人体运动图像, 通过图像分析的方法实现跌倒判断。基于环境传感器的跌倒检测系统通常在人体活动区域内嵌入无线传感器网络、红外传感器、声音传感器、压力传感器、多普勒雷达等非视频传感器, 采集人体运动和姿势信息, 进而判断是否发生跌倒。穿戴式跌倒检测系统通常将跌倒检测单元嵌入手机<sup>[7]</sup>、衣服、帽子、鞋、腰带、首饰等处, 可实时采集人体的运动参数或生理参数, 通过算法判断是否发生跌倒事件。这样的方法不仅增加了设备部署成本, 还带来了生活上的不便。为了克服上述限制, 近年来人们将注意力放在无线局域网技术上, 基于 Wi-Fi 的室内跌倒检测方法也逐渐成为主要的研究方向, Wi-Fi 信号几乎完全覆盖室内区域, 与上述方法相比, Wi-Fi 具有低成本、保护隐私等优点<sup>[8]</sup>。

传统的 Wi-Fi 室内跌倒检测主要依靠信号接收强度 (RSS, received signal strength)<sup>[9-10]</sup>, 但 RSS 属于 MAC 层, 存在不稳定、粗粒度、易受环境因素干扰等固有缺陷, 对于人体动作无法进行高精度的识别。近年来, 研究人员开始利用信道状态信息 (CSI, channel state information) 进行 Wi-Fi 感知研究<sup>[11-15]</sup>, 相较于 RSS, CSI 具有更好的时频稳定性和更细粒度的信道感知信息, 可以更灵敏地感知无线环境中

的人体动作的变化。因此, 基于 CSI 的跌倒监测技术能够获得更高的检测准确度。

目前基于 CSI 的跌倒检测算法主要分为人工提取特征的学习算法和自动提取特征的学习算法, 但是上述的两种方法都存在优缺点。前者主要依靠人工提取 CSI 矩阵的统计特征, 如均值、标准差、方差、波峰波谷数量等统计信息, 并使用机器学习模型 (如逻辑斯谛回归 (LR, logistical regression)、支持向量机 (SVM, support vector machine) 等) 学习不同动作情况下 CSI 测量矩阵之间的特征差异, 从而来识别跌倒动作。文献[16]使用高斯混合模型-隐马尔可夫模型 (GMM-HMM, the Gaussian mixture model-hidden Markov model) 模拟和学习复杂的人类活动, 在得到 HMM 的初始模型参数后, 采用 Baum-Welch 算法对模型参数进行训练, 然后进行迭代优化。该模型能够实现对一个人的实时跌倒检测, 并达到 95% 以上的检测准确率。文献[17]先从 CSI 幅度和相位差中提取特征, 然后利用 SVM 和标记树分类器实现了准确率为 96% 二值分类。FallViewer<sup>[18]</sup>分别从幅度、相位和频率等不同的角度提取特征, 利用支持向量机库 (LibSVM, a library for support vector machine) 作为二元分类器, 并设置高斯径向基函数 (RBF, radial basis function) 为其核函数, 该系统检测跌倒事件的平均准确率可达 95.8%。传统的机器学习算法虽然运算速度快, 但其缺点在于大多数机器学习算法的性能依赖于所提取的特征的准确度, 特征处理过程耗时而且需要专业知识来标定特征, 人工选取特征造成的经验误差难以控制。

深度学习技术免去了人工选取特征的步骤, 只需要将 CSI 矩阵的幅值信息和相位信息经过一定的

预处理（分割、降噪等）后输入神经网络模型（如深度神经网络、卷积神经网络（CNN, convolutional neural network）、循环神经网络等）进行监督训练，模型即可通过训练自动计算权重偏量并提取数据特征进行分类。文献[12]采用堆叠的 CNN 模型，它包含一个识别房间的分类器和识别每个房间活动的检测模型，在检测时先对识别活动发生在哪个房间，进而判断在那个房间中发生了哪个活动。文献[19]选择并行的 CNN-双向长短期记忆（BiLSTM, bi-directional long short-term memory）神经网络构建学习模型用于用户动作特征的提取和分类。文献[20]采用经过 ImageNet 数据集预训练后的 CNN 对不同房间下跌倒和非跌倒的二分类性能进行了实验评估，并将其与传统方法进行了性能比较。虽然深度学习削减了设计特征提取器的工作，但它依赖于充足的样本数据。此外，训练深度模型需要进行大量的矩阵运算，对硬件资源需求较大且通常训练时间长。

尽管经过充分训练的深度学习模型可以在一个特定场景实现高精度的跌倒检测，一旦在新的环境使用（如改变收发设备的位置或者更换实验房间和检测对象），由于同样的行为动作造成的 CSI 样本分布差异显著，跨场景检测精度往往会急剧下降。例如，本文实验表明，将空旷房间中训练的深度学习模型应用到摆设较为密集的房间后，跌倒检测准确率从 98% 急剧下降到 60%。为了保障较高的跌倒检测精度，现有的方法通常需要从头开始训练模型。但在实践中，收集新环境的数据和标记大量训练样本的成本非常高，难以在大规模的跨场景应用中操作。

考虑到上述情况，本文提出了一个基于小样本学习（FSL, few-shot learning）的场景鲁棒性跌倒检测系统，首先，利用 CNN 在标注样本充足的熟悉场景下提取跌倒行为数据特征；然后，引入小样本学习方法解决跨场景跌倒检测的模型鲁棒性和样本数量不足的问题，对于步行后跌倒（以下简称跌倒）、坐着、步行、坐下 4 种动作分类的问题，只需要极少量的陌生场景标注样本便达到 95% 以上的准确率。本文的主要贡献总结如下。

1) 基于 CSI 小样本学习的场景鲁棒性跌倒检测系统（FDFL）框架

FDFL 框架包括两个主要阶段：第一阶段是源域的元训练阶段，第二阶段是目标域的元学习阶段。在元训练阶段，其中一个源域收集的数据集上

训练先验深度学习 CNN 模型，从 CSI 的幅度和相位输入数据中提取特征。在元学习阶段，利用预先训练好的 CNN 模型作为目标域数据的特征提取器，再利用轻量化分类器得出最终的跌倒检测结果。通过两个阶段的处理，FDFL 可以有效地将从源域学习到的信号特征迁移运用到目标域，仅利用目标域少量的标注数据训练生成达到很高准确率的分类器。

## 2) 多姿态分类检测任务

该系统可以对多种动作（如步行、步行跌倒、坐下等）进行检测，因此本系统不局限用于跌倒检测，这要求更精准、更敏感的感知性能，FDFL 采用的小样本学习方法可以提高多姿态识别在跨域时的鲁棒性，实现多种动作的精确检测。

## 3) 面向姿态特征增强的无线信号预处理

分别为 CSI 幅度和相位数据设计了两个独立的数据预处理模块，对原始 CSI 数据进行去噪和分段等操作，便于后续更精确地提取信号特征。对于经过预处理的信号，利用两个特征提取器分别提取 CSI 低维幅度和相位数据的特征，便于在数据样本非常有限的情况下充分挖掘信号特征训练目标域分类器。

## 4) 实验验证与性能分析

通过搭建感知试验平台，笔者在不同场景下充分的评估了 FDFL 框架在跨域跌倒检测任务中的性能。结果表明，在 5-shot 的情况下，该方法的四分类检测精度约为 88%；在 15-shot 的情况下，检测性能有了明显的提升，在仅检测跌倒和不跌倒二分类的情况下可以达到 100% 的检测精度，在原实验场景中更换新的实验人员的数据作为测试数据时的四分类跌倒检测精度可达到 95% 以上，在更换实验场景和实验人员的数据作为测试数据时的四分类跌倒检测精度甚至可以达到 98%。在对比了不同的特征维度和分类器结构对跨域跌倒检测性能的影响之后，所提方法在不同的域中均达到优异的分类检测精度。

# 1 相关工作

本节从两个角度回顾了相关的工作，对于跌倒检测的研究和小样本学习在活动识别上的研究。

## 1.1 跌倒检测

室内跌倒检测对于及时救治独居老人有重要的作用，多年来一直都是研究热点。虽然人们自 20 世纪 90 年代初以来提出了大量的跌倒检测的技

术,但直到近几年才有研究尝试使用 Wi-Fi 射频信号对人体活动进行识别,如人数检测<sup>[21-22]</sup>、手势识别<sup>[23]</sup>、跌倒检测等。FallDeFi<sup>[6]</sup>利用短时傅里叶变换(STFT, short-time Fourier transform)提取时频特征,再利用基于时频的预筛选器对跌倒前的事件进行检测,并将预筛选器输出作为跌倒检测的特征。对于预先训练的系统可以达到 93% 以上的平均准确率,而在环境发生变化后平均准确率接近 80%。DeFall<sup>[2]</sup>的系统是由两个阶段组成的,离线阶段采用统计模型从 CSI 中估计跌倒速度,在基于动态时间规整(DTW, dynamic time warping)的算法中生成人类跌倒模板;在线阶段对跌倒事件进行检测,其检测准确率超过 95%。文献[24]采用 CSI 相位差展开矩阵作为跌倒检测的特征,并将 GMM-HMM 从基于三维骨架的活动识别迁移到基于 Wi-Fi 的跌倒检测中,利用一种简单的混合、自适应的嵌入方法,通过使用目标域测试样本进行模型-参数自适应来统一嵌入方法和权重自适应。WiFall<sup>[3]</sup>使用一个加权移动平均滤波器来降低环境噪声对 CSI 幅度产生的影响,并且采用异常检测算法检测人类活动,然后提取多个特征,使用支持向量机来识别跌倒,它可以实现平均 94% 的跌倒检测精度。Anti-Fall<sup>[4]</sup>将两个天线上 CSI 的相位差确定为可靠地分割跌倒和类似跌倒活动的特征,利用 CSI 的相位和幅度数据准确地将跌倒与其他类似跌倒活动分开。这个系统优于 WiFall 方法,检测率平均提高 10%,误报率降低 10%。RT-Fall<sup>[5]</sup>利用 CSI 的相位和幅度数据,实现了自动实时分割和检测跌倒的目标。RT-fall 优于 WiFall 方法,平均灵敏度提高 14%,特异性提高 10%。为了解决跨场景跌倒检测模型的鲁棒性和样本数量不足的问题,本文结合迁移学习和小样本学习的相关方法,提出了一个仅利用少量标注样本实现可靠跨场景室内跌倒检测的方法。

## 1.2 小样本学习

机器学习分类模型的训练需要学习大量的标注样本,为了降低数据收集和标记相关的高成本,近几年人们开始尝试将小样本学习方法应用到基于 CSI 的无线传感的应用中,如手势识别、人类活动识别等。小样本学习是机器学习的一种特殊情况,其目的是希望在训练集中仅能提供有限标记的样本情况下依然可以获得良好的分类性能。形式化来说, few-shot 的训练集中包含了很多的类别,每

个类别中有多个标注样本。在训练阶段,从训练集中随机抽取  $N$  个类别,每个类别  $K$  个样本(总共  $N \times K$  个数据),构建一个元任务(meta-task),作为模型的支撑集(support set)输入;再从这  $N$  个类剩余的数据中抽取一批样本作为模型的预测对象(batch set)。即要求模型基于  $N \times K$  个标注数据中学会如何区分这  $N$  个类别,这样的任务被称为  $N$ -way  $K$ -shot 问题。文献[25]所提系统采用了卷积块注意模块(CBAM, convolutional block attention module)的特征提取层提取 CSI 数据中的相关活动信息,然后利用设计的基于图的双注意机制小样本学习模式(CSI-GDAM, a graph-based few-shot learning method with dual attention mechanism is proposed to perform CSI-based HAR)对跨域下的多种人类活动数据(包含弯腰、起立、挥手等)进行分类,在新环境下识别新活动(如步行、跳跃、坐下等)的学习任务下, 5-way 5-shot 和 5-way 1-shot 的识别准确率分别达到 99.74% 和 98.42%。并与其他小样本学习方法进行了比较,如基于元学习的无设备手势识别(ML-DFGR, device-free gesture recognition based on meta learning)<sup>[26]</sup>、采用网络初始化方式的元学习(MTL, meta-transfer learning)<sup>[27]</sup>、一种利用增强信道状态信息的匹配网络的新方案(MatNet-eCSI, a novel scheme using matching network with enhanced channel state information)<sup>[28]</sup>。文献[29]首先利用神经网络将原始的 CSI 数据嵌入可分离的特征空间中,然后采用基于余弦距离的度量学习方法对手势活动(如坐着用右手画圈、伸起和放下双手等)进行预测,在基于小样本学习情况下实现了仅用很少带标签的样本进行训练的跨域感知,并在二分类中可实现 97% 的识别精度。文献[30]提出了一个基于 CSI 的人体活动识别系统框架,该框架可以通过对模型参数进行微调,而不用对网络进行再次训练,从而实现少量样本识别新类别的显著性能。在包含 276 种手势的公共数据集和 16 种人体活动的自制数据集上识别新活动的准确率分别达到 98.9% 和 94.7%。基于信道状态信息的人工认证系统(CAUTION, CSI-based human authentication system)<sup>[31]</sup>是一种基于 CSI 的人工认证系统,该系统可以通过 CSI 数据学习不同用户的独特步态特征,并利用小样本学习在非常有限的 CSI 训练数据下构建准确的用户识别模型,用户识别精度可达到 92% 左右,入侵者检测检测的平均精度为 90% 左右。

与细粒度人体动作检测的研究相比,精确的跨域人体活动识别如跌倒检测会更加困难,因为跌倒引起的CSI幅度和相位变化对背景环境变化非常敏感,在陌生新场景下的分类性能可能会急剧下降。本文提出了一个基于CSI小样本学习的场景鲁棒性跌倒检测系统,适用于多种检测场景变化下的应用:如相同场景下对不同实验人员的行为检测、不同场景下对实验人员的行为检测等。此系统可以从少量标记的目标域样本中学习,以实现高效精确的跨域跌倒检测。

## 2 背景知识和问题阐述

### 2.1 CSI模型

CSI描述了信号在每条通信链路传输路径上的衰弱因子,包含传输过程中受到物理环境(如反射、衍射和散射)的影响。当前的Wi-Fi协议标准,例如本文中采用的IEEE 802.11n/ac在其物理层中使用正交频分调制(OFDM, orthogonal frequency division multiplexing)并且是支持多输入多输出(MIMO, multiple-input multiple-output)的传输<sup>[5]</sup>。本文实验使用AtherosCSI工具对Wi-Fi信号进行采集,整个系统工作于40 MHz 114个子载波的Wi-Fi标准下,包括2根发射天线、3根接收天线。在这种情况下,采集到的原始CSI流为4维的复数矩阵,  $\mathbf{H} \in \mathbf{C}^{T \times N_r \times N_t \times N_{sc}}$ , 其中 $T$ 是时间维度,  $N_r$ 是接收天线数量,  $N_t$ 是发射天线数量,  $N_{sc}$ 则是子载波数量。在频域内,将具有多发射和多接收天线的信道建模为

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{N} \quad (1)$$

其中,  $\mathbf{Y}$ 和 $\mathbf{X}$ 分别为接收的和传输的信号向量,  $\mathbf{H}$ 为信道矩阵,  $\mathbf{N}$ 表示为信道噪声向量。CSI所描述的信道频率响应可以表示为

$$\mathbf{H}(f; t) = \sum_n^N a_n(t) e^{-j2\pi f \tau_n(t)} \quad (2)$$

其中,  $a_n(t)$ 是第 $n$ 条路径上的幅度衰减因子,  $\tau_n(t)$ 是第 $n$ 条路径上的传播时延,  $f$ 是载波频率,  $N$ 表示多路径数。因此,该接收信号可以描述为

$$\mathbf{Y}(f; t) = \mathbf{H}(f; t) \cdot \mathbf{X}(f; t) + \mathbf{N}(f; t) \quad (3)$$

其中,  $\mathbf{X}(f; t)$ 为频率为 $f$ 和时间为 $t$ 时的发射信号,  $\mathbf{Y}(f; t)$ 为对应的接收信号,  $\mathbf{N}(f; t)$ 为对应的接收机噪声。

### 2.2 问题建模分析

由于CSI通常对Wi-Fi收发器的部署和周围环

境的部署很敏感,本文将特定的设备部署和房间视为源域场景,而相对于源域场景的设备部署或者房间环境发生任何重大变化都将视为一个新的目标域场景,同时考虑了房间变化的情况以及视距(LOS, line of sight)和非视距(NLOS, non-line-of-sight)下Wi-Fi设备位置变化的情况。

小样本学习是元学习在监督学习领域的应用,利用以往的知识经验来指导新任务的学习,是解决标注样本匮乏问题常用的方法之一。在元学习问题中,将采集的CSI数据根据来源分为源域数据集和目标域数据集,令源域数据集为  $S = (D_s^{\text{train}}, D_s^{\text{test}})_{s=1}^S$ , 其中  $D_s^{\text{train}} = (x_i, y_i)_{i=1}^I$  是训练集, 包含大量的标注样本,  $D_s^{\text{test}} = (x_j, y_j)_{j=1}^J$  则是测试集; 目标域数据集为  $T = (D_t^{\text{train}}, D_t^{\text{test}})$ , 其中  $D_t^{\text{train}} = (x_p, y_p)_{p=1}^P$  是训练集, 包含少量的标注样本,  $D_t^{\text{test}} = (x_q, y_q)_{q=1}^Q$  是测试集。对于测试集中有 $N$ 类标签, 每类中有 $K$ 个标注样本的数据集, 基于数据的分类任务可称为 $N$ -way  $K$ -shot小样本分类任务。

为了降低跨场景跌倒检测系统的复杂度,可利用迁移学习将网络模型从源域数据中学习到的先验知识迁移到新的场景中。为此本文从源域和目标域中的4个不同场景分别采集了一定数量的4种动作(跌倒、坐着、步行和坐下),源域数据集中的  $D_s^{\text{train}}$  和  $D_s^{\text{test}}$  分别用于训练和测试。源域中的预训练过程可以使网络不断最小化CSI特征提取器的损失,从而寻找基于参数 $\phi$ 最佳的嵌入函数,  $\phi$ 的训练过程可以表述为

$$\phi = \arg \min_{\phi} L^{\text{ce}}(D_s^{\text{train}}; \phi) \quad (4)$$

其中,  $L^{\text{ce}}$ 为源域数据与其相应标签之间的交叉熵损失函数。接着利用测试集  $D_s^{\text{test}}$  中未带标注的样本来评估该网络的性能。

在源域中获得CSI特征提取器 $\phi$ 后,本系统特征提取器某个中间层的输出作为训练目标域分类器的特征。在目标域中,实验设置了4-way  $K$ -shot的分类任务,即  $D_t^{\text{train}}$  中包含的4类动作数据,其中每类动作包含 $K$ 个样本,实验中 $K$ 取1或5或15,  $D_s^{\text{test}}$ 是剩余的样本。由于  $D_t^{\text{train}}$  中仅包含非常有限的标注样本,本文使用一个由 $\theta$ 参数化的轻量级分类器(包括LR、SVM和 $K$ 最近邻(KNN,  $K$ -nearest neighbor)),利用  $D_t^{\text{train}}$  中的少量标注样本来最小化

交叉熵损失， $\theta$  的训练过程可以表述为

$$\theta = \arg \min_{\{W, b\}} \sum_{p=1}^P L^{\text{ce}}(W f_{\phi}(x_p) + b, y_p) + R(W, b) \quad (5)$$

其中， $W$  是权值， $b$  是偏置项， $R$  是正则项。最后，利用剩余样本  $D_s^{\text{test}}$  测试小样本分类的分类性能。

### 3 系统框架

#### 3.1 系统概述

FDFL 框架如图 1 所示，主要由源域的元训练模块和目标域的元学习模块组成。元训练模块主要包含数据预处理部分和分类训练部分。数据预处理分为 CSI 幅度预处理和 CSI 相位预处理，包括 4 个部分：收集、归一化、去噪、分段。这个环节能够有效地对原始数据进行去噪，并且截取出动作相关的部分，为后续模型的训练提供样本输入。分类训练阶段利用源域的样本先训练出一个先验模型  $f_{\theta}$ ，先验模型的目标是用于提取目标域数据的特征，生成低维度的特征图。元学习模块在得到了分类训练的特征编码器  $f_{\theta}$  情况下，从目标域中采样  $N$ -way  $K$ -shot 的任务进行有效的特征提取，降低了对目标域训练数据量的需求，在目标域中利用小样本即可实现优秀的分类性能。

#### 3.2 数据预处理

从 CSI 中提取的幅度数据存在环境噪声干扰，需要通过滤波处理去除噪声影响；相位数据存在随机相位偏移，需要进行相位校准。

#### 3.2.1 CSI 幅度数据预处理

CSI 幅度是跌倒的稳健指标<sup>[15-17, 32]</sup>，由于受硬件和物理环境的影响，原始 CSI 测量数据中的幅度测量值通常是非常嘈杂的。对此需要通过预处理降低噪声干扰，降低噪声对后续特征提取模型造成的过拟合问题，获取更精确的跌倒等动作的信号特征。具体幅度数据预处理过程如下，CSI 幅度数据预处理如图 2 所示。

**步骤 1** 对每一对收发天线对的数据进行基于层的标准化处理，此时数据矩阵大小为  $T_w \times N_{sc}$ ，再将天线对数与子载波数合并到同一个维度，生成矩阵大小为  $T_w \times (N_{rt} \times N_{sc})$  的数据。标准化后的幅度数据为

$$\overline{H_{amp}} = \frac{H_{amp} - \mu_{amp}}{\sigma_{amp}} \quad (6)$$

其中， $H_{amp}$  和  $\overline{H_{amp}}$  分别为某一通道标准化前后的幅度矩阵， $\mu_{amp}$  和  $\sigma_{amp}$  分别为幅度矩阵的均值和标准差。

**步骤 2** 对生成矩阵大小为  $T_w \times (N_{rt} \times N_{sc})$  的数据做保留贡献度为 0.9 的主成分分析，保留方差较大的  $K$  个有用信号成分，消除掉其他方差较小的噪声成分。满足条件的最小  $K$  值为

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{\text{approx}}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} = 1 - \frac{\sum_{i=1}^K S_{ii}}{\sum_{i=1}^m S_{ii}} \leq t \quad (7)$$

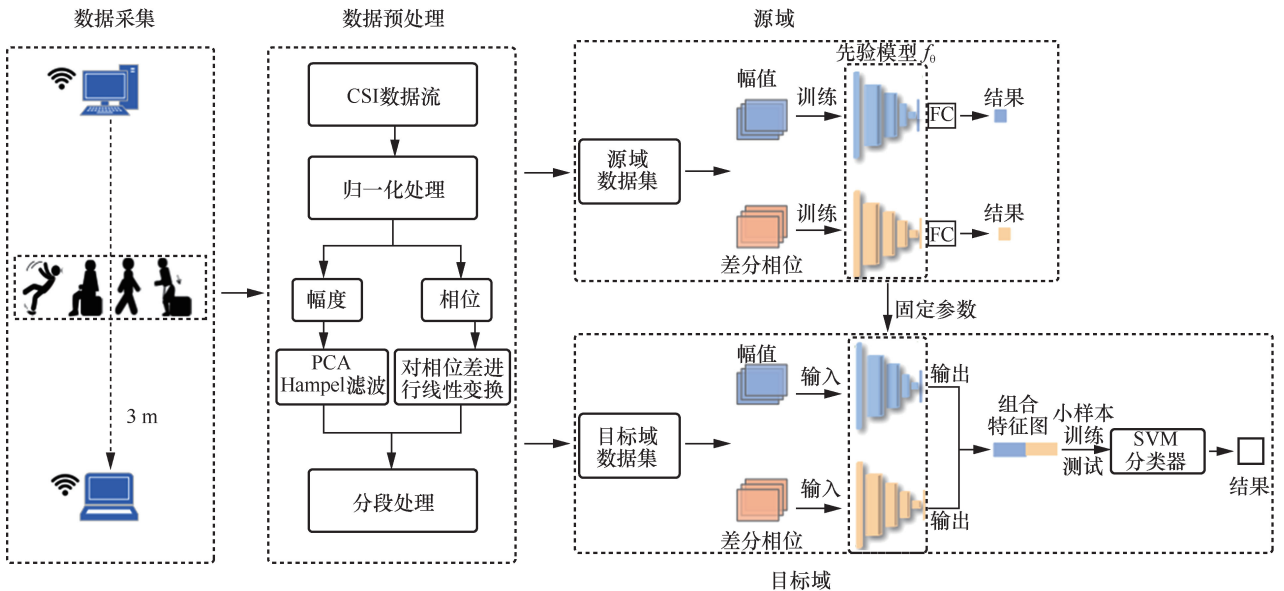


图 1 FDFL 框架




图2 CSI幅度数据预处理

均方投影误差为  $\frac{1}{m} \sum_{i=1}^m x^{(i)} - x_{\text{approx}}^{(i)2}$ ，其中  $x_{\text{approx}}^{(i)}$  为映射值；数据的总变化为  $\frac{1}{m} \sum_{i=1}^m x^{(i)2}$ ；计算协方差矩阵为  $\text{Sigma} = \frac{1}{m} \sum_{i=1}^m (x^{(i)}) \cdot (x^{(i)})^T$ 。

利用奇异值分解求解协方差矩阵的特征值： $[U, S, V] = \text{SVD}(\text{Sigma})$ ， $S$  为对角矩阵： $S = \text{diag}(S_{11}, S_{22}, \dots, S_{mm})$ 。

本文  $t$  值取 0.1，即表示该主成分分析保留了 90% 的主要信息，目的是在保留尽可能多信息的前提下降低维度。

**步骤 3** 对每对收发天线对中的 114 个子载波上的样本进行 Hampel 滤波以消除峰值和离群值，利用长度为 10 的滑动窗口依次计算子载波上数据点与窗口内的数据中值的差值，如果超过阈值与标准差的积时，该窗口内的数据中值就会代替区间上的异常点。

**步骤 4** 通过均方差的选取保留方差最大的 15 个子载波。

**步骤 5** 最后进行数据分段，按照固定的时间窗口对含有动作（跌倒、坐着、步行、坐下）的区间进行截取，可以得到最终分段数据的矩阵大小为  $N_{\text{rt}} \times T_w \times N_{\text{sc}}$ 。

### 3.2.2 CSI 相位数据预处理

从 CSI 数据流的变化来看，两个天线对之间的相

位差的方差是每个天线上的个体方差之和<sup>[5]</sup>，相位差对环境变化非常敏感。但原始 CSI 相位信息中包含了载波频率偏移（CFO, carrier frequency offset）和采样时间偏移（STO, sampling time offset）这两种主要的噪声，由于 Wi-Fi 网卡中的不同天线共享相同的射频振荡器，它们的时变相位偏移是相同的。那么通过式(8)计算收发天线对之间的相位差，可以有效消除相位误差。

$$\begin{aligned} \theta_{11} &= \frac{Y_1(f, t)}{Y_2(f, t)} \\ \theta_{12} &= \frac{Y_2(f, t)}{Y_3(f, t)} \\ \theta_{13} &= \frac{Y_3(f, t)}{Y_1(f, t)} \end{aligned} \quad (8)$$

其中， $\theta_{ij}$  表示第  $i$  个收发天线对与第  $j$  个收发天线对之间的相位差。

基于商用 Wi-Fi 设备获取的相位信息可靠性不是很高，发射端和接收端之间的载波频率也无法做到完全同步。通过式(9)可以有效地消除子载波上的噪声分量。

$$\psi_k = \Phi_k - a\eta_k - b = \phi_k - \frac{\phi_m - \phi_1}{\eta_m - \eta_1} \eta_k - \frac{1}{m} \sum_{j=1}^m \phi_j \quad (9)$$

其中

$$\Phi_k = \phi_k - 2\pi \frac{\eta K}{N} \delta + \beta + Z \quad (10)$$

$$a = \frac{\Phi_m - \Phi_1}{\eta_m - \eta_1} = \frac{\phi_m - \phi_1}{\eta_m - \eta_1} - \frac{2\pi}{N} \delta \quad (11)$$

$$b = \frac{1}{m} \sum_{j=1}^m \Phi_j = \frac{1}{m} \sum_{j=1}^m \phi_j - \frac{2\pi\delta}{mN} \sum_{j=1}^m \eta_j + \beta \quad (12)$$

其中， $\Psi_k$  是经过线性变化校准后的相位， $K$  是子载波数， $\Phi_k$  是解卷绕之后的相位， $\phi_k$  是原始相位， $\delta$  是定时误差偏移（时延）， $\beta$  是设备引起的随机相位偏移， $Z$  是测量过程中的随机噪声， $\phi_m$  是第  $m$  个子载波的相位， $\eta_k$  是子载波索引， $\eta_m$  是第  $m$  个子载波， $N$  为快速傅里叶变换（FFT, fast Fourier transform）点数， $N = 128$ 。

CSI 相位数据预处理如图 3 所示，处理后的相位在时间上的变化能够反映动作的变化。后续对相位的处理类似于对幅度的处理，保留方差最大的 15 个子载波，按照固定的时间窗口进行截取，得到最终分段数据的矩阵大小为  $N_{\pi} \times T_w \times N_{sc}$ ，其中  $N_{\pi} = 3$ ， $T_w = 600$  是截取窗口大小， $N_{sc} = 15$ 。采集到的数据经过上述预处理后，将多个样本数据组合成 4 维矩阵  $N_s \times 3 \times 600 \times 15$ ，其中  $N_s$  是样本数，为了便于后续的训练，将数据格式重构为  $(N_s \times 15) \times 3 \times 25 \times 24$ ，对每个样本打标签并将样本保存为  $(x_i, y_i)$ ，其中  $x_i = (\mathbf{H}_i^{amp}, \mathbf{H}_i^{phd})$ ， $\mathbf{H}_i^{amp}$  为处理后的幅值矩阵， $\mathbf{H}_i^{phd}$  为处理后的相位差矩阵，

$y_i$  为标签。

### 3.3 特征提取器训练

迁移学习能够把在源域预训练的模型参数迁移到新的目标域中来帮助模型训练，在样本数不足的目标域，利用源域和目标域数据间存在的联系通过知识迁移帮助目标域分类网络识别新数据。从而在深度学习中，模型可以自动提取目标域中深层次特征并随着场景的变化和网络的迭代而进行更新。因此在元训练阶段，首先利用源域数据集中充足的样本训练出 CSI 特征提取器，模型参数用  $\phi$  表示，其中包含两个结构相同又相互独立的子模型。在训练完成之后，通过冻结网络来固定参数，保存训练后的模型。由于两个子模型的结构和参数相同，以幅度为例，FDL 的 CNN 特征提取器模型结构如图 4 所示，该模型是由 4 个卷积块和 1 个全连接层组成的二维 CNN。其中，每个卷积块包含 16 个卷积核，每个卷积核尺寸为  $2 \times 2$ ，1 个批量标准化层和 1 个 ReLU 激活函数，以及 1 个池化层。分别用来处理幅度和相位差的参数为  $\phi_{amp}$   $\phi_{phd}$ ，它们的训练过程如下。

$$\phi_{amp} = \arg \min_{\phi_{amp}} L^{ce}(D_S^{\text{train\_amp}}, \phi_{amp}) \quad (13)$$

$$\phi_{phd} = \arg \min_{\phi_{phd}} L^{ce}(D_S^{\text{train\_phd}}, \phi_{phd}) \quad (14)$$




图 3 CSI 相位数据预处理

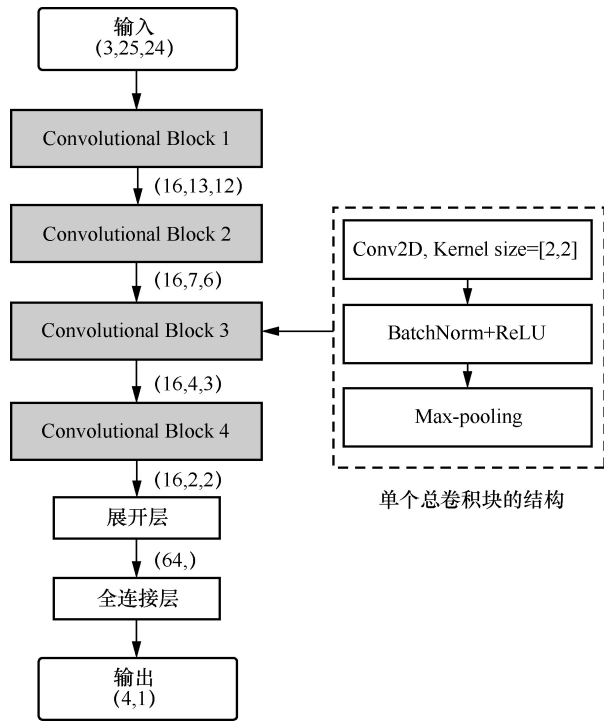


图4 CNN 特征提取器模型结构

### 3.4 跨域小样本学习

由于 CSI 分布对外界环境非常敏感，场景发生变化时如果仍然使用源域数据训练的分类器，其分类性能可能急剧下降。为此本文设计了基于 CSI 小样本学习的场景鲁棒性跌倒检测系统，借助元学习的方法实现跨域知识迁移、降低目标域分类的难度、提高模型的鲁棒性。在目标域测试仅依赖目标域中少量标注样本对预训练模型进行重新训练，便可作为新场景下的 CSI 特征提取器，通过轻量级分类器可实现准确的跌倒检测。CNN 中训练样本的数据维数变化如图 5 所示。

输入的幅度和相位差经过 CNN 处理，可以在降低维度的同时获取不同维度的特征图。经过充分的实验后，发现取第 3 个卷积块的输出得到的特征图分类效果最佳，将其展开成  $1 \times 192$  ( $192=16 \times 4 \times 3$ ) 大小的一维特征向量。在目标域使用轻量化分类器(如 LR、SVM 和 KNN)对所得到的幅度和相位联合特征作为分类器输入

进行训练。该轻量级网络是由  $\theta = \{W, b\}$  参数化。本文使用目标域的小样本训练数据集来最小化交叉熵损失

$$f_{\phi}(x_P) = (f_{\phi_{amp}}(x_{P\_amp}), f_{\phi_{phd}}(x_{P\_phd})) \quad (15)$$

$$y_P = (y_{P\_amp}, y_{P\_phd}) \quad (16)$$

$$\theta = \arg \min_{\{W, b\}} \sum_{p=1}^P L^{\text{ce}}(W f_{\phi}(x_p) + b, y_p) \quad (17)$$

其中， $x_{P\_amp}$  和  $x_{P\_phd}$  分别表示目标域训练集的幅度和相位差样本信息， $y_{P\_amp}$  和  $y_{P\_phd}$  为各自相对应的标签。最后，利用剩余的样本  $D_s^{\text{test}}$  评估小样本分类的性能。

## 4 实验评价分析

### 4.1 实验布置

本实验使用一台内置两根发射天线的笔记本电脑作为发射机，使用一台外接 3 根接收天线的台式计算机作为接收机，这两个设备都配置了 Atheros 802.11n 网卡 (AR9580/AR9382) 进行通信。发射机和接收机设备之间的距离约为 3 m，高度距离地面约为 1 m，以确保较大的环境覆盖。同时，这两个设备的运行系统都是 Ubuntu14.04，并且在接收端使用 Atheros CSI 工具<sup>[33]</sup>收集 CSI。设备中设置的网卡工作频段都是在 2.4 GHz 的频段上，信号的采样速率设置为 100 pkt/s，占用 40 MHz 的带宽，有 114 个子载波。

实验中不同环境的训练数据集由 5 名实验人员收集，不同环境的测试数据集由该 5 名实验人员之外的实验人员甲进行收集。训练和测试数据集包含相同的人体动作，包括跌倒（包含前后左右 4 个方向）、坐着、步行和坐下 4 个动作，每个动作都在 10 s 内完成，且实验人员允许在区域（图中绿色方框）内随机选择位置完成相应的动作。为了检验在不同场景下的跨域性能，实验选取两个布局差异明显的房间进行：空旷的会议室和布局紧凑的办公




图5 CNN 中训练样本的数据维数变化

室，包括 LOS 和 NLOS 的 4 个场景。这里的 LOS 是指收发端的直射路径被实验人员的动作遮挡，而 NLOS 则是指实验人员的动作不影响收发端的直射路径。

本文将“域”定义为服从某种联合分布的 CSI 观测数据和其对应行为动作（如跌倒）构成的集合，对应某种特定的设备部署、房间背景和实验人员等环境因素的组合。当由于其中任意一个环境因素（如房间背景）产生变化造成的联合分布发生显著变化，称其为“不同的域”。在本文研究的小样本学习问题中，将给定的一个环境因素组合下的数据集称为“源域”，而对另一个不同环境因素组合下待检测分类的数据集称为“目标域”，将基于源域得到的检测模型应用到目标域的行为称为“跨域检

测”。为了方便表述而不引起歧义，本文中“跨场景”与“跨域”表意相同，可互换使用。

两个房间采集实验数据的 4 个场景，包含 LOS 和 NLOS 如图 6 所示，为了防止其他干扰，实验场景仅一人在场。场景 A 为常见的室内场景，收集实验人员在视距环境下做出不同动作的数据作为源域数据，在场景 A 收集了每个实验人员的每个动作各 60 次。通过改变收发设备摆放的位置、更换实验人员以及更换房间来收集目标域数据，目标域一共有 3 个目标场景即场景 B、C 和 D，分别在这 3 个目标场景收集了每个实验人员的每个动作各 20 次，其中场景 A 和场景 B 是在同一个房间，场景 C 和场景 D 在同一个房间。每个场景中不同动作的实验样本数量见表 1。

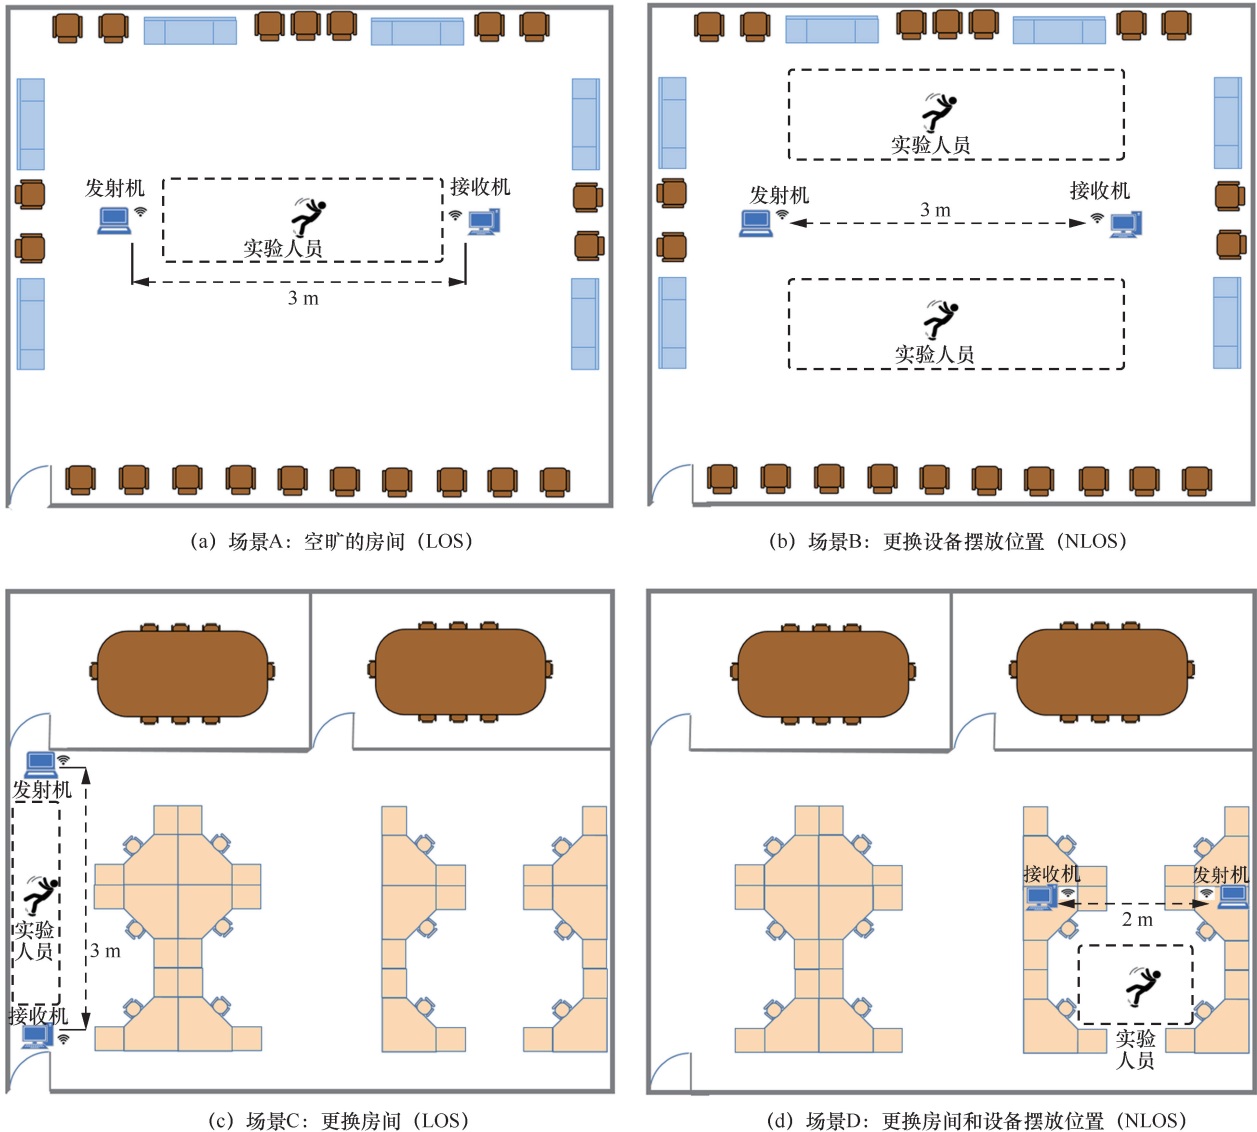


图 6 两个房间采集实验数据的 4 个场景，包含 LOS 和 NLOS

**表 1** 每个场景中不同动作的实验样本数量

房间	场景 A				场景 B				场景 C				场景 D			
动作类型	跌倒	坐着	步行	坐下	跌倒	坐着	步行	坐下	跌倒	坐着	步行	坐下	跌倒	坐着	步行	坐下
实验次数	300	300	300	300	120	120	120	120	120	120	120	120	120	120	120	120

**4.2 跌倒检测分类**

在目标域的跌倒检测过程中，每次选取一位实验人员的样本数据依次进行测试并记录结果。在目标域的分类训练过程中，从目标域中采样  $N$ -way  $K$ -shot 的任务进行有效的特征提取，得到输出的幅值和相位差的特征图。例如，5-shot 可以表示为从

某一目标域（如场景 C）中实验人员甲的 4 类动作，每类采集 5 个标注样本的数据集作为目标域的训练样本。在分类器模型的选择上，本文对比了 3 种目标域分类器：LR、SVM 和 KNN，不同环境下使用 LR、SVM 和 KNN 的目标域分类器的精度见表 2~表 4，结果显示出 3 种机器学习分类器具有相似的

**表 2** 不同环境下使用 LR 的目标域分类器的精度

		源域场景 A→目标域场景 A	场景 A→场景 B	场景 A→场景 C	场景 A→场景 D	平均值
1-shot	二分类	0.791 0	0.801 0	0.923 1	0.867 6	0.845 7
	三分类	0.720 2	0.701 2	0.818 6	0.780 9	0.755 2
	四分类	0.661 4	0.636 3	0.658 7	0.837 9	0.698 6
5-shot	二分类	0.859 3	0.867 8	0.979 7	0.993 9	0.925 2
	三分类	0.864 4	0.858 8	0.901 1	0.892 5	0.879 2
	四分类	0.850 8	0.828 8	0.905 2	0.884 8	0.867 4
15-shot	二分类	0.947 4	0.943 5	1.000 0	1.000 0	0.972 7
	三分类	0.935 0	0.941 7	0.983 6	0.942 4	0.950 7
	四分类	0.922 8	0.927 2	0.961 9	0.978 4	0.947 6

**表 3** 不同环境下使用 SVM 的目标域分类器的精度

		源域场景 A→目标域场景 A	场景 A→场景 B	场景 A→场景 C	场景 A→场景 D	平均值
1-shot	二分类	0.607 0	0.632 1	0.755 9	0.858 2	0.713 3
	三分类	0.600 9	0.635 5	0.662 1	0.747 3	0.661 5
	四分类	0.557 7	0.586 1	0.618 4	0.669 2	0.607 9
5-shot	二分类	0.862 7	0.906 8	0.994 9	0.947 5	0.928 0
	三分类	0.852 0	0.861 0	0.896 6	0.900 5	0.877 5
	四分类	0.838 1	0.854 2	0.905 2	0.900 4	0.874 5
15-shot	二分类	0.963 9	0.943 5	1.000 0	0.999 4	0.976 7
	三分类	0.958 0	0.947 5	0.983 1	0.972 7	0.965 3
	四分类	0.955 3	0.926 3	0.957 1	0.982 0	0.955 2

**表 4** 不同环境下使用 KNN 的目标域分类器的精度

		源域场景 A→目标域场景 A	场景 A→场景 B	场景 A→场景 C	场景 A→场景 D	平均值
1-shot	二分类	0.791 0	0.801 0	0.923 1	0.867 6	0.845 7
	三分类	0.705 7	0.674 5	0.820 9	0.773 0	0.743 5
	四分类	0.666 4	0.632 1	0.670 7	0.825 5	0.698 7
5-shot	二分类	0.883 1	0.910 2	0.925 4	0.959 8	0.919 6
	三分类	0.866 7	0.822 6	0.849 4	0.907 0	0.861 4
	四分类	0.831 4	0.847 5	0.852 2	0.895 5	0.856 7
15-shot	二分类	0.956 8	0.929 9	0.996 5	0.987 6	0.967 7
	三分类	0.941 8	0.909 0	0.975 8	0.969 2	0.949 0
	四分类	0.946 5	0.912 3	0.952 4	0.935 7	0.936 7

性能, LR 分类器的检测准确率与 SVM 分类器的检测准确率不相上下, 均略优于 KNN 分类器。为了测量多种的人类活动对跌倒检测的影响, 本文在实验中依次增加了不同的动作类型, 分别有以下 3 种情况。

- 二分类: 采用志愿者在可活动的范围内跌倒和坐着的数据。
- 三分类: 采用志愿者在可活动的范围内跌倒、坐着和步行的数据。
- 四分类: 采用志愿者在可活动的范围内跌倒、坐着、步行和坐下的数据。

表 2~表 4 分别显示了在以上 3 种情况下, 不同场景中 1-shot、5-shot 和 15-shot 的结果, 为了方便起见, 用→来表示实验中环境的变化, 如源域场景 A→目标域场景 A 表示使用源域场景 A 中训练的 CSI 特征提取器模型对目标域场景 A 收集的测试数据进行小样本学习并分类等。

为了进一步体现迁移学习达到的精确分类效果, 本文进行了无迁移学习情况下的对比实验, 即利用源域训练的 CSI 特征提取器模型参数, 在目标域不做元学习训练的情况下, 将目标域的数据直接输入进行分类测试, 四分类的平均准确率仅达到 16.67%。从实验结果可知, 在不进行迁移学习的情况下, 由于 CSI 分布对外界环境非常敏感, 场景发生变化时如果仍然使用源域数据训练的分类器, 其分类性能会急剧下降。在不采用小样本学习方法的情况下, 将目标域的数据分为训练集和测试集, 利用目标域的训练集数据对源域训练出的 CSI 特征提取器模型参数进行微调, 分类精度仍然可以达到很高, 但需要较长的实验时间, 并且在目标域需要预先收集大量的样本, 这不符合跌倒检测系统的实际应用。为此本文设计了基于 CSI 小样本学习的场景鲁棒性跌倒检测系统, 仅依赖目标域中少量标注样本对预训练模型进行重新训练, 便可作为新场景下的 CSI 特征提取器, 通过轻量级分类器可实现准确的跌倒检测。

#### 1) 相同场景、不同人 (相同的 LOS 环境)

训练数据集和测试数据集是在同一环境中由不同的实验人员采集, 为了评估 FDFL 的跌倒检测与个体差异的兼容性。本文利用场景 A (空旷的房间) 采集的 5 个实验人员的数据预训练 CSI 特征提取器, 将少量带标注实验人员甲的数据对特征提取器进行微调, 并测试 1-shot、5-shot 和 15-shot 3 种情况下跨场景跌倒检测系统的效果。在整个过程中严格保持整个

实验环境不变, 包括天线对之间的距离、同组外置天线的间距、桌椅摆放位置等。以 SVM 作为分类器为例, 从表 3 中的源域场景 A→目标域场景 A 可以看出在 5-shot 的情况下四分类的准确率为 83.81%, 随着 shot 数量的增多, 准确率增加, 在 15-shot 时, 仅检测跌倒和非跌倒二分类的情况下可以达到 96.39% 的检测精度, 在四分类中检测精度可达到 95.53%。

#### 2) 不同人且改变设备位置 (NLOS)

训练数据集和测试数据集由不同的实验人员采集, 测试数据是在场景 A 所在房间的基础上改变了天线对的摆放位置, 并在非视距下进行收集的, 如图 6(b)所示。为了评估视距和非视距环境下对跌倒检测器的影响。本文利用在场景 A 中训练的 CSI 特征提取器对实验人员甲在场景 B 中采集的数据进行测试。从表 3 中的场景 A→场景 B 实验结果可以看出 NLOS 环境下 5-shot 的四分类准确率为 85.42%, 在 15-shot 时, 仅检测跌倒和非跌倒二分类的情况下准确率为 94.35%, 四分类的准确率为 92.63%, 与 LOS 情况下的分类性能一致。

#### 3) 不同房间、不同人 (LOS)

训练数据集和测试数据集由不同的实验人员在不同的房间进行采集, 其中测试数据是在另一个空旷的房间的 LOS 环境下收集的, 如图 6(c)所示。为了评估本文提出的 FDFL 与不同环境的兼容性。CSI 特征提取器仍然使用的是在场景 A 中训练的, 用于测试实验人员甲在场景 C 采集的数据。从表 3 中的场景 A→场景 C 实验结果可以看出在所提 FDFL 中更换实验房间对分类准确率影响甚微, 在仅检测跌倒和非跌倒二分类的情况下 15-shot 时的检测精度可以达到 100%, 而在四分类时准确率可达 95.71%, 甚至高于原房间的准确率, 这是由散射信号加持作用形成的, 第 4.3 节对这一现象进行了详细的解释。

#### 4) 不同房间、不同人且改变设备位置 (NLOS)

训练数据集和测试数据集由不同的实验人员在不同的房间进行采集, 其中测试数据是在另一个空旷的房间的 NLOS 环境下收集的, 如图 6(d)所示。为了评估在不同房间的 LOS 和 NLOS 环境下对 FDFL 的影响。本文利用场景 A 的数据训练得到的 CSI 特征提取器对场景 D 中采集的数据进行测试。从表 2 的场景 A→场景 D 实验结果可以看出 FDFL 在不同房间的 NLOS 环境下仍然可以保持相同的准确率。以 SVM 作为分类器、在 15-shot 的情况下, 四分类准确率可达 98.20%, 在二分类情况下可达 99.94% 的准确率。

### 4.3 讨论和分析

在进行跌倒检测实验过程中，由于人体的运动阻挡了接收机与发射机之间的直接视距路径或非视距路径，或者造成主衍射波的能量衰减时，接收机可以通过接收地面反射和周围物体散射的信号来提高接收信号的强度。这也就很好地解释了当实验环境从空旷房间换成拥挤的房间时，分类准确率反而有所提高的情况。

在场景 A→场景 C 的 15-shot 中，分别使用 LR、SVM 和 KNN 作为轻量级分类器的分类结果如图 7 所示，可以看出，SVM 的四分类平均准确率保持在 95%左右，同时动作种类的增加并没有对准确率产生太大的影响。在场景 C 中的四分类 15-shot 情况下，分别使用 LR、SVM 和 KNN 作为轻量级分类器时分类结果的混淆矩阵如图 8 所示，可以发现，LR 和 SVM 准确率不相上下，而 KNN 的略微逊色一点。总的来看，FDFL 可以达到非常高的准确率，即将误差范围控制在 2%左右。




图 7 在场景 A→场景 C 的 15-shot 中，分别使用 LR、SVM 和 KNN 作为轻量级分类器的分类结果




图 8 在场景 C 中的四分类 15-shot 情况下，分别使用 LR、SVM 和 KNN 作为轻量级分类器时分类结果的混淆矩阵

### 5 结束语

本文基于小样本学习思想提出了一个无线环境下场景鲁棒性跌倒检测系统 (FDFL)，它主要用于检测室内单人跌倒事件。本系统主要包含源域的元训练阶段和目标域的元学习阶段，其中元训练阶段主要由数据预处理部分和预训练特征提取器部分。利用在源域环境预训练的 CNN 作为迁移学习的载体，搭建起已知环境与陌生环境的桥梁，通过迁移学习知识帮助目标域分类网络识别新数据，降低目标域的分类难度。同时提出使用小样本学习的方法，将迁移学习和小样本学习相结合，在有限的标注样本中充分挖掘关键特征，从而提高跨域检测系统的鲁棒性，只需要新场景下的 15 个样本，即可以训练出针对新场景的性能优异的轻量级分类器，解决了机器学习模型、深度学习模型迁移到新场景下性能下降的鲁棒性问题，小样本学习还一定程度上避免了模型在新场景应用过程中的数据采集难、训练难等问题。在同时考虑鲁棒性和数据收集困难情况下，本文采用小样本学习方法很好地解决了这些问题，实验结果表明，在不同的跨域场景下，包含 4 种动作的跌倒检测准确率可达到 95% 以上。

#### 参考文献:


- [1] 预防老年人跌倒健康教育核心信息[J]. 江苏卫生保健, 2022(2): 50-52.  
Prevention of falls in the elderly health education core information[J]. Jiangsu Health Care, 2022(2): 50-52.
- [2] HU Y Q, ZHANG F, WU C S, et al. DeFall: environment-independent passive fall detection using Wi-Fi[J]. IEEE Internet of Things Journal,

- 2022, 9(11): 8515-8530.
- [3] WANG Y X, WU K S, NI L M. WiFall: device-free fall detection by wireless networks[J]. *IEEE Transactions on Mobile Computing*, 2017, 16(2): 581-594.
- [4] ZHANG D Q, WANG H, WANG Y S, et al. Anti-fall: A non-intrusive and real-time fall detector leveraging CSI from commodity Wi-Fi devices[C]//*Proceedings of International Conference on Smart Homes and Health Telematics*. Cham: Springer, 2015: 181-193.
- [5] WANG H, ZHANG D Q, WANG Y S, et al. RT-fall: a real-time and contactless fall detection system with commodity Wi-Fi devices[J]. *IEEE Transactions on Mobile Computing*, 2017, 16(2): 511-526.
- [6] PALIPANA S, ROJAS D, AGRAWAL P, et al. FallDeFi[J]. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2018, 1(4): 1-25.
- [7] THAMMASAT E, CHAICHARN J. A simply fall-detection algorithm using accelerometers on a smartphone[C]//*Proceedings of 5th 2012 Biomedical Engineering International Conference*. Piscataway: IEEE Press, 2013: 1-4.
- [8] KHALILI A, SOLIMANAH, ASADUZZAMANM, et al. Wi-Fi sensing: applications and challenges[J]. *The Journal of Engineering*, 2020, 2020(3): 87-97.
- [9] PATWARI N, WILSON J, ANANTHANARAYANAN S, et al. Monitoring breathing via signal strength in wireless networks[J]. *IEEE Transactions on Mobile Computing*, 2014, 13(8): 1774-1786.
- [10] XIANG P, JI P, ZHANG D. Enhance RSS-based indoor localization accuracy by leveraging environmental physical features[J]. *Wireless Communications and Mobile Computing*, 2018(1).
- [11] ZHENG X L, WANG J L, SHANGGUANL F, et al. Design and implementation of a CSI-based ubiquitous smoking detection system[J]. *IEEE/ACM Transactions on Networking*, 2017, 25(6): 3781-3793.
- [12] KONINGS D, GRACE R, ALAM F. A stacked neural network-based machine learning framework to detect activities and falls within multiple indoor environments using Wi-Fi CSI[J]. *IEEE Sensors Letters*, 2021, 5(5): 1-4.
- [13] LIN Z Z, XIE Y C, GUO X N, et al. WiEat: fine-grained device-free eating monitoring leveraging Wi-Fi signals[C]//*Proceedings of 2020 29th International Conference on Computer Communications and Networks (ICCCN)*. Piscataway: IEEE Press, 2020: 1-9.
- [14] ZHANG J, WU F X, HU W, et al. WiEnhance: towards data augmentation in human activity recognition using Wi-Fi signal[C]//*Proceedings of 2019 15th International Conference on Mobile Ad-Hoc and Sensor Networks (MSN)*. Piscataway: IEEE Press, 2020: 309-314.
- [15] HE Y, CHEN Y, HU Y, et al. Wi-Fi vision: sensing, recognition, and detection with commodity MIMO-OFDM Wi-Fi[J]. *IEEE Internet of Things Journal*, 2020, 7(9): 8296-8317.
- [16] CHENG X Y, HUANG B K, ZONG J. A device-free human fall detection system based on GMM-HMM using Wi-Fi signals[C]//*Proceedings of 2021 IEEE 4th International Conference on Electronics and Communication Engineering (ICECE)*. Piscataway: IEEE Press, 2022: 87-92.
- [17] KEENANR M, TRAN L N. Fall detection using Wi-Fi signals and threshold-based activity segmentation[C]//*Proceedings of 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications*. Piscataway: IEEE Press, 2020: 1-6.
- [18] WANG Y C, YANG S, LI F, et al. FallViewer: a fine-grained indoor fall detection system with ubiquitous Wi-Fi devices[J]. *IEEE Internet of Things Journal*, 2021, 8(15): 12455-12466.
- [19] WU M J, TANG Z L. Research on user action recognition method based on parallel CNN-BiLSTM neural network[C]//*Proceedings of 2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*. Piscataway: IEEE Press, 2021: 2003-2009.
- [20] NAKAMURA T, BOUAZIZI M, YAMAMOTO K, et al. Wi-Fi-CSI-based fall detection by spectrogram analysis with CNN[C]//*Proceedings of GLOBECOM 2020 - 2020 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2021: 1-6.
- [21] CHOI H, FUJIMOTO M, MATSUI T, et al. Wi-CaL: Wi-Fi sensing and machine learning based device-free crowd counting and localization[J]. *IEEE Access*, 2022(10): 24395-24410.
- [22] LIU Z X, YUANR H, YUANY Z, et al. A sensor-free crowd counting frame work for indoor environments based on channel state information[J]. *IEEE Sensors Journal*, 2022, 22(6): 6062-6071.
- [23] TANG Z L, LIU Q Q, WU M J, et al. Wi-Fi CS Igesture recognition-based on parallel LSTM-FCN deep space-time neural network[J]. *China Communications*, 2021, 18(3): 205-215.
- [24] SCOTT R, RIDGEWAY K, MOZERM C. Adapted deep embeddings: asynthesis of methods for  $k$ -shot inductive transfer learning[C]//*Proceedings of the 32nd International Conference on Neural Information Processing Systems*. New York: ACM, 2018: 76-85.
- [25] ZHANG Y, CHEN Y, WANG Y J, et al. CSI-based human activity recognition with graph few-shot learning[J]. *IEEE Internet of Things Journal*, 2022, 9(6): 4139-4151.
- [26] MA X R, ZHAO Y N, ZHANG L, et al. Practical device-free gesture recognition using Wi-Fi signals based on meta learning[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 228-237.
- [27] SUN Q R, LIU Y Y, CHUA T S, et al. Meta-transfer learning for few-shot learning[C]//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2020: 403-412.
- [28] 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.
- [29] DING X, JIANG T, ZHONG Y, et al. Improving WiFi-based human activity recognition with adaptive initial state via one-shot learning[C]//*Proceedings of 2021 IEEE Wireless Communications and Networking Conference (WCNC)*. Piscataway: IEEE Press, 2021: 1-6.
- [30] WANG Y J, YAO L, WANG Y, et al. Robust CSI-based human activity recognition with augment few shot learning[J]. *IEEE Sensors Journal*, 2021, 21(21): 24297-24308.
- [31] WANG D Z, YANG J F, CUIW, et al. CAUTION: a robust WiFi-based human authentication system via few-shot open-set recognition[J]. *IEEE Internet of Things Journal*, 2022, 9(18): 17323-17333.
- [32] SADREAZAMI H, BOLIC M, RAJAN S. TL-FALL: contactless indoor fall

detection using transfer learning from a pretrained model[C]//Proceedings of 2019 IEEE International Symposium on Medical Measurements and Applications (MeMeA). Piscataway: IEEE Press, 2019: 1-5.

- [33] FDIDA S, PAU G, KASERA S, et al. Proceedings of the 21st annual ACM International Conference on Mobile Computing and Networking (Mobicom)[EB]. 2015.

[作者简介]



曾钰婷（1997- ），女，深圳大学电子与信息工程学院硕士生，主要研究方向为无线感知。



郑莉莉（1990- ），女，博士，深圳大学电子与信息工程学院博士后，主要研究方向为无线感知。



林晓辉（1975- ），男，博士，深圳大学电子与信息工程学院教授，主要研究方向为无人机通信网络的优化设计。



毕宿志（1987- ），男，博士，深圳大学电子与信息工程学院副教授，主要研究方向为无线通信网络资源管理、移动计算与无线感知。



王晖（1969- ），男，博士，深圳信息职业技术学院教授，主要研究方向为无线通信与信号处理。