

# 一种基于 CSI 的非合作式人体行为识别方法

李晓薇 余江 常俊 杨锦朋 冉亚鑫

(云南大学信息学院 昆明 650500)

**摘要** 目前,基于 Wi-Fi 的无线人员感知技术被广泛应用于防入侵安全监测、人类健康护理、步态识别等领域,对此提出了一种基于无设备的非合作式人体行为识别方法,利用 Wi-Fi 信号的信道状态信息 CSI 来识别 5 个动态活动:行走、坐-站、深蹲、跳跃和跌倒。该方法利用 SIMO 系统采集 CSI 数据,在对 CSI 幅度和相位分别进行预处理之后,实施 3 个步骤来降低计算开销机制:子载波融合、基于移动方差阈值的不良数据链路剔除以及基于小波变换的动态时间窗口的数据分割。在经过前期的各项预处理后提取动作特征,从时域扩展到频率域,通过分析多普勒功率谱的特性来提高 CSI 信号的利用率。实验结果表明,总体识别率随着使用特征维度的增加而上升;组合分类器加权投票方法经过两轮投票优化,把对 5 个动作的总体识别率提高到 90.3%,且相较于 RSSI,CSI 在人体行为识别领域的优势更加明显。

**关键词** 信道状态信息,非合作式,小波分析,多普勒功率谱

**中图分类号** TP391.4 **文献标识码** A **DOI** 10.11896/jsjcx.190200349

## Non-cooperative Human Behavior Recognition Method Based on CSI

LI Xiao-wei YU Jiang CHANG Jun YANG Jin-peng RAN Ya-xin

(School of Information Science and Engineering, Yunnan University, Kunming 650500, China)

**Abstract** Currently, Wi-Fi-based wireless personnel perception technology is widely used in anti-intrusion security monitoring, human health care, gait recognition and other fields, regarding this, this paper proposed a non-cooperative human behavior recognition method. The channel state information (CSI) of Wi-Fi signals can be used to recognize five dynamic activities: walking, sitting-standing up, squatting, jumping and falling. The method uses a SIMO system to collect CSI data, and after performing pre-processing on the CSI amplitude and phase respectively, implements a three-step computational cost reduction mechanism: subcarrier fusion, rejection of bad data link based on mobile variance threshold, and data segmentation of dynamic time window based on wavelet transform. Then activity features are extracted and extended from the time domain to the frequency domain. By analyzing the characteristics of the Doppler power spectrum, the utilization of the CSI signal is improved. Experiment results show that the overall recognition rate increases with the use of feature dimensions. Optimized by two rounds of voting, the combined classifier weighted voting method is increasing the overall recognition rate of five dynamic activities to 90.3%. And compared to RSSI, the advantages of CSI in the field of human behavior recognition are more prominent.

**Keywords** CSI, Non-cooperative, Wavelet analysis, Doppler power spectrum

## 1 引言

现今,人体行为识别技术主要分为两大类:合作式和非合作式。合作式人体行为识别技术主要利用可穿戴传感器等获取各种体态信息<sup>[1]</sup>,其缺点是需要随身佩戴设备,给使用者带来了一定的不便并且可能泄露个人隐私;而非合作式人体行为识别技术主要利用电磁波的传播特性进行活动识别<sup>[2]</sup>,不需要随身携带任何传感设备,增强了实用性且应用更加广泛。近年来,随着无线感知技术在各个领域的应用,从获得某人的位置坐标到识别某人在此位置的行为状态<sup>[3-4]</sup>,甚至是个人动作的步态估计<sup>[5]</sup>,无线信号实现了更细粒度的感知识别。

Wi-Fi 技术在无线感知领域的应用最为广泛,具有设备易于部署、信号易于获取的特点。Youssef 等早已运用接收信号强度(RSSI)的波动来进行被动式人体位置检测<sup>[6]</sup>;Sigg 等则把 RSSI 运用于人体活动识别领域<sup>[7]</sup>。然而,RSSI 测量的是信号多径传播的叠加效果,文献[8]表明在典型实验室环境下,一台静止的接收机在 1min 内接收到的 RSSI 可能出现 5dB 的波动,这暴露了 RSSI 信号由于多径传播而产生的稳定性差的缺点。而信道状态信息(CSI)的分辨率在子载波尺度上可以更精细地刻画多径信道。利用 Intel 5300 网卡,通过修改固件的方式,普通的 Wi-Fi 设备可以获得 30 个正交频复用子载波上的 CSI<sup>[9]</sup>。因此,利用 CSI 信号进行室内定

收到日期:2019-02-23 返修日期:2019-08-13 本文受国家自然科学基金(61162406),云南省高校频谱传感与边疆无线电安全重点实验室开放课题(C6165903),云南省教育厅科学研究基金项目(2019J0007),云南大学 2018 年研究生科研创新项目(Y2000211)资助。

李晓薇(1994-),女,硕士生,CCF 会员,主要研究领域为无线感知技术应用;余江(1961-),男,教授,硕士生导师,主要研究领域为无线通信技术、网络通信理论等,E-mail:yujiang@ynu.edu.cn(通信作者);常俊(1970-),男,副教授,硕士生导师,主要研究领域为网络通信理论、无线通信与网络等;杨锦朋(1992-),男,硕士生,主要研究领域为室内定位技术理论及应用等;冉亚鑫(1996-),女,硕士生,主要研究领域为人体行为检测技术应用。

位<sup>[10-11]</sup>及人体动作识别<sup>[12-13]</sup>成为了研究的热点。

在现有的人体行为识别研究中,文献[14]设计了基于 WLAN 的人员感知与入侵检测系统,利用了不同 CSI 相位矩阵的相似性差异,但此种使用特征值突变量的方法存在易受周围环境影响而不稳定的缺陷。文献[3]通过提取 CSI 幅度和相位的相关矩阵的最大和次大特征值来构成四维的特征向量,但识别率是否会随着特征向量的增加而有所提高还有待验证。文献[15]提出提取不同动作对应的子载波特征方差,进而采用 SRC 算法对人体行为进行分类,但该方法稳定性差,在人体活动不剧烈的情况下检测效果不理想。文献[16]为降低成本而省去了数据预处理的过程,其提取原始 CSI 数据的幅度的均值和方差作为特征,采用 SVM 进行人员感知,然而原始 CSI 数据中存在干扰信息,因此该方法的效果不理想。

针对上述问题,本文设计了一种非合作式的人体行为识别方法。相比于昂贵的软件无线电设备 USRP,本文利用易于部署的 Wi-Fi 商用网卡进行 CSI 数据的采集。针对原始幅度,本文方法通过指数滤波及 Hampel 标识符来进行降噪及异常点的剔除,再对原始相位进行线性变换和校准。因为每个数据流中的 30 个 CSI 子载波彼此高度相关,存在冗余,所以对每个数据流中的 30 个子载波进行加权平均处理,以达到降维并保持数据特性的目的。在子载波融合后,本文提出利用移动方差阈值剔除不良数据链路,并采用离散小波变换进行行为数据的分割与提取,以进一步降低计算开销;在提取 CSI 数据的时域特征之后,提出利用多普勒功率谱提取频域特征;最后采用组合分类器加权投票的方法实现人体行为识别。

## 2 CSI 数据预处理

### 2.1 CSI 数据模型

Wi-Fi 采用正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)技术,将信号调制到间隔为 312.5 kHz 的子载波上进行通信,接收端从每个数据包中获取 CSI 信息。因此,一组 CSI 信息  $\{H_k(i)\}_{k=1}^{30}$  ( $i=1,2,\dots,N$ ) 是以子载波频差为频率采样间隔对 Wi-Fi 带宽内的信道频率响应(CFR)的 30 个离散采样值,以代表子载波的幅度和相位<sup>[17]</sup>:

$$H_k(i) = \|H_k(i)\| e^{j\angle H_k(i)} \quad (1)$$

其中,  $H_k(i)$  为在采样时刻  $t_i$  ( $i \in [1, N]$ ), 每条链路中的第  $k$  个子载波的 CSI,  $\|H_k(i)\|$  和  $\angle H_k(i)$  分别为其幅度和相位。

### 2.2 幅度预处理

CSI 包含室内环境干扰及 2.4 GHz 设备引起的电磁干扰,故存在一定量的噪声,由于典型的人体运动仅引入低频变化<sup>[18]</sup>,因此可使用低通滤波器去除高频噪声。以一个子载波为例,图 1 给出了跌倒动作的原始 CSI 与经过低通滤波后的 CSI。可以看出,低通滤波器有效地消除了噪声,且不会扭曲由人体运动引起的 CSI 变化的趋势。




图 1 原始 CSI 及其经过低通滤波的对比

Fig. 1 Comparison of original CSI and after low-pass filtering

Hampel 标识符是 three-sigma 统计规则的变形,对异常值具有很强的鲁棒性,可用于消除明显非人类运动产生的突然变化。如图 2 所示,Hampel 标识符把任何落在闭区间  $[\mu - \gamma\sigma, \mu + \gamma\sigma]$  之外的点视为异常值并进行剔除,其中  $\mu$  和  $\sigma$  分别是指定长度数据的中位数和中值绝对偏差, $\gamma$  是与应用相关的参数,通常取 3<sup>[3]</sup>。




图 2 对低通滤波后的 CSI 进行异常值剔除

Fig. 2 Abnormal value culling of low-pass filtered CSI

### 2.3 相位预处理

如图 3 所示,由于随机噪声的影响以及发送端与接收端之间的时钟没有达成同步,原始相位信息在各个子载波上的分布十分随机,跌倒动作发生时和无动作发生时的 CSI 原始相位分布都无规律可循,因此原始相位信息无法直接使用。

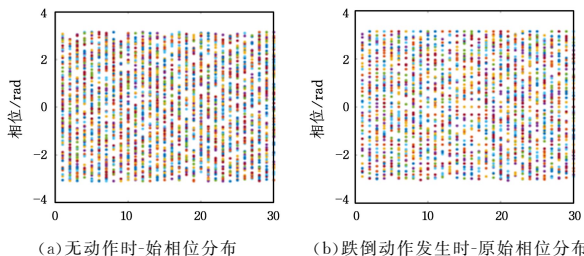


图 3 CSI 原始相位信息

Fig. 3 Raw phase information of CSI

把第  $j$  根天线上的第  $i$  个子载波的原始相位  $\hat{\phi}_i^j$  表示为:

$$\hat{\phi}_i^j = \phi_i^j - 2\pi \frac{k_i}{N} \delta + \beta_j + Z \quad (2)$$

其中,  $\phi_i^j$  表示真实相位;  $\delta$  是接收端处的时间偏移,其定义为信号到达时间和信号被检测到的时间之间的时间差,是造成相位误差的主要原因之一;  $\beta_j$  是未知的相位偏移,  $Z$  是一些测量噪声;  $k_i$  表示第  $i$  个子载波的索引。

对原始相位数据采用线性变换可消除随机相位偏移的重要组成部分,其关键思想是通过考虑整个频带的相位来消除  $\sigma$  和  $\beta$ 。首先定义  $a$  和  $b$  分别为:

$$a = \frac{\hat{\phi}_n - \hat{\phi}_1}{k_n - k_1} = \frac{\phi_n - \phi_1}{k_n - k_1} - \frac{2\pi\delta}{N} \quad (3)$$


$$b = \frac{1}{n} \sum_{j=1}^n \hat{\phi}_j = \frac{1}{n} \sum_{j=1}^n \phi_j - \frac{2\pi\delta}{nN} \sum_{j=1}^n k_j + \beta \quad (4)$$

当子载波频率对称时,可得  $\sum_{j=1}^n k_j = 0$ , 则  $b$  可表示为  $b = \frac{1}{n} \sum_{j=1}^n \phi_j + \beta$ 。从原始相位  $\hat{\phi}_i$  中减去线性项  $ak_i + b$ , 即得到一个真实相位的线性组合  $\tilde{\phi}_i$ , 此时已经消除了随机相位偏移(已忽略较小的测量噪声  $z$ ):

$$\tilde{\phi}_i = \hat{\phi}_i - ak_i - b = \phi_i - \frac{\phi_n - \phi_1}{k_n - k_1} k_i - \frac{1}{n} \sum_{j=1}^n \phi_j \quad (5)$$

图 4 给出了经过线性变换后的 30 个子载波上的 CSI 相位分布,图中描述了 100 个相同的数据包的相位信息,可以看

出,相比图3中分布随机的相位,经过线性变换后可以得到聚集性更好的相位分布。当人体行为动作发生时,其对无线网络环境造成了扰动,使得无线信号在室内的多径传播发生变化,人体行为动作发生时与无动作时形成了鲜明的对比,更好地刻画了无线信号在传播过程中的环境特征。



(a) 无动作时线性变换后的相位分布 (b) 跌倒时线性变换后的相位分布

图4 经过线性变换后的子载波相位分布

Fig. 4 Subcarrier phase distribution after linear transformation

## 2.4 降低计算开销机制

### 2.4.1 子载波数据的融合

因为每个CSI数据流中有3条链路,每条链路包含30个子载波,并且这30个子载波彼此高度相关,即CSI数据在经过降噪与异常值剔除后仍然存在冗余。为消除数据的冗余,对每条链路上的30组CSI进行加权平均,以获得有效的CSI(见图5),即利用频率分集来补偿小规模衰落效应,将功率归一化到频带内的中心频率上<sup>[19]</sup>:

$$CSI_{eff} = \frac{1}{K} \sum_{k=1}^K f_k \times \|A\|_k \quad (6)$$

其中, $K$ 表示子载波的总数; $f_c$ 表示中心频率; $f_k$ 为第 $k$ 个子载波的载波频率; $\|A\|_k$ 为第 $k$ 个子载波经过预处理后的幅度。




图5 CSI子载波融合

Fig. 5 Subcarrier fusion of CSI

### 2.4.2 不良链路的剔除

由于CSI是从具有独特空间特性的天线对收集的,因此各个链路的变化相互独立。普通链路在人体行为动作发生时有明显的幅度波动(如图5中的链路2和链路3所示),而不良链路几乎是平坦的(如图5中的链路1所示)。这种不良链路在不同的天线对中随机出现,严重影响了人体运动发生时CSI数据特征的提取,因此本文提出使用移动方差阈值法来剔除不良链路。计算移动方差的具体方法如式(7)所示:

$$CSI_{var_i} = \frac{1}{L_d - 1} \sum_{j=1}^{L_d} |CSI_j - \mu_{var_i}|^2 \quad (7)$$

$$\mu_{var_i} = \frac{1}{L_d} \sum_{j=1}^{L_d} CSI_j$$

其中, $i=1,2,\dots,N_d-L_d+1$ ;  $L_d$ 表示滑动窗口的大小,根据本文的数据特点取值为30;  $N_d$ 为采样数据包个数;  $\mu_{var_i}$ 为第 $i$ 个数据包段的窗口内数据的均值。

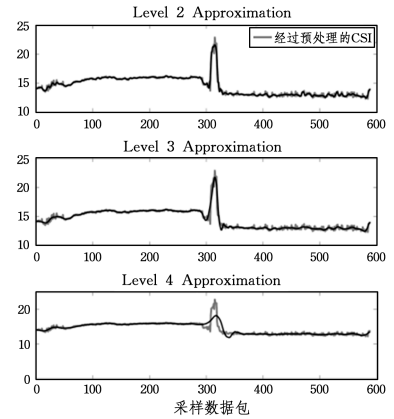
具体方法为:沿子载波融合后的各个CSI幅度链路计算移动方差,记录不良链路在滑窗内数据信号的平均值 $\mu_b$ 和归

一化标准差 $\sigma_b$ ,根据统计经验确定阈值 $\delta_b: \mu_b + 6\sigma_b \leq \delta_b$ 。通过采集各个链路滑窗中的数据并逐一计算比较,把小于阈值的链路视为不良链路,并将其剔除。



### 2.4.3 基于小波变换的动作数据分割

在对CSI原始信号进行前期预处理后,虽然消除了噪声、异常值和不良数据链路,但在人体运动的持续时间内,完整的CSI信号轨迹包含过多的静止状态,这无疑增加了计算开销。因此,需要对采集到的CSI数据进行分割,将包含人体运动的数据段分离并提取出来作为人体运动的样本,以针对不同行为动作进行特征提取。

图1给出了由于跌倒动作造成的原始CSI的明显波动,再使用小波变换就可以确定运动发生的时间点。图6给出了利用小波变换的结果来确定动态时间窗口值。



(a) 不同层数的小波变换结果



(b) 时间窗口

图6 确定动态时间窗口值的过程

Fig. 6 Process map for determining dynamic time window values

图6(a)给出了对已经经过预处理的CSI数据进行离散小波变换的结果,分别对应第二、三、四层小波分解后重构的低频信号。可以看到,在小波分解中出现了显著的峰值,本文使用基于希尔伯特变换的包络提取方法,根据小波分析的结果确定动态时间窗的宽度,提取可以覆盖运动持续时间的波峰。如图6(b)所示,在包络曲线的第三层中可以容易地找到最大波峰的左右斜率零点,可以把两个零点之间的时间视为覆盖整个跌倒动作的持续时间。这样就可以利用动态时间窗口来灵活地提取运动数据,而不需要使用固定的阈值。

### 3 CSI 特征提取及行为识别

#### 3.1 特征提取

在剔除不良链路后,人体运动会引起子载波的幅度和相位发生变化,同一条链路上的子载波的相关性较高,但也存在一定差异<sup>[2]</sup>,因此可使用在连续采样时间内采样得到的子载波间的相关性描绘 CSI 的变化,以突出不同人体行为的特征。

对于剔除不良链路后剩余的所有  $n$  个子载波上的 CSI,有:

$$H(i) = [H_1(i), H_2(i), \dots, H_n(i)] \quad (8)$$

在连续采样时间  $N$  内的 CSI 信息  $\mathbb{H} = [H(i)]_{N \times n}$ , 分别计算其幅度相位的相关矩阵  $\mathbf{A}$  和  $\mathbf{P}$ :

$$\mathbf{A} = [a(i, j)]_{N \times N}, \mathbf{P} = [p(i, j)]_{N \times N} \quad (9)$$

其中,  $a(i, j)$  和  $p(i, j)$  表示  $H(i)$  和  $H(j)$  之间的相关系数:

$$a(i, j) = \text{corr}(\|H(i)\|, \|H(j)\|) \quad (10)$$

$$p(i, j) = \text{corr}(\angle H(i), \angle H(j)) \quad (11)$$

然后分别提取幅度和相位相关矩阵的最大的 3 个特征值作为表征各个人体行为的特征:

$$\alpha = \max(\text{eigen}(\mathbf{A})) \quad (12)$$

$$\rho = \max(\text{eigen}(\mathbf{P}))$$

经过子载波数据融合后,再提取 3 个时域特征:1)归一化标准差(NSTD),以反映动态运动的规模,即较大幅度的运动

会导致较大的 NSTD;2)中值绝对偏差(MAD),用于稳定测量定量数据的单变量样本的变异性;3)四分位距(IQR),用以表示 CSI 方差的分散程度。

此外,采用多普勒功率谱来提取频域特征。假设信道可以由广义静止(WSS)过程表示,则多普勒功率谱  $D(\lambda)$  可以通过对时域 CSI 数据应用快速傅里叶变换(FFT)来获得,其中  $N_p$  为采样时间内 CSI 数据包的数量:

$$D(\lambda) = \sum_{i=1}^{N_p} (csi_i) e^{-j\frac{2\pi\lambda}{N}} \quad (13)$$

如图 7 所示,多普勒功率谱是具有零均值的对称函数,并且始终受到最大多普勒频移的限制<sup>[20]</sup>。计算多普勒功率谱的第三阶中心矩(见式(10))和第四阶中心矩(见式(11)),将其作为标识不同人体行为的特征进行提取:

$$D_{sk} = \frac{\frac{1}{N_p} \sum_{i=1}^{N_p} (csi_i - \overline{csi})^3}{\text{var}^3} \quad (14)$$

$$D_{ku} = \frac{\frac{1}{N_p} \sum_{i=1}^{N_p} (csi_i - \overline{csi})^4}{\text{var}^4} \quad (15)$$

另外,对原始 CSI 经离散傅里叶变换后各分量幅度的信息进行归一化,将其作为信息熵,以辅助分类识别:

$$E_s = - \sum_{i=1}^N p_i \ln p_i \quad (16)$$

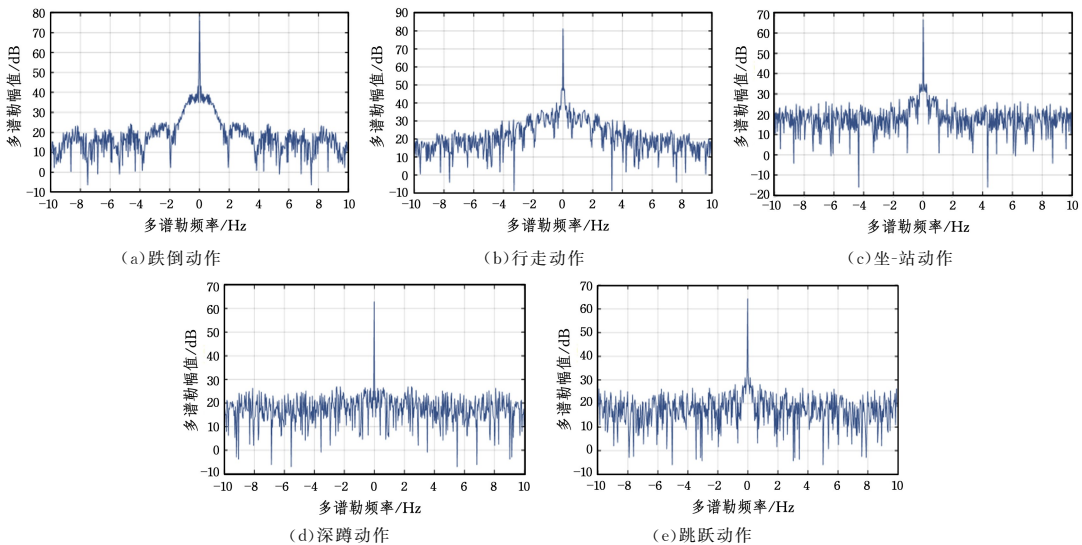


图 7 5 个运动行为的频域信息

Fig. 7 Frequency domain information of five action behaviors

#### 3.2 行为识别方法

人体行为动作的识别,实质上是对不同行为动作的分类问题,属于多元非线性分类问题,各种机器学习方法可以根据特征来实现人体行为动作的分类识别。

KNN 分类器构造简单、易于计算,但在解决多分类问题时效果不佳;朴素贝叶斯分类器数学模型简单且易于实现,但前提是需要假设理想条件,导致较难生成完全拟合的数学模型,使得分类正确率不理想;而多类支持向量机能够在二分类的支持向量机的基础上进行扩展,效果较优。除以上 3 种监督学习方法之外,各种集成学习方法通过整合多个弱学习器来获得较优的学习效果,其中 Boosting 和随机森林是典型代表。

在参数设置方面,本文根据经验把 KNN 分类器中的参数  $k$  设置为 3;在集成学习 Boosting 的 RUSBoost 算法中,基

学习器采用判别分析方法,集成学习周期为 50;在随机森林中,决策树数量为 20。

另外,组合分类器融合可以利用不同的分类器来完成不同的任务,从而避免考虑不全面的问题。考虑到不同分类器对同一样本的分类能力不同,本文采用组合分类器加权投票算法进行多种人体行为动作的分类与识别,利用上述的 5 种分类器进行投票决策,具体流程如算法 1 所示。

##### 算法 1 组合分类器加权投票算法

parameters of classifier:  $k, T, \text{NumTrees}$

Input: feature vector  $v_i$  of train set and test set

Output: recognition accuracy and confusion matrix

The first voting:

for  $i = 1, 2, \dots, N$

```

applied classifieri
get the recognition result of each classifier
for k=1,2,...,M
    if vi ∈ motionk ← classifieri
        numi = numi + 1
    end
if numi = max(num) and there are no other maximum
    vi ∈ motionk ← classifierj
else do:
Weighted voting:
if sum(Wik) > sum(Wjk)
    vi ∈ motionk ← classifieri
end
end

```

在第一轮投票中,若多个分类器对分类动作的投票结果出现了相同的最大票数,则进行第二轮加权投票,其中各分类器的权重与每个分类器对此类别动作的识别准确率呈正相关。

## 4 算法仿真及结果分析

### 4.1 实验环境的布置与实施

本实验采用配备 Intel 5300 NIC 并运行 Ubuntu 11.04 OS 的迷你台式机(装有三根接收天线)及 TL-WR742N 无线路由器(装有一根发射天线)分别作为收发设备,设置工作模式于 2.4 GHz 频段,采用 40 Mb 带宽模式。整个收发机构成一个 1 \* 3 的 SIMO 系统。如图 8 所示,数据采集实验在云南大学信息学院三幢一楼走廊中进行,实验收发设备分别置于相同高度的椅子上,距地面 45 cm。



图 8 实验场景  
Fig. 8 Experimental scene

实验邀请一名志愿者,在收发设备相距 4 m 的视距位置中间做出行走、跌倒、坐-站、深蹲和跳跃等 5 个动作,每个动作采集 200 个样本,共 1000 个样本,将其中每个动作 80% 的样本作为训练数据,剩下的 20% 作为测试数据。

### 4.2 实验整体框架

图 9 给出了本文提出的基于 CSI 的非合作式人体行为识别方法的流程图。第一阶段为 CSI 数据预处理,主要包括对幅度和相位的预处理,实验分 3 个步骤以降低计算开销的机制;第二阶段为动作特征提取,包括时域和频域特征;第三阶段为对人体行为动作的分类识别,主要利用几种监督学习方法及本文提出的组合分类器加权投票方法进行分类识别。




图 9 基于 CSI 的非合作式人体行为识别方法框图

Fig. 9 Block diagram of CSI-based non-cooperative human behavior recognition method

## 4.3 实验结果

### 4.3.1 不同分类方法的识别率对比

利用 3.1 节所述的 8 类特征(幅度相关矩阵的最大的 3 个特征值、相位相关矩阵的最大的 3 个特征值、归一化标准差、中值绝对偏差、四分位距、多普勒功率谱的第三阶中心矩、多普勒功率谱的第四阶中心矩、信息香农熵),运用 KNN 分类器、朴素贝叶斯、多类支持向量机、集成学习 RUSBoost 算法、随机森林和组合分类器加权投票方法,在本文的实验场景中对 5 种动作进行识别,总体的识别正确率分别为 71.6%, 72.5%, 85.1%, 82.4%, 85.3% 和 90.3%。

表 1 列出了运用组合分类器加权投票方法对 5 种动作进行识别的混淆矩阵,其中最高的误判率出现在跳跃动作上,而且对坐-站动作与深蹲动作的识别效果也不太理想。其原因为跳跃、坐-站和深蹲的运动方向主要集中在垂直方向上,三者的运动方向存在相似性,因而影响了分类效果。

表 1 组合分类器加权投票方法的混淆矩阵

Table 1 Confusion matrix of combined classifier weighted voting method (单位:%)

	坐-站	行走	跳跃	深蹲	跌倒
坐-站	90	0	15	4.8	5
行走	0	95.4	0	0	0
跳跃	10	0	85	9.5	0
深蹲	0	4.6	0	85.7	0
跌倒	0	0	0	0	95

实验表明,KNN 分类器和朴素贝叶斯分类器的总体分类识别效果不理想,而运用组合分类器加权投票方法可以获得更高的动作总体识别率。针对跳跃动作,在本文的实验场景中,各个机器学习方法的识别效果都不太理想,此时组合分类器加权投票方法有效地将识别正确率提高到 85%。然而,各个分类器对不同动作的识别效果也有所不同,本文中多类支持向量机对坐-站动作的识别效果最佳;KNN 分类器对行走动作的识别效果最佳;随机森林对深蹲动作的识别效果最佳;针对跌倒动作,由于其运动趋势最明显,运用随机森林和多类支持向量机的识别正确率都为 100%,这表明这两种分类识别方法对运动趋势较大的动作的特征比较敏感,在这种情况下,组合分类器加权投票方法的优势没有凸显出来。

### 4.3.2 特征维度对识别率的影响对比

图 10 给出了运用不同维度的特征对分类效果的影响,横坐标 1—8 分别对应 3.1 节所述的 8 类特征。




图 10 总体识别率随特征数量的变化

Fig. 10 Changes of overall recognition rate with features number

实验结果表明,随着特征维度的增加,各种分类方法的总体识别率有所上升,总体上组合分类器加权投票方法优于其他分类方法。特征数量对各个分类方法的影响效果不同,其中集成学习 RUSBoost 算法受到的影响最大;随着特征数量的逐渐增加,其对 5 种动作的总体识别正确率逐渐上升;特征

数量对多类支持向量机和朴素贝叶斯的分类效果的影响较大,相比只使用 3 类特征,使用 5 类特征的识别效果得到显著提升,这表明特征数量的选择对识别准确率至关重要。

#### 4.3.3 CSI 与 RSSI 的对比

文献[7]把度量信号多径传播的叠加效果的 RSSI 应用于人体行为识别领域,因此本文对同一时间段内采集的 RSSI 数据进行与 CSI 数据相同的预处理与特征提取,再运用组合分类器加权投票方法实现人体行为识别研究,结果如图 11 所示。




图 11 CSI 与 RSSI 对行为识别效果的对比

Fig. 11 Comparison of CSI and RSSI on behavior recognition

实验结果表明,在相同的实验条件下,利用 RSSI 对 5 种动作的总体识别率为 78.2%,利用 CSI 单子载波和 CSI 的 30 个子载波时总体识别率分别为 81.2%和 90.3%,与前两者相比,CSI 的 30 个子载波信息的优势得到凸显。此优势在对跳跃动作的识别中更为明显,受到采集的跳跃动作样本中不良因素的影响,结合 4.3.1 节实验结果的分析可知,利用 30 个子载波信息可使算法更具有鲁棒性,对于人体行为识别正确率的提高确实起到了积极作用。

**结束语** 目前,基于 Wi-Fi 的无线人员感知技术被广泛应用于防入侵安全监测、人类健康护理、步态识别等领域。本文研究了一种 WLAN 环境下基于信道状态信息 CSI 的非合作式人体行为识别方法。首先,对 CSI 数据进行预处理,对 CSI 幅度进行降噪及异常值剔除,并对 CSI 相位进行校准;然后,为减小数据冗余、降低计算开销,分 3 步对经过前期预处理的 CSI 进行处理,即进行子载波融合并剔除不良数据链路,之后运用小波分析提取包含运动持续时间的数据;最后,在时域及频域对动作数据进行特征提取。通过对比各种分类器的性能可知,组合分类器加权投票方法为需要较高动作总体识别正确率的场景提供了参考。对于本文方法,实验中只考虑了一个人的活动,这对于实际的人体行为识别应用来说仍无法满足需求,在将来的研究中将进一步完善实验内容。在一个场景中,如有多人同时进行活动,每个人的动作将不同程度地影响 CSI 信息变化,这些影响会相互混淆,未来需要在解析区分 CSI 信息层面寻求突破,以便使其得到更为广泛的应用。

#### 参考文献

[1] WANG L. Research on human behavior recognition technology based on wearable sensor network[D]. Nanjing: Nanjing University, 2014.

[2] WU C S, YANG Z, ZHOU Z M, et al. Non-invasive detection of moving and stationary human with Wi-Fi[J]. IEEE Journal on Selected Areas in Communications, 2015, 33(11): 2329-2342.

[3] QIAN K, WU C, YANG Z, et al. Enabling Contactless Detection of Moving Humans with Dynamic Speeds Using CSI[J]. ACM

Transactions on Embedded Computing Systems, 2018, 17(2): 1-18.

[4] ZEHUA D, FANGMIN L, JULANG Y, et al. Indoor Motion Detection Using Wi-Fi Channel State Information in Flat Floor Environments Versus in Staircase Environments [J]. Sensors, 2018, 18(7): 2177.

[5] LIU M G, ZHANG L, YANG P L, et al. Wi-Run: Device-free step estimation system with commodity Wi-Fi [J]. Journal of Network and Computer Applications, 2019, 143(1): 77-88.

[6] YOUSSEF M, MAH M. Challenges: Device-free Passive Localization for Wireless [C] // Acm International Conference on Mobile Computing & Networking. Montréal, Québec, Canada: ACM, 2007.

[7] SIGG S, SCHOLZ M, SHI S, et al. RF-Sensing of Activities from Non-Cooperative Subjects in Device-Free Recognition Systems Using Ambient and Local Signals [J]. IEEE Transactions on Mobile Computing, 2014, 13(4): 907-920.

[8] YANG Z, ZHOU Z, LIU Y. From RSSI to CSI: Indoor Localization via Channel Response [J]. ACM Computing Surveys, 2013, 46(2): 1-32.

[9] YANG Z, LIU Y H. Wi-Fi Radar: From RSSI to CSI [J]. Chinese Computer Society, 2014, 10(11): 55-60.

[10] TIAN X H, ZHU S J, XIONG S J, et al. Performance Analysis of Wi-Fi Indoor Localization with Channel State Information [J]. IEEE Transactions on Mobile Computing, 2019, 18(8): 1870-1884.

[11] ZHANG Y, LI D P, WANG Y J. An Indoor Passive Positioning Method Using CSI Fingerprint Based on Adaboost [J]. IEEE Sensors Journal, 2019, 19(14): 5792-5800.

[12] XIN T, GUO B, WANG Z, et al. FreeSense: human-behavior understanding using Wi-Fi signals [J]. Journal of Ambient Intelligence and Humanized Computing, 2018, 9(5): 1611-1622.

[13] LI W D, TAN B, PIECHOCKI R J. Wi-Fi based passive sensing system for human presence and activity event classification [J]. IET Wireless Sensor Systems, 2018, 8(6): 276-283.

[14] LI L X. Research and Design of Personnel Perception and Intrusion Detection Technology Based on WLAN [D]. Beijing: Beijing University of Posts and Telecommunications, 2018.

[15] XIAO L, PAN H. Human motion recognition system based on Wi-Fi signal [J]. Journal of Beijing University of Posts and Telecommunications, 2018, 41(3): 119-124.

[16] WANG T, YANG D D, ZHANG S Q, et al. Wi-Alarm: Low-Cost Passive Intrusion Detection Using Wi-Fi [J]. Sensors, 2019, 19(10): 2335.

[17] WU K, XIAO J, YI Y, et al. FILA: Fine-grained indoor localization [C] // Proceedings of IEEE INFOCOM, 2012: 2210-2218.

[18] WANG W, LIU A X, SHAHZAD M, et al. Device-Free Human Activity Recognition Using Commercial Wi-Fi Devices [J]. IEEE Journal on Selected Areas in Communications, 2017, 35(5): 1118-1131.

[19] LI Y H, CHEN B. A Parameter-Independent Access Point Location Method Based on CSI [J]. Computer Science, 2017, 44(12): 74-77.

[20] GENG Y, CHEN J, FU R, et al. Enlighten Wearable Physiological Monitoring Systems: On-body RF Characteristics Based Human Motion Classification Using a Support Vector Machine [J]. IEEE Transactions on Mobile Computing, 2016, 15(3): 656-671.