

文章编号:1007-5321(2020)05-0105-07

DOI:10.13190/j.jbupt.2020-040

# 一种基于 CSI 的人体动作计数与识别方法

刘希文, 陈海明

(宁波大学 信息科学与工程学院, 宁波 315000)

**摘要:** WiFi 信道状态信息(CSI)被广泛应用于被动式(非侵入式)人体行为判断,为使用现有商用设备实现人体连续动作计数与识别,提出了一种 Wi-ACR 方法. 先利用阈值和活动指标检测出一组连续动作发生的区间和时间,再通过 peak-find 算法统计出动作的数量,并确定每个动作的开始和结束时间;再分别采用基于波形特征的动作识别模型和基于统计特征的动作识别模型,得到动作识别结果. 实验评估结果表明,Wi-ACR 对动作计数的准确率可达 95%,两类识别模型对于 2 个动作(深蹲和走)的平均识别精准率为 90%.

**关键词:** 动作计数; 动作识别; 信道状态信息

**中图分类号:** TP391.4

**文献标志码:** A

## A Human Action Counting and Recognition Method Based on CSI

LIU Xi-wen, CHEN Hai-ming

(School of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315000, China)

**Abstract:** Nowadays WiFi channel state information is widely applied in passive (unobtrusive) human continuous activity recognition. The article uses commercial off-the-shelf devices and proposes a human action counting and recognition (Wi-ACR) method, based on channel state information(CSI). Wi-ACR takes advantage of the threshold algorithm and action indicator to detect the start and end time of a set of continuous actions, and then counts the number of actions through the peak-find algorithm and determines the start and end time of each action. After that, Wi-ACR takes the waveform-feature-based action recognition model and the statistical-feature-based action recognition model to obtain action recognition results respectively. Experiments show that Wi-ACR can achieve action counting accuracy of 95% and recognition accuracy of 90% with these two recognition models, in the scenarios with two types of actions (i. e. squat and walk) occurring simultaneously.

**Key words:** action counting; action recognition; channel state information

精确的人体动作识别方法可以对人体行为进行判断,在运动分析、辅助医疗、虚拟现实和人机交互等领域得到了广泛的应用. 人体动作识别方法主要分为两类. ① 基于便携式设备<sup>[1-2]</sup>的方法. 具有较高的计算代价,对平台和设备有较高要求,需要专用

传感器,造价昂贵,设备安装和携带不方便. ② 基于非携带式光学设备<sup>[3-4]</sup>的方法. 涉及隐私问题和视距限制,还容易受光照条件和障碍物的影响,大规模的部署成本也很高. 近年来,通过现有的商用无线信号进行动作识别成为一种新的方法,主要包括

收稿日期: 2020-03-31

基金项目: 浙江省自然科学基金项目(LY18F020011); 宁波市自然科学基金项目(2018A610154)

作者简介: 刘希文(1994—),女,硕士生.

通信作者: 陈海明(1981—),男,副教授,硕士生导师, E-mail: chenhai ming@nbu.edu.cn.

基于无线信号接收信号强度 (RSS, received signal strength)<sup>[5-6]</sup> 和基于软件无线电 (SDR, software defined radio)<sup>[7-8]</sup> 的动作识别方法, 其中 RSS 对环境变化异常敏感, 而 SDR 需要专用硬件来传输和接收调制信号。

近年来, 研究人员提出从无线信号中获取具有相位和幅度信息的信道状态信息 (CSI, channel state information) 来实现动作识别<sup>[9-11]</sup>, 其基本原理是: 当用户在无线环境中移动时, 无线信号会形成多路径传播而产生多径效应, CSI 值会发生改变。但是, 现有基于 CSI 的动作计数和识别方法主要着眼于如何提取特征, 如何识别更多的动作, 如何提高动作识别准确度这几个问题来开展研究, 大都只能进行动作识别或动作计数, 并没有提出两者兼顾的方法。因此, 提出了一种基于 WiFi CSI 的人体动作计数和识别的方法 (Wi-ACR, WiFi action counting and recognition), 对动作进行计数的同时, 也能识别动作类型, 主要过程包括:

1) 通过商用设备采集 CSI 信号, 利用滑动窗口的方法和动作活动指标进行粗粒度动作区间的检测, 确定有无动作发生;

2) 一旦检测到有动作发生, peak-find 算法进行细粒度动作区间检测, 以进一步获取每次动作发生的时间并进行动作计数;

3) 基于波形特征的动作识别模型和基于统计特征的动作识别模型, 得到动作识别结果;

4) 实验结果表明, Wi-ACR 动作计数的准确率能达到 95%, 两类动作识别模型对于 2 个动作 (深蹲和走) 的识别精准率达到 90%。

## 1 相关工作

近几年, 国内外学者在基于 CSI 信号的动作识别和动作计数领域, 主要从动作区间检测、动作计数方法、特征提取、动作识别几个方面进行研究。现有的基于 CSI 的方法在动作识别的同时不能进行动作计数。例如, Electronic Frog Eye 是一种基于 CSI 的无装置人群统计方法<sup>[12]</sup>, 用于非劳动密集型现场调查的人群计数, 但是并没有动作识别功能。而 Wang 等<sup>[9]</sup>提出的 WiFall 利用 CSI 可检测到人的跌倒, 结合支持向量机 (SVM, support vector machine), 可以实现高精度的单人跌倒检测。但其不足之处是在没有干扰的环境下进行实验, 并且只识别一次摔跤动作。Wang 等<sup>[11]</sup>提出的 E-eyes, 使用  $k$  最邻近

(KNN,  $k$ -nearest neighbor) 和多维动态时间规整 (MD-DTW, multidimensionality-dynamic time warping) 来区分不同的活动实例, 如基于 CSI 的人类活动识别和监测系统 CARM<sup>[10]</sup> 建立了 CSI 速度模型和 CSI 活动模型。通过这 2 个模型, 定量地建立 CSI 值动态与特定人类活动之间的相关性。最后利用隐马尔可夫模型 (HMM, hidden Markov model) 进行分类, 计算复杂度较高。文献 [11, 13] 中的多维动态规整需要计算 2 个特征之间的相似度, 一旦样本数量增加, 计算量变大, 效率也随之降低。Zeng 等<sup>[14]</sup>也仅仅进行步态识别, 没有动作计数。

## 2 Wi-ACR 算法框架

图 1 所示为基于 CSI 的人体连续动作计数和识别系统 Wi-ACR 的整体框架, 包括采样、动作计数、动作识别 3 个部分。

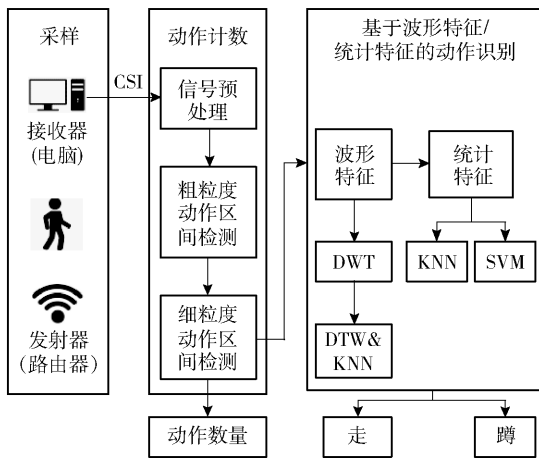


图 1 Wi-ACR 的框架

1) 采样部分。采样部分由发射端和接收端组成。现在的 WiFi 设备支持 IEEE 802.11n/ac 标准, 通常由多个发送和接收天线组成。在 Wi-ACR 中, 发射器具有 2 个定向天线, 接收器配备 3 个全向天线。在 Wi-ACR 工作时, 发射端不断向接收端发送无线数据包, 接收端则对其进行采样以提取 CSI 值。将采样频率设置为 100 Hz。从每个数据包中提取 CSI 矩阵, 其大小为  $N_{Tx} \times N_{Rx} \times S_c$ ,  $N_{Tx}$  为发送端天线数,  $N_{Rx}$  为接收端天线数,  $S_c$  为每根天线 Tx-Rx 的子载波数量。另外, 将每根天线 Tx-Rx 的 CSI 值作为一个 CSI 流, 其中  $S_c = 30$ ,  $N_{Tx} = 2$ ,  $N_{Rx} = 3$ 。

2) 动作计数部分。动作计数部分由信号预处理、粗粒度动作区间检测和细粒度动作区间检测组成。Wi-ACR 的预处理应用了 Hampel 滤波器去异常

值和巴特沃斯低通滤波器去噪方法来最小化环境噪声的干扰,然后确定有动作发生的开始时间和结束时间,称之为粗粒度动作区间检测。由于可能会发生多个连续动作,将进一步采用 peak-find 算法来计算每个粗粒度动作区间中发生动作的数量和定位每个动作的开始时间和结束时间,称之为动作计数和细粒度动作区间检测。

3) 动作识别部分。这是一种基于波形特征的动作识别模型和一种基于统计特征的动作识别模型。基于波形特征的动作识别模型利用离散小波变换(DWT, discrete wavelet transformation)从细粒度动作区间提取动作特征,分析出动作波形的相关性,以此为依据进行基于动态时间规整(DTW, dynamic time warping)的最佳拟合相匹配,利用 KNN 识别出动作的类型。基于统计特征的动作识别模型在波形特征基础上提取统计特征,输入 KNN 分类器和 SVM 分类器。

## 2.1 天线对之间的差异

在 Wi-ACR 中,每 2 个接收天线之间的距离大于 2 cm,可以获得  $2 \times 3$  个 CSI 流。为了理解发射端—接收端天线对之间的差异,在实验中分析了其中 3 个 CSI 流。观察得到:3 个 CSI 序列由相同的动作引起的 CSI 变化截然不同。集成所有 6 个 CSI 流中由动作产生的特征可以获得动作更详细和可区分的特征来改进动作识别。然而,它确实增加了 DTW 期间的时间和空间复杂性。

Wi-ACR 在准确性和计算复杂性之间进行权衡,仅选择一个 CSI 流(1-2)进行动作计数,选择 CSI 流(1-1)进行动作识别。

## 2.2 预处理

Wi-ACR 首先利用 Hampel 滤波器去除每个子载波的异常值,然后通过低通滤波器去除高频噪声,最后进行数据标准化。系统采集的是一段时间内因人体动作产生的 CSI 信号,一对天线对采集到的信号定义为 CSI 流,表示为

$$\mathbf{H}^{n,m} = [\mathbf{H}^{n,m}(1) | \mathbf{H}^{n,m}(2) | \cdots | \mathbf{H}^{n,m}(N)]^T \quad (1)$$

其中: $\mathbf{H}^{n,m}(i)$  为  $S_c \times 1$  维向量,为第  $i$  个数据包在 Tx-Rx 天线对  $n-m$  之间的  $S_c$  个子载波 CSI 值的幅值; $N$  为这段时间内数据包的数量; $i \in [N]$ ;  $n \in [N_{Tx}]$ ;  $m \in [N_{Rx}]$ ;  $\mathbf{H}^{n,m}$  为  $N \times S_c$  维向量,为  $N$  个数据包在 Tx-Rx 天线对  $n-m$  之间  $S_c$  个子载波 CSI 值的幅值。将最后得到的标准化后的数据用  $\mathbf{H}_z^{n,m}$  表示,虽然可以同时获得  $2 \times 3$  个 CSI 流,但是笔者选

择了 CSI 流(1-2),即  $n=1, m=2$ 。选择该天线对的原因见 2.1 节。CSI 信号中的噪声去除是一个经过充分研究的问题,故不再论述有关去噪的更多细节。图 2 为 CSI 流(1-2)预处理后的波形。显然,大大消除了高频噪声。




图2 预处理 CSI 流(1-2)

## 2.3 动作区间检测与粗粒度动作区间检测

为了进行动作计数,首先要确定这段时间内有动作发生的区间,然后分割出每个粗粒度动作区间,从而检测出每个动作的开始时间和结束时间。Wi-ACR 设计出一种新的检测动作区间的方法,具体步骤如下。

1) 用滑动窗口分割 CSI 流。将一个  $w$  (使用大量不同的  $w$  值进行对比实验,发现当  $w$  取 0.3 s 时,实验效果最佳) 窗口中的数据定义为短时间的 CSI 流,表示为

$$\mathbf{H}_w^{n,m}(j) = [\mathbf{H}_z^{n,m}(1) | \mathbf{H}_z^{n,m}(2) | \cdots | \mathbf{H}_z^{n,m}(N)] \quad (2)$$

其中: $j$  为第  $j$  个窗口,  $N = wF_s$  为一个窗口的数据包数量,  $F_s$  为采样频率。

2) 针对每个窗口的短时间 CSI 流,利用主成分分析(PCA, principal components analysis)算法来降维,从而自动选择那些代表所有 CSI 时间序列中最常见变化的主成分。将  $\mathbf{H}_w^{n,m}$  进行特征分解,以计算特征向量  $\mathbf{Q}$  和主成分  $\mathbf{H}$ 。其中  $\mathbf{Q} = (\mathbf{q}_1, \mathbf{q}_2, \cdots, \mathbf{q}_p)$ ,  $\mathbf{H} = (\mathbf{h}_1, \mathbf{h}_2, \cdots, \mathbf{h}_p)$ ,  $\mathbf{q}_p$  和  $\mathbf{h}_p$  为第  $p$  个特征向量和第  $p$  个主成分。

3) 活动指标计算。通过实验分析了特征向量和主成分分量之间的关系和对周围环境的敏感程度,发现当窗口没有动作发生时,第二主成分  $\mathbf{h}_2$  的方差小,第二特征向量  $\mathbf{q}_2$  在相邻子载波上随机变化;相反,该窗口有动作发生时,第二主成分  $\mathbf{h}_2$  的方差大,第二特征向量  $\mathbf{q}_2$  在相邻子载波上变得相关且平滑。因此, Wi-ACR 的动作活动指标  $R$  定义为第



二主成分的方差  $E^2\{\mathbf{h}_2\}$  与第二特征向量的一阶差分  $D\{\mathbf{q}_1\}$  的比值.  $E^2\{\mathbf{h}_2\}$ ,  $D\{\mathbf{q}_1\}$  以及  $R$  的定义为

$$E^2\{\mathbf{h}_2\} = \frac{1}{L} \sum_{l=1}^S (\mathbf{h}_2(l) - \bar{\mathbf{h}}_2)^2 \quad (3)$$

$$D\{\mathbf{q}_2\} = \frac{1}{S-1} \sum_{l=2}^S |\mathbf{q}_2(l) - \mathbf{q}_2(l-1)| \quad (4)$$

$$R = \frac{E^2\{\mathbf{h}_2\}}{D\{\mathbf{q}_2\}} \quad (5)$$

其中:  $L$  为每个窗口的时间 CSI 序列的长度,  $S$  为子载波数量.  $|\mathbf{q}_2(l) - \mathbf{q}_2(l-1)|$  为第二特征向量的相邻不同子载波的系数差.

4) 粗粒度动作区间检测. Wi-ACR 把  $R$  与根据经验设置的一个动作阈值  $T$  (静态环境下的动作活动指标) 进行比较. 当  $R > T$ , 表明当前窗口有动作发生, 根据窗口的时间和数量转化为动作时间, 从而确定整体动作发生的开始点和结束点. 图 3 所示为初步动作区间的开始和结束. 红点代表该动作区间的开始点, 绿点代表了该动作区间的结束点.




图 3 粗粒度动作区间检测

## 2.4 动作计数与细粒度动作区间检测

为了进一步确定动作发生的次数和每次发生的时间, 进行动作计数与细粒度动作区间检测. 首先, 重新对粗粒度动作区间对应的原始 CSI 流进行预处理, 以更多地保留因动作而产生的波形变化. 然后, 对第一主成分进行了平滑处理, 以更好地应用计数算法使波峰更突出. 最后, 利用 peak-find 算法识别一系列动作的波峰, 统计波峰的数量, 得到动作数量. 每个波峰的开始和结束就是每次动作的开始点和结束点, 即完成细粒度动作区间检测.

peak-find 算法通过以下 3 个步骤实现了动作检测和计数.

1) 求一阶导数  $d_x$ . 若  $d_x > 0$ , 将预处理后的每个时间区间进行如粗粒度动作区间检测一样的

PCA 降维操作. 由观察所知, 第一主成分的 CSI 时间序列变化最为明显, 所以选择第一主成分进行下一步操作, 且该点处于上升沿; 若  $d_x < 0$ , 该点处于下降沿. 上升沿和下降沿的每一个区间分别记录在  $I$  和  $D$  这 2 个变量中. 每个变量包含上升沿 (下降沿) 的开始采样点 ( $I_{sp}$  和  $D_{sp}$ )、上升沿 (下降沿) 的结束采样点 ( $I_{ep}$  和  $D_{ep}$ ) 和长度 ( $I_L$  和  $D_L$ ).

2) 在  $d_x > 0$  的情况下, 将  $I_L$  和由经验得到的阈值  $\Delta d$  进行比较, 一旦  $I_L > \Delta d$ , 保留第  $i$  个符合条件的正数区间  $I(i)$ . 在  $d_x < 0$  的情况下, 将  $D_L$  与  $\Delta d$  进行比较, 如果  $D_L > \Delta d$ , 记录符合条件的第  $j$  个负数区间  $D(j)$ .

3) 寻找波峰的开始位置和结束位置. 检测到有动作发生后, 判断  $I(i)_{ep}$  是否等于  $D(j)_{sp} - 1$ . 若是, 表示出现了波峰, 算法将记录波峰数量的变量  $P$  加 1, 直到所有的  $I(i)$  和  $D(j)$  都判断完成.  $I(i)_{sp}$  和  $D(j)_{ep}$  表示每个波峰的开始点和结束点, 也就是每个动作的细粒度动作区间, 波峰的数量也就是动作次数.

## 2.5 特征提取

### 2.5.1 波形特征提取

实验显示同种动作的波形形状基本相似, 而且不同动作的波形不同. 因此, 选用动作波形作为动作特征, 既保留了时域和频域的信息, 也更适合于分类. 为了更好地区分动作, 选择了数据差异最大的 CSI 流 (1-1). 每个子载波波形都包含了很多个数据点, 直接使用波形作为分类算法的输入会增加计算成本, Wi-ACR 应用 DWT 和 PCA 降维提取到特征波形. DWT 在保留时域和频域信息的同时压缩原始信号, 有助于信号分析.

波形特征提取的小波基函数选择了多贝西小波的 db5, 分解层数为 2 层. 在每个细粒度动作时间片段上进行 2 次 DWT 和 PCA 降维, 选特征最为明显的第一主成分作为细粒度动作区间内每个动作的特征波形, 即动作特征, 如图 4 所示.

### 2.5.2 统计特征提取

统计特征具有计算直观、处理过程简单的优点. 通过对波形进行统计分析和计算, 可以得到统计特征. 提取波形特征后再一次对波形进行统计特征的提取. 参考了大量的人体行为识别领域的文献, 并结合实测数据以及分析结果, 考察了标准偏差、均值、中位数绝对偏差、四分位差等多种特征值后, 选择了四分位差、最大值和信息熵作为该动作的统计

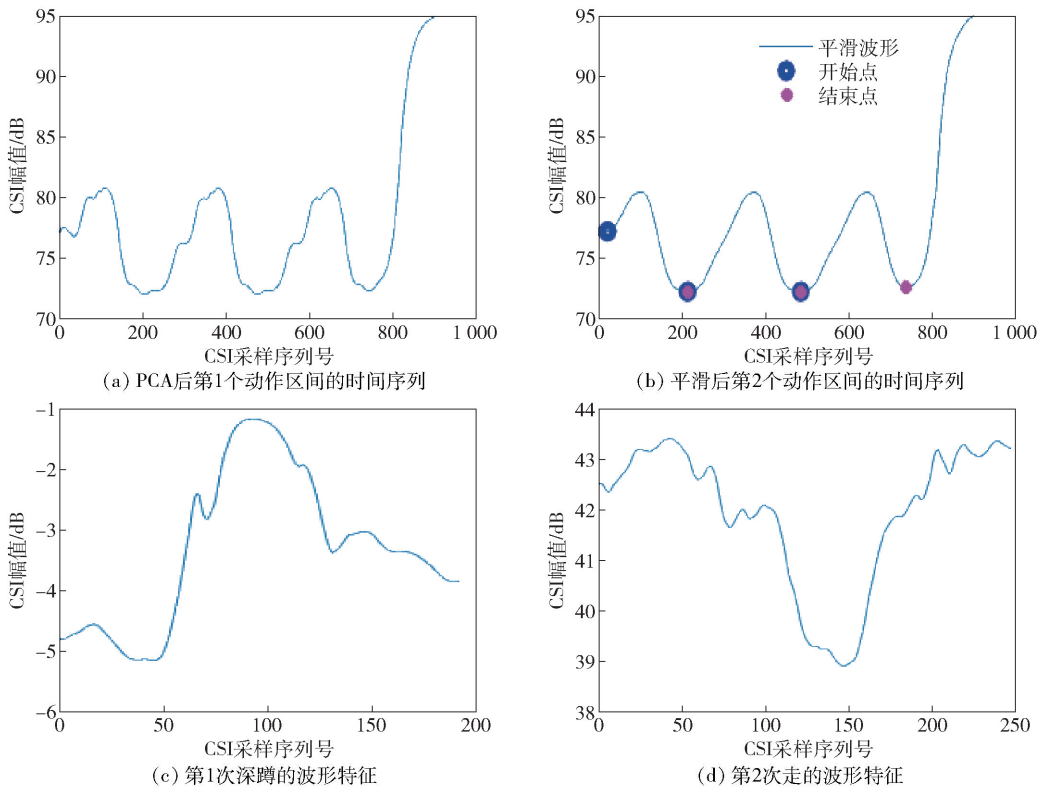


图 4 深蹲和走的波形特征

特征.

## 2.6 动作识别

### 2.6.1 基于波形特征的动作识别模型

在获取基于 DWT 的波形特征后,需要对其进行动作识别. Wi-ACR 使用 KNN 分类器识别不同的动作. 传统的 KNN 分类器采用欧氏距离作为样本之间的测量标准. 考虑到动作的特征向量可能不共享相同的长度,使用 DTW 来计算向量之间的距离. 与欧氏距离相比,DTW 计算了 2 个波形之间的距离.

Wi-ACR 通过 DTW 得到最短路径匹配,选取  $K$  个匹配到的最短路径作为 KNN 的样本间距离,搜索多数类的标签,找到其所对应的动作,确定该动作特征属于的动作类型.

### 2.6.2 基于统计特征的动作识别模型

在波形特征的基础上采集 3 种统计特征,分别为四分位差、最大值和信息熵,利用 KNN 和 SVM 两种分类器再次进行动作识别.

采用 KNN 分类器进行动作识别的原理与 2.6.1 节相同,这里不再阐述. 采用 SVM 分类器是因为 SVM 在小样本上处理二分类问题具有较好的识别效果. 在 Wi-ACR 中选用了四分位差、最大值和信息熵 3 种特征值构成了 3 维特征空间,投影到

高维空间中找出一个最优分界面,将整个特征空间划分为 2 个部分,对应走和深蹲 2 种动作,达到动作识别的目的.

## 3 实验结果与分析

### 3.1 实验平台与环境搭建

实验平台是由一台配备独立电源的 TP-Link TL-WR842N WiFi 路由器作为在 2.4 GHz 的 802.11n AP 模式下运行的发射器和一台由 Halperin 等<sup>[15]</sup>改进的英特尔 5300 无线网卡的 PC 组成的. 如图 5(a)所示,接收器和路由器位于相同高度的地面上. 接收器和发射器之间的距离为 2 m,志愿者在天线之间视线路径的中间进行动作. Wi-ACR 设置的采样频率为 100 Hz,足够确保捕获 CSI 时间序列中的变化,并最大化保留不同动作的细节.

为了保证实验的多样性,排除偶然性,招募了 5 位志愿者协助数据收集,要求志愿者在视距路径中间的活动区域进行实验. 为了避免其他人的运动引起干扰,实验环境中只有数据采集员和志愿者. 志愿者 1~5 在实验环境下每次执行规定的 2 种动作(匀速走和匀速深蹲)各 50 次,以构建训练数据集. 共收集了每位志愿者(共 5 名)100 组的测试文件

(标识为 1 ~ 100 号文件),构成测试集,做实验的过程中同时进行记录.




图 5 实验环境

3.2 评估指标

在动作计数方面,主要是对计数的准确率( $R_{TP}$ )、误报率( $R_{FA}$ )、漏报率( $R_{FN}$ )进行分析.  $R_{TP}$ 为正确检测到动作次数与实际动作发生次数的比值; $R_{FA}$ 为多报次数与实际动作发生次数的比值; $R_{FN}$ 为没有检测到的动作次数与实际动作发生次数的比值.

3.3 实验结果

3.3.1 动作计数的准确率和动作识别的准确率

采集了 5 位志愿者单次深蹲和走这 2 种动作的数据集作为训练集,提取波形特征和统计特征提供给 KNN 分类器和 SVM 分类器.

实验结果显示,志愿者在动作计数方面的总准确率约为 95%,误报率约为 3%,漏报率约为 4%. 对于深蹲和走 2 个动作,在细粒度动作区间提取出它们的每个动作波形特征和统计特征,计算识别准确率  $R_{ACR}$ .

表 1 给出了 Wi-ACR 采用基于波形特征的动作识别模型后,每个动作被正确和错误识别的概率. 当测试动作为走,Wi-ACR 识别为走的概率为 92%;当测试动作为蹲,Wi-ACR 识别为蹲的概率为 88%. 整体上,动作的识别率约为 90%.

表 1 基于波形特征的动作识别模型的动作识别准确率 %

识别的动作类型	实际的动作类型	
	深蹲	走
深蹲	88	8
走	12	92

实验还对比了 Wi-ACR 采用基于波形特征和基于统计特征这两类动作识别模型所得到的动作识别

准确率. 模型 1,2,3 分别代表了基于波形特征的动作识别模型、采用 KNN 分类器的基于统计特征的动作识别模型以及采用 SVM 分类器的基于统计特征的动作识别模型. 3 种动作模型的准确率基本相似,模型 1 和模型 3 的准确率为 90%,模型 2 的准确率为 92%.

将 Wi-ACR 与现有的基于 CSI 的动作识别方法进行对比. 在 Wang 等<sup>[11]</sup>提出的 E-eyes 中,使用的也是 KNN 分类器,但识别的是在不同时间段的单次不同动作,并没有动作计数. 由于只执行了一个类型的动作,所以获得的特征将更加明显,其动作识别精度为 92%. 相比之下,Wi-ACR 在一段时间内可识别 2 种类型的动作,同时可以完成动作计数. Wi-ACR 的最高识别率依旧可达到 92%. Qian 等<sup>[16]</sup>设计了 WiDance 系统. 在动作检测方面,WiDance 直接利用无运动时候频谱图功率的方差作为阈值检测动作发生时间,而 Wi-ACR 采用了两步检测法. 在典型的室内环境中 WiDance 对方向识别的精度为 92%. 虽然 WiDance 的实验效果较好,但是该系统主要是对运动方向进行识别,针对的是腿部的动作. Palipana 等<sup>[17]</sup>建立的 FallDeFi 感知系统的任务是摔跤检测,利用 SVM 分类器进行分类,准确率为 93%. 但是其只能判断有无发生摔跤,而 Wi-ACR 对动作类型实现识别的同时进行动作计数,在任务更加丰富的情况下计数准确率为 95%,平均识别准确率约为 91%. 这也表明 Wi-ACR 具有可行性,与现有的方法相比有一定的优势.

3.3.2 KNN 分类器 K 值的影响

KNN 分类器中的 K 值是人为设定的参数. 当 K 值的选择不同时,对分类的准确度也会产生影响. 通过实验观察到在模型 1 和模型 2 中不同 K 值对结果的影响. 在模型 1 中,当  $K < 26$ ,曲线为单调递增;当  $K > 26$ ,曲线单调递减,所以在模型 1 中将 K 设置为 26,以得到最高准确率. 在模型 2 中,当  $K = 4$  时,得到最高的动作识别准确率为 90%.

3.3.3 训练集大小的影响

为评估训练集大小的影响,将每个志愿者的训练样本数量从 50 个减少到 30 个,发现准确率从 90%降低至 85%. 每个志愿者的训练样本数量减少到 30 时,模型 2 的动作识别准确率下降至 88%,模型 3 的动作识别准确率下降至 80%. 可见,当训练样本减少时,整体的准确率均有所下降.



## 4 结束语

提出了一种基于 WiFi CSI 的人体动作计数与识别的方法 Wi-ACR,它基于现有的商用设备,利用 CSI 对动作进行计数,并且识别出动作的类型.与现有的工作相比,Wi-ACR 是一种新的动作区间检测方法,能够准确地获取每次动作的开始和结束点,并利用 peak-find 算法对连续动作进行计数.同时,它结合基于 DWT 提取的波形特征和统计特征,采用 DTW、KNN 和 SVM 两类动作识别模型进行对比,完成动作类型识别.实验结果显示,Wi-ACR 在动作计数方面的准确率能够达到 95%,两类动作识别模型的准确率达到 90%.

需要指出的是,利用 CSI 可以识别大幅度人体动作,但是在实现过程中存在很多的局限性,如同一个人在不同地点做同一种动作对信号产生的影响是不一致的.如何提高系统的鲁棒性,让其适用于不同的群体是下一步需要完善的工作.

## 参考文献:

- [1] Yatani K, Truong K N. BodyScope: a wearable acoustic sensor for activity recognition[C]//UbiComp 2012: Proceedings of the 2012 ACM Conference on Ubiquitous Computing. New York: ACM, 2012: 341-350.
- [2] Kim D, Hilliges O, Izadi S, et al. Digits: freehand 3D interactions anywhere using a wrist-worn gloveless sensor [C]//UIST 2012: Proceedings of the 25th annual ACM Symposium on User Interface Software and Technology. Massachusetts: ACM, 2012: 167-176.
- [3] Herath S, Harandi M, Porikli F. Going deeper into action recognition: a survey[J]. Image and Vision Computing, 2017, 60: 4-21.
- [4] Kerola T, Inoue N, Shinoda K. Spectral graph skeletons for 3D action recognition[C]//ACCV 2014: Proceedings of the Asian Conference on Computer Vision. Singapore: Springer, 2014: 417-432.
- [5] El-Kafrawy K, Youssef M, El-Keyi A, et al. Propagation modeling for accurate indoor WLAN RSS-based localization[C]//VTC-Fall 2010: Proceedings of the 2010 IEEE 72nd Vehicular Technology Conference-Fall. Cairo: IEEE, 2010: 1-5.
- [6] Kosba A E, Abdelkader A, Youssef M. Analysis of a device-free passive tracking system in typical wireless environments[C]//NTMS 2009: Proceedings of the 3rd International Conference on New Technologies, Mobility and Security. Ottawa: IEEE, 2009: 1-5.
- [7] PuQifan, Gupta S, Gollakota S, et al. Whole-home ges-

- ture recognition using wireless signals [C]//MobiCom 2013: Proceedings of the 19th Annual International Conference on Mobile Computing & Networking. Florida: ACM, 2013: 27-38.
- [8] Kellogg B, Talla V, Gollakota S. Bringing gesture recognition to all devices[C]//NSDI 2014: Proceedings of the 11th USENIX Symposium on Networked Systems Design and Implementation. Seattle: ACM, 2014: 303-316.
- [9] Wang Yuxi, Wu Kaishun, Ni L M. Wifall: device-free fall detection by wireless networks[J]. IEEE Transactions on Mobile Computing, 2016, 16(2): 581-594.
- [10] Wang Wei, Liu A X, Shahzad M, et al. Understanding and modeling of wifi signal based human activity recognition[C]//MobiCom 2015: Proceedings of the 21st Annual International Conference on Mobile Computing and Networking. Paris: ACM, 2015: 65-76.
- [11] Wang Yan, Liu Jian, Chen Yingying, et al. E-eyes: device-free location-oriented activity identification using fine-grained wifi signatures[C]//MobiCom 2014: Proceedings of the 20th Annual International Conference on Mobile Computing and Networking. Hawaii: ACM, 2014: 617-628.
- [12] Xi Wei, Zhao Jizhong, Li Xiangyang, et al. Electronic frog eye: counting crowd using wifi [C]//INFOCOM 2014: Proceedings of the IEEE Conference on Computer Communications. Toronto: IEEE, 2014: 361-369.
- [13] Li Hong, Yang Wei, Wang Jianxin, et al. WiFinger: talk to your smart devices with finger-grained gesture [C]//UbiComp 2016: Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing. Heidelberg: ACM, 2016: 250-261.
- [14] Zeng Yunze, Pathak P H, Mohapatra P. WiWho: wifi-based person identification in smart spaces[C]//IPSN 2016: Proceedings of the 15th International Conference on Information Processing in Sensor Networks. Vienna: IEEE, 2016: 4.
- [15] Halperin D, Hu Wenjun, Sheth A, et al. Tool release: gathering 802.11n traces with channel state information [J]. ACM SIGCOMM Computer Communication Review, 2011, 41(1): 53-53.
- [16] Qian Kun, Wu Chenshu, Zhou Zimu, et al. Inferring motion direction using commodity Wi-Fi for interactive exergames[C]//CHI 2017: Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems. Denver: ACM, 2017: 1961-1972.
- [17] Palipana S, Rojas D, Agrawal P, et al. FallDeFi: ubiquitous fall detection using commodity Wi-Fi devices[J]. ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2018, 1(4): 1-25.