

一种室内 WiFi 环境下的人体活动识别方法

何继爱, 李先祺, 赵雪

(兰州理工大学 计算机与通信学院, 甘肃 兰州 730050)

摘要:针对人体活动识别邻域中的隐私保护性差、识别准确率低、成本高等问题,提出一种基于 WiFi 信号识别人体活动的方法,该方法利用人体活动对 WiFi 信道状态信息的影响实现非接触式的活动识别。首先,利用子载波的相关性及其对活动敏感性的差异提出一种天线-子载波选择策略,减少不敏感天线及子载波对活动识别的影响;然后,对包含活动特征的 WiFi 信道状态信息用 Hampel 滤波及小波变换去噪进行预处理,并利用滑动窗口内信号的方差变化确定活动区间,去除不含活动特征的冗余信息,再用统计特征构造用于分类的特征量;最后,利用麻雀搜索算法优化正则化学习机的参数选择过程以提高模型性能。实验结果表明,该方法对拍手、前踢、深蹲、步行、弯腰、打电话、坐下、高摆手、喝水九种人体动作平均准确率可达到 96%,所提出的天线-子载波选择策略将九种活动的准确率平均提高了 4.56%;通过与目前先进算法和其他改进算法的对比,有效证明了该方法的有效性。

关键词:无线感知;人体活动识别;信道状态信息;机器学习;优化算法

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2025)03-0179-08

doi:10.20165/j.cnki.ISSN1673-629X.2024.0345

A Human Activity Recognition Method in Indoor WiFi Environment

HE Ji-ai, LI Xian-qi, ZHAO Xue

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Aiming at the problems of poor privacy protection, low recognition accuracy and high cost in the human activity recognition neighbourhood, a method for human activity recognition based on WiFi signals is proposed, which uses the effect of human activity on WiFi channel state information to achieve non-contact activity recognition. Firstly, an antenna-subcarrier selection strategy is proposed using the correlation of subcarriers and their differences in activity sensitivity to reduce the impact of insensitive antennas and subcarriers on activity recognition. Then, WiFi channel state information containing activity features is pre-processed with Hampel filtering and wavelet transform denoising, and the variance change of signals within the sliding window is used to determine the activity interval, and the redundant information without activity features is removed, and statistical features are used to construct the feature volume for classification. Finally, the regularized learning machine parameter selection process is optimized using a sparrow search algorithm to improve the model performance. The experimental results show that the proposed method can reach an average accuracy of 96% for nine human body movements: clapping, front kicking, deep squatting, walking, bending, talking on the phone, sitting down, high hand swinging, and drinking water, and the proposed antenna-subcarrier selection strategy improves the accuracy of the nine activities by an average of 4.56%. By comparing with the current state-of-the-art algorithms and other improved algorithms, the validity of the proposed method has been effectively proved.

Key words: wireless perception; human activity recognition; channel status information; machine learning; optimization algorithm

0 引言

近年来,随着无线感知技术的迅速发展,人体行为识别技术被广泛应用于健康监控^[1-3]、智能家居^[4-5]和人机交互^[6]等新兴领域,此技术成为了产学研研究的关键问题。目前的人体行为识别研究工作主要分为接触式和非接触式两大类,基于接触式的识别系统是利

用可穿戴式传感器设备对用户进行行为识别,如惯性测量单元传感器^[7]和三轴加速度传感器等,此类方法虽然有着较高的准确率,但对使用者的日常生活造成了侵扰且应用场景单一;非接触式的识别系统主要包括基于计算机视觉^[8]的识别系统和基于雷达的识别系统等,基于计算机视觉的识别技术对于环境亮度敏

收稿日期:2024-09-04

修回日期:2025-01-08

基金项目:国家自然科学基金项目(62361040)

作者简介:何继爱(1969-),男,教授,硕导,研究方向为通信感知一体化、通信信号处理与盲信号处理;通讯作者:李先祺(1999-),男,硕士研究生,研究方向为 WiFi 感知。

感且易侵犯使用者的隐私,而后者识别系统又存在设备成本昂贵等问题。

由于 WiFi 信号不侵犯使用者隐私且成本低廉,利用 WiFi 信号进行无线感知成为了近年来的研究热点。其两个重要的物理特性为接受信号强度 (Received Signal Strength, RSS) 和信道状态信息 (Channel State Information, CSI)。RSS 是信道的粗略描述,所含信息较少,易受多径效应的影响,因此 RSS 仅适用于入侵检测和室内定位等粗粒度场景。与 RSS 相比,CSI 是无线信号的细粒度描述,能呈现不同子载波上的多个路径的幅度与相位信息,从而提供更丰富和稳定的信道参数,使移动对象的感知更具有精细的分辨率。Halperin 等人^[9]通过修改网卡驱动程序,发布了能够从商用 Intel 5300 NIC 里提取到信道状态信息的 CSI Tool 工具。

现有的 WiFi 感知方法可以分为基于模型的方法和基于学习的方法。基于模型的方法通过信号传播规律构建 CSI 物理模型,描述人体活动与 CSI 之间的数学关系。王伟等人^[10]提出了基于 CSI 速度模型和 CSI 活动模型的人体活动识别和检测系统 CARM,通过这两个模型量化了不同人体部位的运动速度与特定人类活动之间的相关性。张大庆等人^[11]提出了菲涅尔区模型,根据人体穿过菲涅尔区所引起的 CSI 幅度和相位变化实现了呼吸检测。但当涉及到复杂连续的人体活动时,基于模型的方法表现不佳。这是因为人体活动包括身体各个部位的协同运动,其难以用模型表示。相比之下,基于学习的方法可以通过神经网络提取 CSI 信号的深层特征,在复杂任务中表现出卓越的性能。

Yousefi 等人^[12]将原始 CSI 幅度数据作为特征向量输入到长短记忆网络 (Long Short-Term Memory, LSTM),对六种日常人体行为实现了 90.5% 的平均准确率。Alsaify 等人^[13]提出一种基于 CSI 的多环境人体活动识别系统,使用支持向量机 (Support Vector Machine, SVM) 分类器,达到了 91% 的准确率。Yan 等人^[14]提出一种人体行为识别系统 WiAct,设计了一种基于信号方差差异的自适应活动切割算法,达到了 94.2% 的平均准确率。文献^[15]利用多任务学习,通过软参数共享,提高了系统的泛化性能,实现了 93.3% 的准确率。上述使用 CSI 数据进行人体行为识别的方法虽然识别性能良好,但未考虑不同天线和子载波对活动敏感度的差异而造成系统开销过大的问题,且未考虑分类器的参数选择过程对系统性能的影响。

针对上述问题,该文的主要贡献概述如下:

(1) 构建了一种基于 WiFi 的非接触式人体活动

识别系统,其利用广泛部署的 WiFi 设备中的物理层 CSI 作为识别特征。与传统的人体活动识别系统相比,该系统不需要用户穿戴设备、隐私保护性强且成本低。

(2) 基于不同天线与子载波对活动的敏感度,提出一种天线—子载波选择算法,以减少后续计算的数据量并突出活动特征。

(3) 利用与活动相关的多维特征作为分类器的输入,并对极限学习机 (Extreme Learning Machine, ELM) 算法进行优化。实验结果表明,与传统分类器相比,优化后的 ELM 具有较高的识别性能。

1 WiFi CSI 信号模型与系统架构

CSI 描述了发射端与接收端之间通信链路的信道特性,包含了信号在多径传播过程中引起的时延、幅度、相位衰减等变化。令 $\mathbf{x}$ 和 $\mathbf{y}$ 分别为发射端和接收端信号的向量表示,二者有以下关系:

$$\mathbf{y} = \mathbf{H} * \mathbf{x} + \mathbf{n} \quad (1)$$

其中, $\mathbf{n}$ 代表高斯白噪声, $\mathbf{H}$ 代表信道增益矩阵,可以表示为 $\mathbf{H} = [h_1, h_2, \dots, h_k]$, k 表示子载波的数量。该文使用一个发射天线和三个接收天线,且 $k = 30$ 。

通常使用信道频率响应 (Channel Frequency Response, CFR) 从幅频特性和相频特性来描述信道对信号传播的影响,可由下式表示:

$$H(f, t) = \frac{Y(f, t)}{X(f, t)} \quad (2)$$

式中, $Y(f, t)$ 和 $X(f, t)$ 分别为接受信号和发射信号的频域表示。包含环境噪声与多径传播特征的 $H(f, t)$ 可表示为:

$$H(f, t) = e^{-j2\pi\Delta f t} \sum_{l=1}^N a_l(f, t) e^{-j2\pi f \tau_l(t)} \quad (3)$$

式中, $a_l(f, t)$ 是第 l 条路径上的信道衰减的复表示, $e^{-j2\pi f \tau_l(t)}$ 代表具有时延为 $\tau_l(t)$ 的第 l 条路径上的相位偏移, N 是信号传播路径总个数, Δf 表示发射端和接收端之间的载波频率之差。

CSI 可看作是 CFR 在不同子载波上的离散采样,采样的频率点对应不同的载波频率,表示为:

$$H(f_k) = \|H(f_k)\| e^{j\angle H(f_k)} \quad (4)$$

式中, $H(f_k)$ 表示中心频率为 f_k 子载波的 CSI, $\|H(f_k)\|$ 和 $\angle H(f_k)$ 分别代表第 k 个子载波的幅度和相位。在室内环境下,CSI 提供了不同子载波的幅度与相位信息,人体活动会对载波进行“调制”,使原本的 CSI 发生改变。

该文基于 WiFi 信号的 CSI 构建了一个人体行为识别系统,该系统由天线—子载波选择、数据预处理、活动分割和分类识别组成,系统框图如图 1 所示。




图1 系统框图

2 人体活动识别系统

2.1 天线-子载波选择算法

2.1.1 天线选择算法

由于多进多出系统的多径影响和周围环境的复杂性,不同天线对同一动作的敏感度不同。图2表示步行动作的三根天线的CSI幅度均值,可以观察到天线3相对于天线1和天线2对活动敏感度较差,很难反映真实的人体活动。不敏感天线的存在会加大系统运算复杂度和计算量,天线选择的目的是剔除对活动最不敏感的天线。




图2 各天线幅度均值

为进一步区分不同天线对活动的敏感度,对子载波进行相关性分析。图3(a)和(b)分别表示天线1和天线3中子载波的相关系数矩阵。矩阵中每个元素对应于一个采样点中两个子载波幅度之间的相关系数。可以看出不敏感天线因受到噪声等多种干扰造成子载波之间的相关性较差。基于以上研究,提出一种天线选择方法,根据不同天线中子载波相关性来排除对活动最不敏感的一根天线。子载波之间的相关性系数可由下式计算。




图3 子载波相关性矩阵

$$\rho_{f_i f_j} = \frac{\text{COV}(f_i, f_j)}{\sqrt{V(f_i)} \cdot \sqrt{V(f_j)}} \quad (5)$$

其中, f_i 和 f_j 分别表示第 i 和 j 个子载波, $\text{COV}(f_i, f_j)$ 表示两个子载波的协方差, $V(f_i)$ 和 $V(f_j)$ 分别表示两个子载波各自的方差, $\rho_{f_i f_j}$ 越大表示两个子载波相关度越高。通过计算天线中 30 个子载波相关系数均值,剔除相关系数最小的天线。

2.1.2 子载波选择算法

为了进一步提高数据的可靠性并降低计算复杂度,在系统中采用子载波选择算法。根据正交频分复用技术,不同子载波具有不同的载波频率。当人体活动时,一些子载波可能会产生较大的功率变化,且更容易受到噪声等因素的影响,导致对活动不敏感。因此选择对人体活动更敏感的子载波,弱化噪声对子载波的影响以提高准确率。通常,对活动敏感的子载波具有较大平均绝对离差与方差。第 i 个子载波的敏感度可由下式计算。

$$P_{f_i} = \frac{M(f_i) + V(f_i)}{2} \quad (6)$$

式中, $M(f_i)$ 表示第 i 个子载波的平均绝对离差。图4给出了在第一根天线中 30 个子载波对步行动作的敏感度,且第 4 个子载波具有最高的敏感度,该文在一根天线中选择对活动最敏感的 20 个子载波。天线-子载波选择算法伪代码如下所示(算法1)。




图4 子载波敏感度

算法1: 天线-子载波选择算法

输入: S - CSI 序列数据

输出: S_m - 最敏感的 CSI 序列数据, 包含 40 个子载波

1: for 每个子载波 S_j

2: 计算 S_j 各子载波的相关系数 $\rho_{f_i f_j}$

3: 分别计算三根天线中子载波相关系数均值 ρ_1, ρ_2, ρ_3

4: if $\rho_1 \geq \rho_2$ & $\rho_1 \geq \rho_3$, 则

5: if $\rho_2 \geq \rho_3$, 则敏感天线 $S_a = S_1 + S_2$

6: else, $S_a = S_1 + S_3$

- 7: else, if $\rho_2 \geq \rho_1 \& \rho_2 \geq \rho_3$, 则 $S_a = S_2 + S_3$
- 8: else, $S_a = S_1 + S_3$
- 9: for S_n in S_a
- 10: 计算两根天线中各子载波敏感度 $P_{(1,f)}$, $P_{(2,f)}$
- 11: 分别将 $P_{(1,f)}$, $P_{(2,f)}$ 中最大的 20 个载波返回到 S_m

2.2 预处理

由于多径传播和硬件不完善等因素的影响,在原始 CSI 信号中产生了非人为引起的大量噪声,影响系统的准确率^[16]。因此在预处理这项工作中,使用 Hampel 滤波及小波变换去噪的方式对原始 CSI 信号进行离群值和噪声的去除。

Hampel 滤波利用中位数和中位数绝对偏差检测离群值的位置,如图 5 所示。Hampel 滤波很好地去除了 CSI 信号中的离群值。小波变换去噪的原理是对信号进行小波分解,利用阈值函数对各层系数量化后重构得到去噪后的信号。小波变换去噪能在抑制高频干扰的同时保留有用信号的尖峰和突变信号。从图 5 中观察到,CSI 信号波形变得更平滑且保留了人体活动信息。




图 5 预处理结果

2.3 活动分割

由于 CSI 信号中含有大量与人体活动无关的冗余信息,影响识别效率。因此有必要从整个时间序列中检测人体活动的起始点,该系统采用一种基于方差的滑动窗口法进行活动分割。一个动作样本的 CSI 序列数据为 $S = [S_1, S_2, \dots, S_n]$, 其中 S_i 和 n 表示样本中第 i 个数据包和 CSI 序列的长度。计算第 t 个窗口内数据的方差如下:

$$\text{var}_s[t] = \frac{1}{\text{win}} \sum_{i=t}^{\text{win}+t} \left(S[i] - \frac{\sum_{i=1}^{\text{win}+t} S[i]}{\text{win}} \right)^2 \quad (7)$$

其中, win 表示窗口长度,设置窗口长度为 3。方差较大的部分代表人体活动片段,而人体静止时方差较小。

将方差序列的均值作为阈值,检测人体活动的起始点。若该片段方差高于阈值,则判断为人体活动;若方差低于阈值,为了防止系统误判,则将该窗口和前后相邻窗口三个方差的均值作为新阈值,将该窗口内方差与新阈值对比,确定该片段是否属于人体活动区间。步行动作的活动分割结果如图 6 所示。




图 6 活动分割

2.4 特征提取

人体活动会导致反射信号的波长和频率发生变化,进而发生多普勒效应^[17],如式 8 所示。

$$\Delta D \propto \frac{2vc \cos \theta}{c} f \quad (8)$$

式中, ΔD 表示多普勒频移, v 和 θ 表示目标移动的速度和方向, c 为光速, f 表示信号中心频率。根据上述多普勒效应,接收端信号的信道频率响应表示为:

$$H(f, t) = H_s(f) + \sum_{k \in P_d} \alpha_k(t) \exp(2\pi \int_{-\infty}^t f_{D_k}(v) dv) \quad (9)$$

式中, $H_s(f)$ 是静态路径响应之和, P_d 是动态路径的集合, $\alpha_k(t)$ 是第 k 条路径的衰减因子。

根据文献[17]可知,将一对天线共轭相乘可以消除相位偏移,且保留了多普勒频移信息。为提高步行、深蹲等大幅度活动识别准确率,该文将两根天线的信道频率响应共轭相乘,并将结果的幅度作为一个识别特征。

再从预处理之后的 CSI 信号中提取以下时域统计特征作为特征向量:(1)均值;(2)归一化标准差;(3)最大值和最小值;(4)差值;(5)四分位距;(6)信息熵;(7)中位数绝对偏差。

2.5 人体活动检测与分类

与传统单隐层前馈神经网络相比,ELM 的输入权值与阈值无需进行迭代调整,可以解决局部最优解问题,且具有更快的训练速度和更好的泛化性。为进一步解决模型过拟合问题,该文尝试将正则化 ELM (Regularization ELM, RELM) 作为分类器并引入麻雀搜索算法 (Sparrow Search Algorithm, SSA) 来选择最佳正则化系数等参数,以提高模型精度及泛化性。

2.5.1 正则化极限学习机

极限学习机是 Huang 等人提出的一种神经网络

算法模型,结构如图7所示,由输入层、隐藏层、输出层构成,每层又由不同数量的神经元组成。与其他前馈神经网络不同的是,ELM的输入权重 ω 和偏置 b 是随机选择的,并采用最小二乘法对输出层权重进行求解。对于 n 个随机样本数据,具有 j 个隐藏层神经元和激活函数 $G(x)$ 的ELM在数学上可建模为:

$$y_i = \sum_{k=1}^j G(\omega_k \cdot x_i + b_k) \cdot \beta_k (i=1,2,\dots,n) \quad (10)$$

式中, $\omega_k = [\omega_{k1}, \omega_{k2}, \dots, \omega_{kn}]^T$ 是连接第 k 个隐藏层神经元和输入节点的权重; $\beta_k = [\beta_{k1}, \beta_{k2}, \dots, \beta_{kn}]^T$ 是第 k 个隐藏层神经元的输出权重, y_i 为ELM的输出值。将等式10表示为矩阵形式。

$$Y = H\beta \quad (11)$$

式中, Y 为ELM输出矩阵, H 为隐藏层输出矩阵, β 为隐藏层输出权重矩阵。因此,ELM的目标是求解满足下式的隐藏层输出权重向量 β 。

$$\|H \cdot \beta - Y\|^2 = \min_{\beta} \|H \cdot \beta - Y\|^2 \quad (12)$$

上式的最小二乘解 β 表示为:

$$\beta = H^+ Y \quad (13)$$

式中, H^+ 为 H 的Moore-Penrose广义逆矩阵。




图7 ELM结构

由式10可知,ELM并未考虑结构风险,容易出现模型过拟合问题。为提高模型泛化性,引入正则化参数平衡经验风险和结构风险的比例,构建RELM模型^[18]。RELM目标函数如下:

$$\begin{aligned} \min_{\beta} & \frac{1}{2}(\gamma \|e\|^2 + \|\beta\|^2) \\ \text{s. t.} & \sum_{k=1}^j \beta_k \cdot G(\omega_k \cdot x_i + b_k) - y_i \\ & = e_i (i=1,2,\dots,n) \end{aligned} \quad (14)$$

式中, e_i 为预测值与真实值之间的误差向量, γ 为正则化系数。该问题可看作条件极值问题,定义如下拉格朗日函数进行求解。

$$\begin{aligned} L(\beta, e, \alpha) &= \frac{1}{2}(\gamma \|e\|^2 + \|\beta\|^2) \\ &\quad - \alpha(H\beta - Y - e) \end{aligned} \quad (15)$$

式中, α 为拉格朗日算子,合并 $L(\beta, e, \alpha)$ 的Karush-

Kuhn-Tucker最优化条件可得到隐藏层输出权重 β 的解。

$$\beta = Y(H^T H + \frac{I}{\gamma})^{-1} H^T \quad (16)$$

式中, I 为单位矩阵。由上式可知,RELM与ELM的主要区别在于前者引入正则化系数 γ 给予模型更强的泛化性。但其参数的选择仍会影响模型的性能,因此该文使用麻雀搜索算法进行参数优化。

2.5.2 麻雀搜索算法

SSA是一种由麻雀觅食特性启发的群智能优化算法^[19]。在SSA中,种群的所有个体被分为发现者和追随者两类,发现者为追随者觅食提供方向引导,其位置更新公式为:

$$S_{i,j}^{t+1} = \begin{cases} S_{i,j}^t \cdot \exp(\frac{-i}{\delta \cdot M}) & \text{if } R_2 < ST \\ S_{i,j}^t + Q \cdot L & \text{if } R_2 \geq ST \end{cases} \quad (17)$$

式中, $S_{i,j}^t$ 代表第 i 只麻雀在第 j 维度的位置, t 是当前迭代次数, M 是最大迭代次数, $\sigma \in (0,1]$, Q 是遵循正态分布的随机数, L 是元素为1的一行多维矩阵, $R_2(R_2 \in [0,1])$ 和 $ST(ST \in [0.5,1.0])$ 分别代表报警值和安全值。

追随者位置更新公式描述为:

$$S_{i,j}^{t+1} = \begin{cases} Q \cdot \exp(\frac{S_{\text{worst}} - S_{i,j}^t}{i^2}) & \text{if } i > n/2 \\ S_p^{t+1} + |S_{i,j}^t - S_p^{t+1}| \cdot A^+ \cdot L & \text{otherwise} \end{cases} \quad (18)$$

式中, S_p 是发现者占据的最佳位置, S_{worst} 表示当前全局最差位置, A 是一个每个元素为1或-1的 $1 \times d$ 维矩阵,满足 $A^+ = A^T(AA^T)^{-1}$ 。用于侦察和预警的麻雀占种群的10%到20%,其位置更新如下所示:

$$S_{i,j}^{t+1} = \begin{cases} S_{\text{best}}^t + \chi \cdot |S_{i,j}^t - S_{\text{best}}^t| & \text{if } f_i > f_g \\ S_{i,j}^t + K \cdot (\frac{|S_{i,j}^t - S_{\text{worst}}^t|}{f_i - f_w + \varepsilon}) & \text{if } f_i = f_g \end{cases} \quad (19)$$

式中, S_{best}^t 是当前全局最优位置, χ 为步长控制参数, f_i 是当前麻雀适应度, f_g 和 f_w 分别为当前全局最佳适应度和最差适应度, K 为随机数, ε 是避免误差的最小常数。

3 实验结果与分析

3.1 实验数据

为验证该方法的有效性,选用WiAR数据集^[20]在包含少量办公家具的会议室内10名志愿者(5男5女)的9种人体活动(拍手、前踢、深蹲、步行、弯腰、打电话、坐下、高摆手、喝水),包括上半身活动、下半身活动和全身活动。采用一台路由器作为发射端,一台配有Intel 5300网卡的电脑作为接收端。发射端与接收端之间的距离为4 m,志愿者与发射端的距离为1

m,与接受端的距离为 3 m。实验环境参数如表 1 所示。实验所使用主机 CPU 为 12th Gen Intel(R) Core (TM) i7-12700H 2.70 GHz, GPU 为 NVIDIA GeForce RTX3050Ti。

表 1 实验参数

特性和参数	环境参数
房间大小	6m × 8m
人数	1
带宽/MHz	20
频率/GHz	5
天线	3Rx × 3Tx
子载波数量	90
SSA 种群规模	30
SSA 最大迭代次数	100

3.2 实验结果与分析

实验采用四折交叉验证法进行评估,将数据集分为四个部分,每次使用其中三个部分作为训练集,剩余一个部分作为测试集,每次选择不同的部分作为测试集。最终,将四次实验的评价指标取平均值作为评估结果。为了全面评估该方案的性能,定义以下四个评价指标:

$$\text{准确率 (Acc)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (20)$$

$$\text{精度 (Pre)} = \frac{TP}{TP + FP} \quad (21)$$

$$\text{召回率 (Rec)} = \frac{TP}{TP + FN} \quad (22)$$

$$F1 = \frac{2 \times \text{Rec} \times \text{Pre}}{\text{Rec} + \text{Pre}} \quad (23)$$

式中,TP 是被正确分类的活动数量,称为真阳性;FP 是被错误分类的活动数量,称为假阳性;TN 是指实际为负,分类为正的活动的数量,称为真阴性;FN 是指实际为正,分类为负的活动数量,称为假阴性。以上评价指标中,准确率表示所有活动中正确识别的比例,精度是衡量误报的指标,召回率是正确分类的正样本数占所有实际为正的样本数的比例,F1 值是精度和召回率的调和平均数。

图 8 显示了使用 SSA-RELM 分类结果的混淆矩阵,横轴为预测标签,纵轴为真实标签。可以看出,该方法对九种人体活动的平均准确率达到 96%,且“深蹲”“步行”“弯腰”“坐下”这 4 种活动的准确率都达到 97% 以上。其中“拍手”“打电话”和“喝水”的准确率分别为 94%、95% 和 93%,其原因在于这三种活动的性质存在相似性,且动作幅度不大,导致准确率下降。图 9 显示了 SSA-RELM 分类结果的精度、召回率及 F1 值,可以看出该算法表现优越。

综上,提出的人体活动识别方法在公开数据集上表现出优良的性能,可以满足识别人体活动的要求。




图 8 SSA-RELM 混淆矩阵




图 9 SSA-RELM 分类性能

以步行动作为例,天线-子载波算法选择结果如图 10 所示。去除第三根不敏感天线后进一步对第一、二根天线上的子载波进行选择。图中颜色越深代表子载波对活动敏感度越高,可以看出第一根天线中前 20 个子载波以及第二根天线中编号为 1~4、14~30 的子载波具有较好的敏感度。对于一个动作在敏感天线中共选择 40 个子载波用于后续的活动识别。




图 10 天线-子载波算法选择结果

隐层神经元个数对于 RELM 是一个重要参数,为探究隐层神经元个数对分类器性能影响,选择不同隐层神经元个数进行比较实验。如图 11 所示,识别率随着神经元数量增加而增加,当神经元个数为 50 时,分类器性能不佳。但当神经元个数超过 450 时,性能趋于稳定。因此将隐层神经元个数设为 450 可达到最佳性能。

另外,为进一步验证该方法的性能,将 SSA-RELM 与其他分类方法进行对比。选择 ELM、LSTM

算法、文献[21]及 CNN-BiLSTM^[22] 进行比较,结果如表 2 所示。ELM 由于参数不易调整导致性能表现不佳,平均准确率为 83.6%,而基于深度学习的 CNN-BiLSTM 性能提高较为明显,但其训练时间相对较长,且易导致过拟合问题。文献[21]利用信号增强方法突出了活动特征,获得了较高准确率,但未考虑子载波对活动的影响且只限于七种活动。而 SSA-RELM 算法与其他算法相比,在活动种类较多的条件下有效提高了准确率。这说明该算法在 ELM 上引入正则化参数,有效防止了模型出现过拟合问题,利用 SSA 算法优化模型参数选择过程,进一步提高了模型的精度及

泛化性,从而提高了准确率。




图 11 不同隐层神经元个数的性能结果

表 2 不同算法准确率对比

算法类型	拍手	前踢	深蹲	步行	弯腰	打电话	坐下	高摆手	喝水	平均
ELM	0.81	0.83	0.84	0.96	0.87	0.81	0.82	0.80	0.79	0.836
LSTM	0.90	0.91	0.92	0.98	0.91	0.89	0.91	0.85	0.83	0.901
文献[21]	0.95	-	-	0.99	0.94	0.90	0.98	0.91	0.92	0.95
CNN-BiLSTM ^[22]	0.93	0.93	0.94	0.98	0.92	0.91	0.93	0.90	0.91	0.927
文中算法	0.94	0.96	0.97	0.99	0.97	0.95	0.97	0.96	0.93	0.96

由图 12 可以看出,对于“喝水”和“打电话”这两种幅度偏小的活动,识别准确率分别都提高了 8%;天线-子载波选择算法将九种活动的准确率平均提高了 4.56%;对于“步行”活动则无明显提升,这是因为 CSI 对大幅度活动较为敏感,不易受到干扰。这充分说明子载波-天线选择算法有效剔除了不敏感天线和子载波,减少了数据冗余,并从源头上减少了噪声等因素对 CSI 的干扰,使所保留的数据对活动具有较高的敏感度,从而提高了系统识别性能。




图 12 有无天线-子载波选择算法对性能影响




图 13 SSA 寻优迭代曲线

图 13 为 SSA-RELM 模型的寻优迭代曲线,表示 RELM 随着 SSA 迭代次数增加性能不断变化情况。可以看出 SSA 具有良好的寻优能力并跳出了局部最优,在迭代至 82 次时算法收敛,模型性能达到最佳。通过以上分析可知,利用 SSA 优化 RELM 超参数建立人体活动识别模型具有较高的可行性。

4 结束语

该文提出了一种 WiFi 信号的人体活动识别方法,采用天线-子载波选择策略后引入 Hampel 滤波及小波变换去噪以去除大量冗余信息,并通过滑动窗口确定活动区间,提取 CSI 中的多维特征作为分类器的输入,在 RELM 中引入 SSA 以提高模型的精度及泛化性。实验结果和分析表明,该方法对九种活动的平均识别率可达到 96%,在“步行”活动上达到了 99% 的识别率,优于已有识别方法。由于该文只考虑无干扰场景下的单用户活动识别,未来将关注复杂场景下多用户活动识别,进一步提高算法鲁棒性。

参考文献:

[1] ROPITAULT T, DA SILVA C R C M, BLANDINO S, et al. IEEE 802. 11 bf WLAN sensing procedure: enabling the widespread adoption of WiFi sensing[J]. IEEE Communications Standards Magazine, 2024, 8(1): 58-64.

[2] BOUDLAL H, SERRHINI M, TAHIRI A. A monitoring system for elderly people using WiFi sensing with channel state information[J]. International Journal of Interactive Mobile Technologies, 2023, 17(12): 112-131.

- [3] BAO N, DU J, WU C, et al. Wi-breath: a WiFi-based contactless and real-time respiration monitoring scheme for remote healthcare[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 27(5): 2276–2285.
- [4] HAO L, HUANG B, JIA B, et al. Toward accurate crowd counting in large surveillance areas based on passive WiFi sensing[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(12): 14086–14096.
- [5] GONG D, LIU K, PEI D, et al. Wi-Watch: WiFi-based vigilant-activity recognition for ship bridge watchkeeping officers[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1–17.
- [6] BOUDLAL H, SERRHINI M, TAHIRI A. Leveraging WiFi channel state information for efficient and reliable device-free human activity recognition[C]//2023 IEEE 6th international conference on cloud computing and artificial intelligence: technologies and applications (CloudTech). Marrakech: IEEE, 2023: 1–8.
- [7] 时尚, 何正燃, 董恒. 基于 IMU 传感器与深度度量学习的人体行为识别算法[J]. *移动通信*, 2024, 48(3): 131–136.
- [8] 李占利, 权锦成, 靳红梅. 基于 3D-Attention 与多尺度的矿井人员行为识别算法[J]. *国外电子测量技术*, 2023, 42(7): 95–104.
- [9] HALPERIN D, HU W, SHETH A, et al. Tool release: gathering 802.11 N traces with channel state information[J]. *ACM SIGCOMM Computer Communication Review*, 2011, 41(1): 53.
- [10] WANG W, LIU A X, SHAHZAD M, et al. Understanding and modeling of wifi signal based human activity recognition[C]//Proceedings of the 21st annual international conference on mobile computing and networking. New York: Association for Computing Machinery, 2015: 65–76.
- [11] WU D, ZHANG D, XU C, et al. Device-free WiFi human sensing: from pattern-based to model-based approaches[J]. *IEEE Communications Magazine*, 2017, 55(10): 91–97.
- [12] YOUSEFI S, NARUI H, DAYAL S, et al. A survey on behavior recognition using WiFi channel state information[J]. *IEEE Communications Magazine*, 2017, 55(10): 98–104.
- [13] ALSAIFY B A, ALMAZARI M M, ALAZRAI R, et al. A CSI-based multi-environment human activity recognition framework[J]. *Applied Sciences*, 2022, 12(2): 930.
- [14] YAN H, ZHANG Y, WANG Y, et al. WiAct: a passive WiFi-based human activity recognition system[J]. *IEEE Sensors Journal*, 2019, 20(1): 296–305.
- [15] ZHANG Y, CHENG A, CHEN B, et al. A location-independent human activity recognition method based on CSI: system, architecture, implementation[J]. *IEEE Transactions on Mobile Computing*, 2023, 23(5): 4793–4805.
- [16] 刘苗苗, 樊春玲. 基于 WiFi 信号的老年人居行为识别算法[J]. *电子测量技术*, 2023, 46(6): 185–192.
- [17] QIAN K, WU C, ZHOU Z, et al. Inferring motion direction using commodity Wi-Fi for interactive exergames[C]//Proceedings of the 2017 CHI conference on human factors in computing systems. Denver: Association for Computing Machinery, 2017: 1961–1972.
- [18] DENG W, ZHENG Q, CHEN L. Regularized extreme learning machine[C]//2009 IEEE symposium on computational intelligence and data mining. Nashville: IEEE, 2009: 389–395.
- [19] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22–34.
- [20] GUO L, WANG L, LIN C, et al. Wiar: a public dataset for wifi-based activity recognition[J]. *IEEE Access*, 2019, 7: 154935–154945.
- [21] YANG J, LIU Y, LIU Z, et al. A framework for human activity recognition based on WiFi CSI signal enhancement[J]. *International Journal of Antennas and Propagation*, 2021, 2021(1): 6654752.
- [22] 张善进. 基于 CSI 的室内人员身份和日常动作识别技术研究[D]. 南京: 南京邮电大学, 2023.