

WiNet: 一种适用于无线感知场景的步态识别模型

段鹏松¹, 周志一¹, 王超¹, 曹仰杰^{1,2}, 王恩东³

(1. 郑州大学软件学院, 450000, 郑州; 2. 郑州大学汉威物联网研究院, 450000, 郑州;
3. 浪潮集团, 250000, 济南)

摘要: 针对现有基于 Wi-Fi 信号感知步态识别研究存在的特征获取不足、多人场景下单目标识别准确率低的问题,提出了一种基于频率能量图的步态识别模型 WiNet。在对信道状态信息影响因子分析的基础上,选取其中的振幅数据作为步态识别的基础数据;采用频率能量图对原始采集数据进行有效重构使其能够同时容纳步态行为对子载波内和子载波间扰动而产生的有效特征,步态特征的个体辨识度得到较大增强;将频率能量图作为卷积神经网络模型的输入矩阵,经过多组卷积、正则和激活操作,再使用 Softmax 方法进行分类,得到步态行为对应的个体身份,实现了 Wi-Fi 环境下高准确率的多人场景单目标步态识别。与全连接神经网络、循环神经网络及基于卷积神经网络的步态识别模型进行了比较,结果表明:WiNet 在 40 人场景实验中识别准确率达到 98.5%,识别准确率得到明显提升;在典型强/弱多径效应环境及 5 种人体状态的对比实验中,WiNet 均能达到 92% 以上的识别准确率,具有良好的识别效果和鲁棒性。

关键词: 步态识别;信道状态信息;频率能量图;卷积神经网络

中图分类号: TP391 **文献标志码:** A

DOI: 10.7652/xjtuxb202007022 **文章编号:** 0253-987X(2020)07-0187-09



OSID 码

WiNet: a Gait Recognition Model Suitable for Wireless Sensing Scene

DUAN Pengsong¹, ZHOU Zhiyi¹, WANG Chao¹, CAO Yangjie^{1,2}, WANG Endong³

(1. School of Software Engineering, Zhengzhou University, Zhengzhou 450000, China;
2. Hanwei Institute of Internet of Things, Zhengzhou University, Zhengzhou 450000, China;
3. Inspur Group, Jinan 250000, China)

Abstract: Aiming at the problems of insufficient acquisition of features and low recognition accuracy of single target for multi-person scene in gait recognition from Wi-Fi signal perception, a new gait recognition model WiNet is proposed. Depending on the channel state information impact factor analysis, the amplitude data is chosen as the basic data for gait recognition, and a mechanism named frequency energy map is adopted to reconstruct the raw data effectively in WiNet. The advantage of WiNet lies in the capacity of extracting effective features generated by the gait behavior on the inter-subcarrier and intra-subcarrier signals at the same time, which greatly improves the individual recognition in gait recognition. The frequency energy map is used as the input matrix of the convolutional neural network model. After multiple groups convolution, regularization and activation operations, the softmax method is used in classification, and the individual identity corresponding to the gait behavior is obtained. The results show that, compared with other similar gait recognition models which are based on fully

connected neural network, recurrent neural network and convolutional neural network, WiNet has a recognition accuracy of 98.5% for 40-person scene experiment, which is significantly improved. Besides, the recognition accuracy of the WiNet is still more than 92% in the contrast experiment of typical strong/weak multipath effect environments and five-person states, which shows that WiNet performs well and robustly.

Keywords: gait recognition; channel state information; frequency energy map; convolutional neural network

如何在人机交互中更便捷、更高效地进行身份识别,一直是学术界和产业界关注的焦点。步态作为一种不易伪装的生物特征,在身份识别研究中受到广泛关注^[1-2]。传统步态识别研究中,采用摄像机^[3-4]、加速度传感器^[5]或地面传感器^[6]等方式进行步态数据的采集。这些采集方法在使用时存在一定的限制,如易受光线变化或部署成本影响。近年来,随着 Wi-Fi 设备的大量普及^[7],基于 Wi-Fi 信号的无线感知凭借其非接触式、易部署、不受光线影响、隐私性更好等优势,成为步态识别研究的新兴方向。

由于个体体型和运动模式存在差异,步态以独有方式对区域内 Wi-Fi 信号形成扰动,从而在信道状态信息(CSI)上产生辨识度较高的特征响应^[8-9]。CSI 数据是正交频分复用(OFDM)技术中对信道状态的估计参数,能更准确地反映信道的干扰情况,也是目前 Wi-Fi 感知研究中常用的数据分析源。

目前,基于 CSI 的步态识别已有不少研究成果,而且主要集中在多人场景下的单目标识别方面。Shi 等分析了人体日常行为对 CSI 数据的扰动特征,采用神经网络模型实现了行走和静止状态下的身份识别,准确率分别为 94% 和 91%^[10]。Wang 等在 Wi-Fi 环境下,对采集到的步态 CSI 数据使用信号处理技术生成频谱图,使用 SVM 算法对频谱图进行特征提取和匹配实现了身份识别,最高准确率为 93.05%^[11]。Zeng 等利用多径消除和带通滤波去除噪声,提取 Wi-Fi CSI 数据中的步态特征,使用决策树算法进行身份识别,在 2~6 人场景下,准确率为 92%~80%^[12]。Zhang 等提出了 WiFi-ID 方法,利用快速傅里叶变换和 Relief 算法提取 CSI 数据中的步态特征,并通过 SAC 算法进行身份识别,在 2~6 人场景下,准确率为 93%~77%^[13]。Xin 等提出了一种基于步态的身份识别方法 FreeSense,该方法对 Wi-Fi 中采集的 CSI 数据使用主成分分析法、离散小波变换方法进行处理,然后使用动态时间规整方法进行分类,实现了身份识别,在 2~6 人场景下,准确率为 94.5%~88.9%^[14]。余星达等通过

分析子载波中 CSI 数据的空间相关性,提出了一种基于深度学习的非接触式身份识别算法 WiID,在 2~15 人场景下,准确率为 98.1%~82.0%^[15]。

虽然基于 CSI 的步态识别研究取得了一些成果,但由于 CSI 数据是信号及信道状态的综合反映,信号衰落、散射、多普勒频移和功率衰减等多种效应的叠加使得传统特征提取方法实施难度较大且效率低下,多人场景下识别准确率较低^[16-17]。此外,现有 Wi-Fi 感知步态识别研究中,大多数是将采集到的 CSI 作为一维时序数据流直接使用,未能很好地利用步态行为对不同频率子载波扰动结果差异较大的特征,存在步态特征获取不足问题。

本文针对传统基于 Wi-Fi 的步态识别中存在的步态特征获取不足、多人场景下识别准确率较低的问题,根据步态行为对子载波内和子载波间 CSI 信号的扰动关系,将一维时序 CSI 数据流重构为更能准确反映步态行为特征的频率能量图,使得数据特征容纳能力增强,并将频率能量图引入卷积神经网络,提出了一种步态识别模型 WiNet。WiNet 将频率能量图作为卷积神经网络的输入,经过特定的卷积-正则化-激活(CNR)模块和分类器模块处理后,实现了多人场景下准确率较高且鲁棒性较强的步态识别功能。

1 WiNet 模型

1.1 问题定义

在 Wi-Fi 环境下,步态行为对信道状态的扰动具有鲜明特征,可辨别性较强,因此可以作为身份识别的依据^[18]。由于接收端信号处理系统不能区分同时存在的多个动态干扰源,所以国内外目前还暂无同时识别多人步态的相关研究。和其他的步态识别模式类似^[10-15],本文的多人场景单目标步态识别,指的也是在多个采集样本前提下,在无线场景中存在单目标时进行的步态识别。此类应用场景包括小型智能办公场景的身份识别、居家环境中的入户身份识别等。

以 CSI 数据为分析源,在线性时不变假设下,通过对不同步态行为下的信道状态数据进行特征检测和识别,可以实现身份识别功能^[19]。CSI 数据包含子载波的幅度和相位,定义为

$$H(f_k) = |H(f_k)| e^{j\angle H(f_k)}, k \in [1, K] \quad (1)$$

式中: $H(f_k)$ 是以复数形式表示的第 k 个子载波的 CSI 数据; $|H(f_k)|$ 和 $\angle H(f_k)$ 分别是子载波的幅度和相位。由于人体对信号的有效反射面积随步态变化呈规律性变化,并最终反映在接收信号的振幅变化上,因此本文选用接收信号振幅作为步态特征的载体。

对于每一个接收的 CSI 数据包,都可以解析出一个结构为 $N_s \times N_r \times n$ 的多维数据矩阵,其中 N_s 表示发射端天线数量, N_r 表示接收端天线数量, n 表示 OFDM 信道中的子载波数量,矩阵元素表示接收信号振幅。每个 CSI 数据包具有 $N_s \times N_r$ 个数据流,每个数据流包含 n 个子载波。为了检测步态信息,接收端需要在时段 J 内持续采集 CSI 数据,得到 CSI 序列。

在目前基于 CSI 的步态识别研究中,大多数是把 J 时段内采集到的数据以一维时间序列的方式进行表示^[14,20]

$$\mathbf{X} = [H_{1,k} \ H_{2,k} \ \cdots \ H_{j,k} \ \cdots \ H_{J,k}]^T \quad (2)$$

式中 $H_{j,k}$ 表示 j 时刻第 k 个子载波的 CSI 数据。处理单载波时间序列的数据,仅能提取到载波内 CSI 数据变化规律反映的步态特征,而子载波间的步态特征获取不足,导致多人场景下步态识别准确率下降^[16-17]。考虑到采集数据中同时包含多个子载波的数据,而步态行为对不同频率子载波的扰动结果不同,所以将 J 时段内采集的 CSI 数据重构为一个二维矩阵

$$\mathbf{X} = \begin{bmatrix} H_{1,1} & H_{1,2} & \cdots & H_{1,k} & \cdots & H_{1,K} \\ H_{2,1} & H_{2,2} & \cdots & H_{2,k} & \cdots & H_{2,K} \\ \vdots & \vdots & & \vdots & & \vdots \\ H_{j,1} & H_{j,2} & \cdots & H_{j,k} & \cdots & H_{j,K} \\ \vdots & \vdots & & \vdots & & \vdots \\ H_{J,1} & H_{J,2} & \cdots & H_{J,k} & \cdots & H_{J,K} \end{bmatrix} \quad (3)$$

为方便问题定义,将式(3)表示为 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_j, \cdots, \mathbf{x}_J]^T$ 。将带有步态标签的 CSI 数据集表示为 $D = \{(\mathbf{X}_i, \mathbf{Y}_i)\}_{i=1}^I$, $\mathbf{X}_i$ 表示第 i 个 CSI 数据流, $\mathbf{Y}_i$ 表示相应步态标签, $i=1, 2, \cdots, I$ 。

由此,步态识别问题归结为:构建一个映射模型,根据输入的 CSI 数据多维矩阵 $\mathbf{X}$ 预测其对应的

步态标签 $\mathbf{Y}$ 。

1.2 频率能量图

根据式(3)的数据表示方式和 Wi-Fi 感知中 OFDM 和多输入多输出的技术特性,将多维度 CSI 数据重构成频率能量图。将接收到的 CSI 数据序列重构成频率能量图,不仅能形象地表示步态行为对接收端各子载波能量分布的影响,而且能包含更多的步态特征。

(1)频率能量图可以直观反映无线信号能量衰减结果。设载波频率为 f ,发射信号和接收信号的频域形式分别为 $T(f, t)$ 和 $R(f, t)$ 。由于多径效应,存在

$$R(f, t) = H(f, t)T(f, t) \quad (4)$$

式中 $H(f, t)$ 是载波的信道频率响应(CFR)。当人体在 Wi-Fi 环境下行走时,获取到的 CFR 是静态信号和动态信号叠加的结果,此时 $H(f, t)$ 可表示为

$$H(f, t) = \sum_n a_n e^{-j2\pi f \tau_n} + \sum_m a_m(t) \xi(f) e^{-j2\pi f \tau_m(t)} \quad (5)$$

式中: $\sum_n a_n e^{-j2\pi f \tau_n}$ 表示静态环境下的 CFR;

$\sum_m a_m(t) \xi(f) e^{-j2\pi f \tau_m(t)}$ 表示随时间 t 变化的动态 CFR。由于 CSI 是对 CFR 采样的结果,所以可以使用 CSI 近似表示环境对信道的影响结果。从式(1)可知,CSI 包含幅度和相位两部分数据,幅度反映了载波的能量信息,所以步态行为对 CSI 的扰动可以转换为对载波能量衰减的影响。

在 OFDM 技术中,多个子载波的能量在发射时均匀分布,但经过无线信道传输后,各个子载波的能量分布有明显变化,如图 1 所示。




图 1 无线信道对子载波能量分布的影响

在 Wi-Fi 环境中,由于不同个体体型和行走习惯不同,所以其步态行为对应的频率能量分布也不

同。因此,无线信号传播过程中因步态行为扰动而产生的能量衰减轨迹可以直观地反映在频率能量图中。

(2)频率能量图能容纳更多的步态特征。频率能量图分别以步态行为持续时长和子载波数量为矩阵的两个维度,不仅包含了子载波内的步态行为特征,而且包含了子载波间的步态行为特征。另外,考虑到不同天线接收的 CSI 数据在一定程度上反映了个体进入视距路径的空间位置^[21-23],可以将接收天线数量也作为一个维度,生成更高维度的频率能量图,以提取步态行为的空间特征。生成频率能量图时,首先要对采集到的二进制原始 CSI 数据进行预处理。预处理的操作包括对 DAT 格式的数据进行二进制转码,提取其中的振幅信息,生成格式为 CSV 的文件。预处理完成后的 CSV 文件包含了 5 s 时长的受测者步态信息。在 1 发 3 收的天线数量设置下,CSV 文件共包含了 1(接收端天线数)×3(接收端天线数)×30(子载波数)×5 000(时长,

5 000 ms)个的 CSI 振幅数据。取接收端 1 个天线接收到的 CSI 数据,即 $30 \times 5\,000$ 个反映步态特征的振幅数据,将其构成二维矩阵。对该二维矩阵使用 Matlab 编程中的 jet 方案进行着色,生成二维空间的可视化频率能量图。在 3 个不同测试周期内,3 个不同受测者步态对应的二维频率能量图如图 2 所示。

从图 2 可以看出,人体步态在频率能量图上有鲜明的特征辨识,并且相同个体步态对应的频率能量图相似性极大,不同个体步态对应的频率能量图差异明显。与传统数据组织策略相比,频率能量图不仅包含了步态行为的时间特征,而且包含了步态行为对子载波间信号扰动而形成的空间特征。

1.3 模型结构

将原始 CSI 数据重构成频率能量图后,步态行为的时间特征和空间特征得以完整保留,再结合卷积神经网络在多维矩阵特征提取方面的明显优势,设计了一种适用于 Wi-Fi 感知场景的步态识别模型




图 2 不同测试周期内不同受测者步态对应的频率能量图

WiNet,整体结构如图 3 所示。

WiNet 模型中:频率能量图生成部分的操作包括数据采集、数据选择和数据重构 3 部分;步态识别部分则以频率能量图作为输入,基于经典的卷积神经网络操作流程,经过多组 CNR 操作处理,使用 Softmax 方法进行分类,得到的最终输出即为步态识别的结果。

1.3.1 CNR 模块 WiNet 模型中,采用多组 CNR 联合操作的方式提取步态特征。每组 CNR 操作包括卷积、正则化和激活共 3 个操作。由于小卷积核能提取更加细致的特征,减少模型参数量,因此对于 CNR 中的卷积操作中均选用 3×3 的卷积核。通常情况下,卷积神经网络会在卷积层后增加最大池化层来进行下采样,用于减少参数量并防止模型过拟合。但是,由于频率能量图中特征密度较大,进行下采样会造成精度下降,由此可能导致特征丢失。所以,本文设计的 CNR 操作中不包含下采样,而是加入正则化,使每个神经元的输入固定在同一分布上。正则化层的引入不仅加速了模型收敛,还能防止模型过拟合,同时使模型对初始化操作的要求降低。另外,考虑到引入非线性因素可以使模型表达能力更强,在 CNR 操作中引入线性整流函数 Relu 进行激活操作。经频率能量图重构后的 CSI 数据包含了步态行为的主要特征,再经过多个 CNR 操作后,其中蕴含的特征信息被精确提取。在所有 CNR 操作中,均没有下采样操作,步态行为的特征信息基本

完整保留,为后续分类器模块提供了高质量的输入数据。

1.3.2 分类器模块 假设身份类别被分为 I 种, WiNet 的目标是创建一个深度学习模型,根据输入的频率能量图预测可能的身份。在 WiNet 模型中,由于要解决的是多类别分类问题,所以本文选择 Softmax 函数对步态进行分类,并计算出每个输出类别的预测概率为

$$\tilde{y}_i = P(y | X) = \frac{\exp(z_y)}{\sum_{y=1}^I \exp(z_y)}, y \in [1, I] \quad (6)$$

式中: X 是频率能量图; $\tilde{y}_i$ 是预测概率; z_y 是 CNR 模块输出内容再进行全局池化操作后的结果。采用全局池化操作,不仅使提取到的特征图与最终分类结果之间的转换更加简单自然,而且不需要大量训练参数,提高了模型的健壮性和抗过拟合能力。得到 $\tilde{y}_i$ 后,使用 Adam 优化器来对预测概率和真实标签概率 y_i 之间的交叉熵损失函数进行最小化训练,公式为

$$L = - \sum_i y_i \log(\tilde{y}_i) \quad (7)$$

通过使用交叉熵函数作为优化目标,可以使得训练数据上学习到的预测数据分布和真实数据分布保持较好的一致性。经过多次迭代,WiNet 模型的各项评估指标均达到现阶段研究的先进水平,在基于 Wi-Fi 感知的多人场景步态识别中表现出较好的性能。





图 3 WiNet 模型结构

2 实验及结果分析

2.1 数据采集

无线信号在室内传播时会受到多径效应的显著影响。为保证实验数据的客观性和代表性,需要考虑模型在不同多径效应环境下的运行效果。本文选择弱多径效应和强多径效应两种典型室内环境进行步态识别实验。弱多径效应环境开阔,遮挡物较少,信号传播路径相对简单,如图 4a 所示。强多径效应环境场所紧凑,各类物品较多,信号传播路径较为复杂,如图 4b 所示。



(a)弱多径效应环境

(b)强多径效应环境

图4 数据采集环境

对于两种多径环境,均采集了 40 名(男性 20 名,女性 20 名)受测者步态行为的 CSI 数据作为训练集和测试集。受测者年龄介于 18~30 岁之间,能充分保证数据的多样性和代表性。数据采集时,每次有 1 名受测者沿着垂直于发射端和接收端之间的路径往返行走,每次行走时间为 5 s,重复行走 80 次。行走时,受测者有穿越视距路径的过程。

由于目前在 Wi-Fi 步态感知研究领域,国内外还没有公开的权威数据集,因此 WiNet 模型的验证和评估均基于本文团队的数据集。

2.2 实验设置

实验中包括两个不同的 Wi-Fi 设备:作为发射端的 TP_LINK AC1750 无线路由器,作为接收端的 ThinkPad X201 便携式计算机,该计算机配备有 Intel 5300 802.11n WiFi NIC 网卡。在接收端设备上,安装有开源的 CSI Tool 工具,完成对 CSI 信息的实时采集。发射端和接收端分别拥有 1 个和 3 个可检测天线,形成 3(1×3)个 CSI 数据流。每个 CSI 数据流由 30 个子载波组成,经 OFDM 技术调制后发射出去。实验共采集了 90(1×3×30)个 CSI 数据流。由于 Wi-Fi 设备工作在 2.4 GHz 下,同频干扰较多,且由于波长较长不易感知更细粒度的人体运动,为保证数据完整性和准确性,本文所有实验均在 5 GHz 频率下完成,并设置接收端对 CSI 数据包的采样率为 1 000 数据包/s。根据单个步态有效动

作的经验完成时间,设置滑动窗口长度为 600 ms、滑动步长为 200 ms 来构建样本数据,生成不同的频率能量图。相邻滑动窗口之间的重叠部分可以确保数据分割后的连续性,有利于提取到更多的特征信息。

对于深度学习工具,本文选取 Keras 深度学习框架,并以 Python 语言实现模型构建。对于运行环境,WiNet 模型的训练和测试均是在普通计算机上完成,该计算机配备一块 NVIDIA 1080Ti 显卡。对于采集的 CSI 数据,使用受测者姓名作为标签,并将相应频率能量图输入 WiNet 模型进行有监督学习。WiNet 模型的学习率设置为 0.000 1,使用 Adam 优化器最小化损失。在数据集划分上,训练数据量和测试数据量分别占所有采集 CSI 数据量的 80%和 20%。在 WiNet 模型训练完成后,通过测试集评价识别效果。

2.3 评估指标

本文分别采用准确率、召回率、精准率与 F1 分数来评估模型的识别效果。准确率 A 为所有正确预测数占总预测数的比重。召回率 C 为正确预测正值占全部实际正值的比例。精准率 P 为正确预测正值占全部预测正值的比例。 $F1$ 分数 S_{F1} 综合了召回率与精准率,反映了整体情况。各评估指标公式为

$$A = \frac{S_{TP} + S_{TN}}{S_{TP} + S_{TN} + S_{FP} + S_{FN}} \quad (8)$$

$$C = \frac{S_{TP}}{S_{TP} + S_{FN}} \quad (9)$$

$$P = \frac{S_{TP}}{S_{TP} + S_{FP}} \quad (10)$$

$$S_{F1} = \frac{2S_{TP}}{2S_{TP} + S_{FP} + S_{FN}} \quad (11)$$

式中: S_{TP} 为属于该类且被分类器分为该类的样本数; S_{FP} 为不属于该类但被分类为该类的样本数; S_{FN} 为属于该类但被分类为不属于该类的样本数; S_{TN} 为不属于该类且被分类为不属于该类的样本数。

2.4 实验结果及分析

为了全面评估 WiNet 模型的识别效果,分别设计了不同人数、不同模型和不同状态的对比实验,并对实验结果进行详细分析。

2.4.1 不同人数对比 为验证 WiNet 模型在多人场景下的识别效果,分别设计了 10、20(含前 10 人)、30(含前 20 人)、40(含前 30 人)人场景下的识别实验。对于 10 人场景,使用相应人数的 CSI 数据进行完整训练。对于其他人数场景,只需对增量

CSI 数据进行训练,再把该模型和已训练好的场景模型进行参数合并,即可得到该场景下的训练模型。在弱多径效应室内环境中,WiNet 模型不同人数的实验结果如表 1 所示。

表 1 WiNet 模型不同人数的实验结果


人数	A/%	C/%	P/%	S _{F1}
10	100.0	100.0	100.0	1.000
20	100.0	100.0	100.0	1.000
30	98.8	98.8	98.6	0.987
40	98.7	98.6	98.6	0.986

从表 1 可以看出,弱多径效应室内环境下的遮挡物较少,信号传播路径较为简单,依靠频率能量图较强的特征包含能力和 CNR 模型精确的特征提取能力,WiNet 模型表现较好,在 20 人以内准确率达到 100%,在 40 人时准确率仍保持在 98.5%。现有类似研究中,在人数增加后,由于存在反射面积相似的个体,步态特征的区分度下降,导致模型识别准确率明显下降。在 WiNet 模型中,通过引入频率能量图,综合考虑了步态行为的时间特征和空间特征,对步态特征的刻画更为全面准确,在多人场景下识别准确率仍较高。


2.4.2 不同模型对比 为了评估 WiNet 模型和其他模型的对比情况,本文在弱多径效应环境中,设计了 10、20、30、40 人场景的步态识别实验,并分别使用循环神经网络 GRU^[24]、全卷积神经网络 FCN^[25]、WiID 模型^[15]和本文 WiNet 模型进行对比实验,实验结果如图 5 所示。对比模型为经典分类模型或无线感知步态识别最新模型:GRU 是处理时间序列数据的经典模型,FCN 是图像分类的常用模型,WiID 是利用 CSI 信号进行步态识别的最新模型。在对比实验中,GRU 包含 2 个 GRU 层,FCN 包含 3 个卷积层,WiID 设置和原文一致。

从图 5 可以看出,随着人数的增多,GRN 和 WiID 的各项评估指标均有明显下降,而 WiNet 和 FCN 则较为平稳,但 WiNet 的表现要好于 FCN 的。当识别样本数达到 40 人时:GRU 和 WiID 的分类能力出现快速下降,分别只有 67.4%和 65.6%的准确率;FCN 由于采用全连接设置,特征不易丢失,准确率达到 95.0%;WiNet 模型由于采用频率能量图和多 CNR 操作,能够较完整及准确地提取 CSI 信息中蕴含的步态特征,识别性能在 4 个模型中最好,准确率达到 98.7%,F1 分数达到 0.986。


2.4.3 不同状态对比 在 Wi-Fi 感知中,个体携带




(a) 准确率



(b) 召回率



(c) 精准率



(d) F1 分数

图 5 不同模型评估指标对比

附着物(如穿衣、携带物品等)或偏离 Wi-Fi 视距路径均会影响信号的传播路径,进而对 CSI 信号中反映的步态特征造成影响。为评估 WiNet 模型的鲁

棒性,本文分别在弱多径效应环境和强多径效应环境中,对不同个体状态的步态行为进行测试。设计了正常情况、改变穿着、携带背包、携带提包及路径偏移共 5 种不同的状态。正常情况状态指训练数据采集环境下的状态;改变穿着状态指参与者们分别穿着薄 T 恤、羽绒服、带上帽子等不同于正常情况中的状态;路径偏移状态指采集测试数据时要求受测者在偏离预定路径 1 m 处行走。每名受测者采集 30 组数据。10 名受测者在两种环境下的准确率如表 2 所示。

表 2 WiNet 模型在不同环境和状态下的准确率

环境 类别	A/%				
	正常 情况	改变 穿着	携带 背包	携带 提包	路径 偏移
弱多径效应	100.0	99.4	99.7	98.9	97.0
强多径效应	96.0	95.6	95.2	94.9	92.0

由表 2 可以看出,在改变穿着、携带背包、携带提包、路径偏移这 4 种状态下,WiNet 模型的准确率会有不同程度的降低。这是因为附着物或偏离视距路径会导致 CSI 信号相比正常情况状态的传播路径有一定变化,影响步态特征匹配。在携带背包和携带提包状态下,人体的反射面积增大,而路径偏移更是改变了反射面积的变化周期,二者均会对信号的多径传播造成影响。另外,由于强多径效应环境下的遮挡物较多,状态变化对模型的影响程度比对弱多径效应环境的更为明显。虽然在环境、附着物、路径偏移等因素的影响下,WiNet 模型的准确率有一定下降,但仍保持在 92% 以上,说明场景和状态的变化对模型识别率影响有限,体现出模型良好的鲁棒性。

2.4.1~2.4.3 小节不同人数、不同模型和不同状态的实验结果表明,依靠频率能量图的强特征包含能力和卷积神经网络的强特征提取能力,WiNet 模型一定程度上解决了现有研究中存在的特征提取不足及多人场景识别准确率下降较快问题,对基于 Wi-Fi 感知的步态识别研究有积极意义。

3 结 论

传统基于 Wi-Fi 的步态识别模型,大多数将采集到的 CSI 数据以一维时间序列形式来处理,对步态行为的特征考虑不足,在多人场景下难以达到较高的识别准确率。本文提出的 WiNet 模型,将 CSI 数据重构成频率能量图,并且基于卷积神经网

络进行步态识别,能较为准确地提取步态行为的特征,在样本量较大的多人场景中识别单目标取得了较好的效果。实验结果表明,WiNet 模型不仅对多人场景识别具有较高的准确率,而且在人体有不同附着物的情况下仍表现较好,具有较强的鲁棒性。

由于多径效应的存在,基于 Wi-Fi 的步态识别模型对环境的依赖较大,相同模型在不同环境中的识别准确率差异较大,WiNet 模型仍存在一定的局限性。本文后续将从以下方面继续开展研究:①在已获取 CSI 振幅数据的基础上,结合相位信息丰富步态特征的描述方式,进一步提升识别准确率;②研究模型在不同室内环境中的泛化能力,进一步提高 Wi-Fi 环境下步态识别模型的应用价值。

参考文献:

[1] CONNOR P, ROSS A. Biometric recognition by gait: a survey of modalities and features [J]. Computer Vision and Image Understanding, 2018, 167: 1-27.

[2] 贾晔焱,徐森,王科俊. 行人步态的特征表达及识别综述 [J]. 模式识别与人工智能, 2012, 25(1): 71-81.

BEN Xianye, XU Sen, WANG Kejun. Review on pedestrian gait feature expression and recognition [J]. Pattern Recognition and Artificial Intelligence, 2012, 25(1): 71-81.

[3] WU Z F, HUANG Y Z, WANG L, et al. A comprehensive study on cross-view gait based human identification with deep CNNs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(2): 209-226.

[4] 贾晔焱,张鹏,孙成立,等. 均值张量成分分析及其在步态识别中的应用 [J]. 西安交通大学学报, 2015, 49(12): 40-46.

BEN Xianye, ZHANG Peng, SUN Chengli, et al. A mean tensor component analysis and its application in gait recognition [J]. Journal of Xi'an Jiaotong University, 2015, 49(12): 40-46.

[5] ZHANG Y T, PAN G, JIA K, et al. Accelerometer-based gait recognition by sparse representation of signature points with clusters [J]. IEEE Transactions on Cybernetics, 2015, 45(9): 1864-1875.

[6] NAIMI I A, WONG C B, MOORE P, et al. Multimodal approach for non-tagged indoor identification and tracking using smart floor and pyroelectric infrared sensors [J]. International Journal of Computational Science and Engineering, 2017, 14(1): 1-15

[7] Wi-Fi Alliance. Wi-Fi in 2019 [EB/OL]. (2019-02-21) [2020-01-10]. <https://www.wi-fi.org/news->

- events/newsroom/wi-fi-in-2019.
- [8] WANG J, ZHAO Y N, FAN X X, et al. Device-free identification using intrinsic CSI features [J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8571-8581.
 - [9] ABDELNASSER H, HARRAS K, YOUSSEF M. A ubiquitous WiFi-based fine-grained gesture recognition system [J]. IEEE Transactions on Mobile Computing, 2019, 18(11): 2474-2487.
 - [10] SHI C, LIU J, LIU H B, et al. Smart user authentication through actuation of daily activities leveraging WiFi-enabled IoT [C]// Proceedings of the 18th ACM International Symposium on Mobile Ad Hoc Networking and Computing (MobiHoc). New York, USA: ACM, 2017: 1-10.
 - [11] WANG W, LIU A X, SHAHZAD M. Gait recognition using WiFi signals [C]// Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing. New York, USA: ACM, 2016: 363-373.
 - [12] ZENG Y Z, PATHAK P H, MOHAPATRA P. WiWho: WiFi-based person identification in smart spaces [C] // Proceedings of the 15th International Conference on Information Processing in Sensor Networks. Piscataway, NJ, USA: IEEE, 2016: 7460727
 - [13] ZHANG J, WEI B, HU W, et al. WiFi-ID: human identification using WiFi signal [C] // Proceedings of the 12th Annual International Conference on Distributed Computing in Sensor Systems (DCOSS). Piscataway, NJ, USA: IEEE, 2016: 75-82.
 - [14] XIN T, GUO B, WANG Z, et al. FreeSense: indoor human identification with WiFi signals [C]// Proceedings of the 2016 IEEE Global Communications Conference (GLOBECOM). Piscataway, NJ, USA: IEEE 2016: 7841847.
 - [15] 余星达, 陈文杰, 王鼎, 等. 非接触式身份识别的深度学习算法 [J]. 西安交通大学学报, 2019, 53(4): 122-127.
YU Xingda, CHEN Wenjie, WANG Ding, et al. A deep learning algorithm for contactless human identification [J]. Journal of Xi'an Jiaotong University, 2019, 53(4): 122-127.
 - [16] OHARA K, MAEKAWA T, MATSUSHITA Y. Detecting state changes of indoor everyday objects using Wi-Fi channel state information [J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2017, 1(3): 88.
 - [17] POKKUNURU A, JAKKALA K, BHUYAN A, et al. Neuralwave: gait-based user identification through commodity WiFi and deep learning [C]// Proceedings of the 44th Annual Conference of the IEEE Industrial Electronics Society (IECON). Piscataway, NJ, USA: IEEE, 2018: 758-765.
 - [18] WEI B, HU W, YANG M R, et al. Radio-based device-free activity recognition with radio frequency interference [C]// Proceedings of the 14th International Conference on Information Processing in Sensor Networks. New York, USA: ACM, 2015: 154164.
 - [19] ALAM M R, BENNAMOUN M, TOGNERI R, et al. A joint deep Boltzmann machine (JDBM) model for person identification using mobile phone data [J]. IEEE Transactions on Multimedia, 2017, 19(2): 317-326.
 - [20] CHEN Z H, ZHANG L, JIANG C Y, et al. WiFi CSI based passive human activity recognition using attention based BLSTM [J]. IEEE Transactions on Mobile Computing, 2019, 18(11): 2714-2724.
 - [21] ALI K, LIU A X, WANG W, et al. Recognizing keystrokes using WiFi devices [J]. IEEE Journal on Selected Areas in Communications, 2017, 35(5): 1175-1190.
 - [22] LIU Z J, LIU X L, ZHANG J W, et al. Opportunities and challenges of wireless human sensing for the smart IoT world: a survey [J]. IEEE Network, 2019, 33(5): 104-110.
 - [23] 鲁勇, 吕绍和, 王晓东, 等. 基于 WiFi 信号的人体行为感知技术研究综述 [J]. 计算机学报, 2019, 42(2): 1-21.
LU Yong, LÜ Shaohe, WANG Xiaodong, et al. A survey on WiFi based human behavior analysis technology [J]. Chinese Journal of Computers, 2019, 42(2): 1-21.
 - [24] MOU L C, GHAMISI P, ZHU X X. Deep recurrent neural networks for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3639-3655.
 - [25] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651

(编辑 陶晴)