计 算 机 研 究 与 发 展
Journal of Computer Research and Development
https://crad.ict.ac.cn
62(3): 720−732, 2025

Wi-HFM: 基于 WiFi 信道特征的人流量监测方法

杨志勇　卢　超　王俊杰
（南昌航空大学软件学院　南昌　330063）
（yangzhy@nchu.edu.cn）

Wi-HFM: A Human Flow Monitoring Method Based on WiFi Channel Features

Yang Zhiyong, Lu Chao, and Wang Junjie
（*School of Software*, *Nanchang Hangkong University*, *Nanchang* 330063）

Abstract　With the increasing demand for people counting, the technology of human flow monitoring based on channel state information (CSI) attracts much attention because of its advantages such as easy deployment, privacy protection and strong applicability. However, in the existing human flow monitoring work, the accuracy of pedestrian recognition is easily affected by the density of the crowd. To ensure the monitoring accuracy, the monitoring can only be carried out when the crowd is sparse, which leads to the lack of practicability of the human flow monitoring technology based on CSI. In order to solve this problem, a monitoring method that can identify continuous flow of people is proposed. The method firstly uses phase unwrapping and linear phase correction algorithm to eliminate random phase offset and phase compensation for original data, then extracts valid data packets from continuous flow data by standard deviation and variance, and finally inputs phase difference information in the time domain as feature signals into the deep learning convolutional, long short-term memory, deep neural network (CLDNN) for pedestrian recognition. After actual testing, the method achieves outdoor accuracy of 96.7% and indoor accuracy of 94.1% under the condition that the distance between pedestrians in front and back is not less than 1 m, outperforming the existing method of human flow monitoring.

Key words　channel state information (CSI); human flow monitoring; continuous human flow; phase correction; deep learning

摘　要　随着人们对人数统计需求的不断增长，基于信道状态信息（channel state information, CSI）的人流量监测技术因其易于部署、保护隐私和适用性强等优势而备受关注. 然而，在现有的人流量监测工作中，人数识别的准确率容易受到人群密集程度的影响. 为了保证监测精度，通常只能在人群稀疏的情况下进行监测，这导致了基于 CSI 的人流量监测技术缺乏实用性. 为了解决这一问题，提出了一种能够识别连续性人流的监测方法. 该方法首先利用解卷绕和线性相位校正算法，对原始数据进行相位补偿并消除随机相位偏移；然后通过标准差和方差提取连续性人流数据中的有效数据包；最后将时域上的相位差信息作为特征信号输入到深度学习的 CLDNN（convolutional, long short-term memory, deep neural network）中进行人数识别. 经过实验测试，该方法在前后排行人距离不小于 1 m 的情况下，分别实现了室外 96.7% 和室内 94.1% 的准确率，优于现有的人流量监测方法.

关键词　信道状态信息；人流量监测；连续性人流；相位校正；深度学习

收稿日期：2023-08-31；**修回日期**：2024-06-24

基金项目：国家自然科学基金青年科学基金项目（61501218）；江西省自然科学基金项目（20181BAB202015）
This work was supported by the National Natural Science Foundation of China for Young Scientists (61501218) and the Natural Science Foundation of Jiangxi Province (20181BAB202015).

中图法分类号 TP393

DOI: 10.7544/issn1000-1239.202330712 **CSTR:** 32373.14.issn1000-1239.202330712

近年来，随着无线网络技术的快速发展和无线设备的大规模部署，无线感知技术受到了国内外研究学者的高度关注，并且被广泛地应用在室内定位[1]、动作识别[2]和人数统计等各个领域. 作为人数统计的主要方式之一，人流量计数是公共场所实施科学人数管理的关键手段. 通过实时监测特定空间区域内的人流量，能够有效预防因人群拥挤而引发的安全隐患.

为了实现高精度的人数统计，研究人员相继提出了基于通道闸机、计算机视觉和无线信号的计数方法[3]. 在无线信号领域，WiFi 以其普适性强、功耗较低、保护隐私等特点脱颖而出. 发送端发射出的 WiFi 信号会经过多种路径，包括直线传播、通过物体反射以及经过衍射等，最终到达接收设备，形成多径传播的信号. 在 WiFi 标准中，通常使用接收信号强度指示（received signal strength indicator, RSSI）和信道状态信息（channel state information, CSI）来描述无线信道. RSSI 代表了多条传输路径上信号叠加的总和，无论在传输过程中哪条路径上的信息发生变化，接收端接收到的 RSSI 值都会随之相应变化[4]. 因此 RSSI 很容易受到多径和环境变化等因素的影响，基于 RSSI 技术的人流量计数在精度上始终难以得到较大突破.

CSI 信号携带了通信链路中各种基本属性，与 WiFi 无线信道的其他信息不同，它具有更高的敏感度和更精细的分辨率. 这种信号能够描述信号传输过程中产生的振幅衰减、相位偏移和时延等变化情况[5]. 由于 IEEE802.11n 系列通信协议及其之后的无线局域网协议采用了正交频分复用（orthogonal frequency division multiplexing, OFDM）和多输入多输出（multiple in multiple out, MIMO）技术[6]，可以很容易地在商用 WiFi 设备中获取 CSI 信息. 经过从 CSI 信号中提取出适用于不同人数的高鲁棒性特征信号后，与机器学习算法相融合，可以构建人流量监测模型，从而实现高度准确的人流量计数. 然而，当前这类方法面临着 2 个主要问题.

最初，很多研究都倾向于从商用 WiFi 的 CSI 信号中提取时域特征，以供后续的识别工作使用. 然而，商用 WiFi 的 CSI 信号不仅仅包括振幅信息，还包含了相位信息. 因此，需要对这 2 种信息进行分析验证，确定哪种信息更能够准确地反映人体的存在和移动. 此外，目前基于 CSI 的人流量计数主要关注人群稀疏的情况，未能实现人群密集时的连续人流量监测. 针对以上问题，本文提出了一种基于 WiFi 信道特征的人流量监测方法 Wi-HFM，该方法通过商用 WiFi 设备获取不同人数对应的 CSI 信息，利用解卷绕和线性相位校正对原始数据进行预处理，再采用巴特沃斯滤波器降噪，使用主成分分析（principal component analysis, PCA）算法对特征进行降维. 最后把时域上的相位差输入到卷积长短时深度神经网络（convolutional, long short-term memory, deep neural network, CLDNN）中进行人数的分类并生成识别结果. 本文的主要贡献有 3 个方面：

1）针对现有 WiFi 设备中所获取的 CSI 中包含振幅和相位 2 种信息的情况，本文利用传统特征的方式比较 CSI 中振幅信息和相位差信息的有效性. 验证了时域上的相位差信息优于振幅信息，用以表征不同人数对无线信号的影响.

2）针对当前基于 CSI 技术的人流量计数方法在人群密集场景下应用受限的问题，本文加入了连续性人流量监测，通过标准差和方差提取连续性人流数据中的有效数据包，来处理收发装置视距内的多排人群数据.

3）在人流量监测模型构建的阶段，本文采用了 CNN（convolutional neural network）以提取 CSI 的空间特征，同时采用 LSTM（long short-term memory）提取信号的时域特征. 通过这种方法，成功构建了 CLDNN 模型用于监测人流量的变化.

1 相关工作

1.1 人群计数

人群计数是对特定空间内的人数进行统计. 早期人群计数通过传统的计算机视觉技术来提取行人特征，然后采用目标检测或回归的方法来获得图像或视频中的人群数量[7]. 例如，Lin 等人[8]提出了一个多方面注意力网络，以增强 transformer 模型在空间局部上下文编码中进行人群计数的能力，优化了人群图像中频繁出现的显著尺度变化问题. 目前基于计算机视觉的人群计数主要依赖于有限的 RGB 图像数据，而 Liu 等人[9]则采用了融合光学与热信息的策略来实现对行人的识别. 实验结果证明了这一方法在

多模态(例如 RGBT 和 RGBD)人群计数方面的有效性，能够在各种不受限制的场景中探测到可能存在的行人. 虽然摄像机安装方便，但是现有的计算机视觉方法大多需要收集大量的图像或视频数据，这引发了对于数据隐私的担忧. 为了克服一些场景下所面临的隐私保护问题，基于传感器技术和无线信号技术的人群计数获得了越来越多的关注.

基于传感器的人群计数将选定的传感器(如红外传感器、深度传感器和微波传感器等)安装在需要监测的区域内，通过计算和分析传感器数据，识别当前区域内的人数. Liu 等人[10] 采用了成对配置的红外距离传感器，以监测公交车上的乘客数量，其实验结果实现了 95% 的精确度. 文献 [11] 提出了一种基于置于场景顶部的 Kinect 传感器的新型算法，通过在深度图像中检测人们的头部来实现其轨迹跟踪. 利用 SVM 分类器来区分是否为人类的头部，有效解决了拥挤场景下的人群遮挡问题. 然而传感器数据精度受到其技术特性和安装位置的限制，同时一些传感器需要连续运行，这可能会导致不小的能耗，尤其在长时间监测人群的情况下.

基于无线信号的人群计数方法主要依托于分析人体对无线信号(如雷达、WiFi 等)的影响，以统计人群数量. Choi 等人[12] 提出了一种基于 IR-UWB(impulse radio ultra-wideband)雷达的行人计数系统，该系统利用 2 个配备窄波束宽度天线的雷达传感器，在路径中形成 2 个不可见的电子层，用于统计某个区域中行走的人数. 文献[13] 提出了 CrossCount，它使用单个 WiFi 链路来估计区域的人数. 其主要思想是处理 WiFi 链路阻塞间隔，而不是依赖于从 RSSI 值中提取的统计特征. 在新冠病毒大流行的背景下，Sharma 等人[14] 利用 CSI 幅度的频率来测定特定区域内的人数分布，以维持社交距离. 实验证明该系统能够有效监测电梯内人数是否超出新冠肺炎的安全限制，其准确率高达 97%，具有高鲁棒性和良好的可扩展性.

1.2 人流量计数

人流量计数是对通过一个特定通道的人数进行统计. 目前，人流量计数领域的方法相对有限，主要分为 2 类：通道闸机和无线信号的计数方法. 通道闸机通过在出入口安装闸机(例如转门、门禁闸、电子闸机等)来实时感知人员的进出情况. 文献 [15] 利用 8 组红外传感器对闸机通道进行物体检测，并应用 ARIMA 模型分析历史闸机通道的客流量数据，以预测不同时间段的客流情况. 然而，在高峰时段通道闸机的处理速度较为缓慢，这会导致人们排队等候和时间延误的情况，从而限制了进出特定区域的人员流动.

随着无线网络技术的兴起，人们逐渐开始探索以无线信号实现人流量计数的可能性，WiFi 因其低成本、易于部署等优势得到广泛应用. 研究初期，人们利用 RSSI 来实现人流量计数. 其原理是根据信号强度的变化来估计出监测区域人员的数量. 文献 [16] 使用支持向量机来探究 RSSI 与人数之间的关系，但是实验结果显示，仅达到 77% 的准确率，因此在实际应用中存在较大局限性. CSI 相对于 RSSI 具有更高的信号分辨率，能够提供更详细的信道状态信息，从而在一定程度上减小信号强度波动对应用的影响. Yang 等人[17] 提出了一种名为 Door-Monitor 的访客计数系统，该系统对相位差序列进行了短时傅里叶变换，并在此基础上应用卷积神经网络建立计数模型. Zhou 等人[18] 利用人类通过 WiFi 设备所引起的多普勒效应，提出了 WiFlowCount. 该方法利用 CSI 信号构建多普勒频移的频谱图，根据频谱图中的功率分布检测人流. 但是该方法需要个体之间保持较大的间距，因此其实际可行性受到限制.

2 Wi-HFM 模型概述

2.1 WiFi 人流量监测原理

在利用 WiFi 信号来估计人流量时，需要建立 CSI 信号与人数之间的映射关系. 在监测环境中，不同的人数可能导致 CSI 信号在传播过程中发生不同程度的反射和衍射，从而产生多径效应. 当有 N 条传播路径在时刻 t 到达接收端时，信号的理想信道频率响应[19](channel frequency response, CFR)表达式为：

$$H(f,t)=\mathrm{e}^{-\mathrm{j}2\pi\Delta ft}\sum_{k=1}^{N}a_k(f,t)\mathrm{e}^{-\mathrm{j}2\pi f\tau_k(t)}, \tag{1}$$

其中 f 为载波频率，$\mathrm{e}^{-\mathrm{j}2\pi\Delta ft}$ 表示由载波频移导致的相位差，$a_k(f,t)$ 则表示第 k 条路径上的衰减以及初始相位[20]，$\mathrm{e}^{-\mathrm{j}2\pi f\tau_k(t)}$ 表示第 k 条路径上的相位偏移，其时延为 $\tau_k(f,t)$.

在无线通信领域，多径效应包括静态路径和动态路径 2 个部分[21]. 静态路径被看作是与人体影响无关的部分，可用 $H_{\mathrm{s}}(f,t)$ 来表示. 与此不同，动态路径被视为受到人体影响的部分，可以用 $H_{\mathrm{d}}(f,t)$ 来表示：

$$H_{\mathrm{d}}(f,t)=\sum_{k\in P_{\mathrm{d}}}a_k(f,t)\mathrm{e}^{-\frac{1}{\lambda}\mathrm{j}2\pi d_k(t)}, \tag{2}$$

其中 P_{d} 为所有动态路径. 结合式(1)(2)可得总的信道频率响应为

$$H(f,t)=\mathrm{e}^{-\mathrm{j}2\pi\Delta ft}\left(H_{\mathrm{s}}(f,t)+\sum_{k\in P_{\mathrm{d}}}a_k(f,t)\mathrm{e}^{-\frac{1}{\lambda}\mathrm{j}2\pi d_k(t)}\right). \quad (3)$$

通过上述公式的推断，信道频率响应包含了有关 CSI 信号的全部信息，呈现出与人数变化相互关联的趋势，从而证实了 CSI 人流量监测的可行性. 在窄带平坦衰落信道中，假设发送信号向量为$\boldsymbol{x}$，接收信号向量为$\boldsymbol{y}$，那么有[22]

$$\boldsymbol{y}=\boldsymbol{H}\boldsymbol{x}+\boldsymbol{z}, \quad (4)$$

其中$\boldsymbol{z}$为环境噪声向量，$\boldsymbol{H}$为信道矩阵. 根据 IEEE802.11 协议标准，CSI 被划分为 30 个子载波，则$\boldsymbol{H}$表示为

$$\boldsymbol{H}=(\boldsymbol{H}_1,\boldsymbol{H}_2,\cdots,\boldsymbol{H}_{30}). \quad (5)$$

对于单个子载波，CSI 的形式为：

$$\boldsymbol{H}_i=\boldsymbol{h}_i\mathrm{e}^{\mathrm{j}\sin\theta_i}, \quad (6)$$

其中$|\boldsymbol{h}_i|$表示第 i 个子载波的振幅信息，θ_i为第i子载波的相位信息. 由式(6)可知 CSI 是对每条传输链路中的每个子载波的估计，当有人进入收发装置视距的位置时，CSI 信号中的振幅和相位信息会出现变化，因此可以通过建立人数与 CSI 数据信息之间的关联来实现人流量的监测.

2.2 Wi-HFM 模型工作机制

如图 1 所示，Wi-HFM 系统的工作流程可划分为 4 个关键阶段，包括数据获取、数据处理、特征提取和分类识别. 在数据获取阶段，采用商用 WiFi 设备建立了 AP(access point)模式，包括 1 个发送天线和 3 个接收天线，通过组织人员进行人流量模拟实验以获取多组单排人流和多排人流数据. 在数据处理阶段，充分利用信道状态信息测量值中的细粒度信息，分别对振幅信息和相位信息进行预处理，包括清洗数据、选择天线对和提取数据包等.

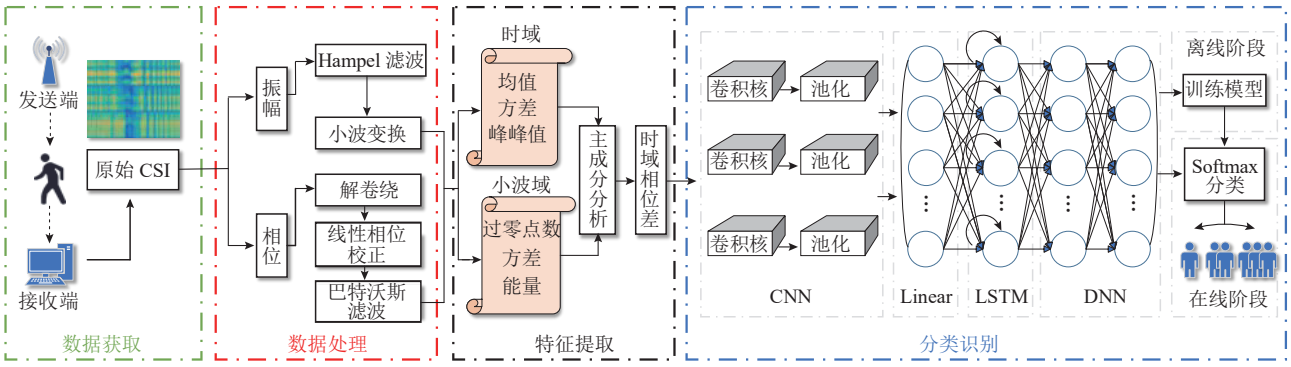


Fig. 1 Flow chart of Wi-HFM model

图 1 Wi-HFM 模型工作流程图

在特征提取阶段，为了获取最优的特征信号以精确地描述人数对无线信号的影响，本文采用主成分分析对从时域和小波域中提取的特征信号进行了降维处理. 通过分析特征信号在时域和时频域上的效果，最终确定了时域中的相位差作为主要的识别特征信号. 在分类识别阶段，使用深度学习来探索 CSI 数据中的潜在特征. 本文选择了卷积神经网络以有效地提取信号的空间特征，以及循环神经网络来提取信号的时域特征，从而构建了一个名为 CLDNN 的人流量监测模型.

3 Wi-HFM 的设计与实现

3.1 CSI 数据处理

通过商用 WiFi 设备收集到的 CSI 信号中主要包含振幅和相位 2 种物理信息，但是原始 CSI 数据中掺杂了大量的异常值以及噪声，需要对其分别进行预处理，从而为后续特征信号的确立提供优质数据集. 这 2 种物理信息的预处理过程十分类似，都包括定位天线对、定位数据包和数据清洗等步骤，本文将以相位的预处理为例，以此阐述 CSI 信号预处理的总过程. 传统的 CSI 采集工具[23]所测得的子载波i的相位信息，可以被表达为

$$\hat{\phi}_i=\phi_i+2\pi\frac{k_i}{N_f}\alpha_i+\beta_i+Z, \quad (7)$$

其中$\hat{\phi}_i$表示原始相位，ϕ_i为真实相位，k_i是第i路子载波的索引值，N_f为 FFT 点数，α_i是时钟同步误差，β_i是载频同步误差，Z是噪声. 根据式(7)，因设备之间时间不同步，会带来时钟同步误差和载频同步的残余误差. 尽管这些残余误差对 CSI 的振幅影响较小，在大多数情形下或可忽略，然而对于 CSI 的相位而言，却会有较为显著的影响，导致了相位偏移的产生.

为了获取准确的相位信息，本文通过解卷绕[24]和线性相位校正[25]对相位进行预处理. 解卷绕旨在

对相位进行修正，将子载波原本的相位范围进行补偿和延拓. 线性校准算法则致力于消除由线性相位误差如载波频偏(carrier frequency offset, CFO)和符号同步偏移(symbol timing offset, STO)引起的随机相位偏移，因此线性相位校正的主要目标在于削弱式(7)中 α 和 β 所产生的影响. 定义关键变量 μ 和 ν：

$$\mu=\frac{\hat{\phi}_{i,n}-\hat{\phi}_{i,1}}{k_n-k_1}=\frac{\phi_{i,n}-\phi_{i,1}}{k_n-k_1}-\frac{2\pi}{N_f}\alpha_i, \tag{8}$$

$$\nu=\frac{1}{n}\sum_{j=1}^{n}\hat{\phi}_{i,j}=\frac{1}{n}\sum_{j=1}^{n}\phi_{i,j}-\frac{2\pi\sigma_i}{nN_f}\sum_{j=1}^{n}k_j+\beta. \tag{9}$$

式(9)中，i表示数据包序号，j为子载波序号，k_j表示第j个子载波索引值，n为子载波个数. 假设 CSI 中的子载波是对称的，即 $\sum_{j=1}^{n}k_j=0$，那么可以得到 $\nu=\frac{1}{n}\sum_{j=1}^{n}\phi_{i,j}+\beta$. 从原始相位中减去线性变量 $\mu k_i+\nu$ 得：

$$\tilde{\phi}_i=\hat{\phi}_i-\mu k_i-\nu=\phi_i-\frac{\phi_n-\phi_1}{k_n-k_1}k_i-\frac{1}{n}\sum_{j=1}^{n}\phi_j. \tag{10}$$

经过相位的校正处理，获得的结果是真实相位经过线性变换得到的值. 此外，经过校正后的相位方差与实际相位方差之间存在一个缩放因子，该缩放因子为常数 c_i，其大小与频率相关：

$$\sigma_{\tilde{\phi}_i}^2=c_i\sigma_{\phi_i}^2, \tag{11}$$

$$c_i=1+2\frac{k_i^2}{(k_n-k_1)^2}+\frac{1}{n}.$$

由于收发设备的特性，不同接收天线接收无线信号是彼此独立的，即 $\phi_{i,1}$ 和 $\phi_{i,2}$ 是相互独立的，可以推导出：

$$\sigma_{\Delta\tilde{\phi}_i}^2=\sigma_{\tilde{\phi}_{i,1}}^2+\sigma_{\tilde{\phi}_{i,2}}^2. \tag{12}$$

通过式(12)可以推断，不同的 2 根天线之间的相位差方差是每根单独天线的相位方差和. 因此相较于单独天线的相位信号，相位差信号具有更高的分辨率，本文选取相位差作为特征信号能更好地映射不同的人数对 WiFi 信号的影响.

在传统的商用 WiFi 设备中，通常采用 OFDM-MIMO 技术实现多发多收的通信情形. 本文使用一套 1 发 3 收的设备来收集数据，借助 3 根接收天线中的相位信息两两做差得到了 3 个相位差矩阵. 为了避免因过多天线对而产生的数据冗余，需要从中选取出对人数变化最为敏感的天线对. 当人数对信号的影响增加时，信号的调制程度也会增加，从而导致子载波中的相位差方差增大. 因此本文选择方差这一指标来衡量人数对天线对的影响程度，以更好地捕捉人数变化对 CSI 的影响. 图 2 展示了在不同天线对中 30 个子载波的相位差方差分布情况. 其中，横轴表示天线对，纵轴表示相位差方差大小，散点表示各子载波的相位差方差，折线数值则代表 30 个子载波相位差方差的平均值. 通过图 2 观察到天线对 1 和 3 的平均方差最大，因此本文选择天线对 1 和 3 的相位差作为人流量监测的信息来源.

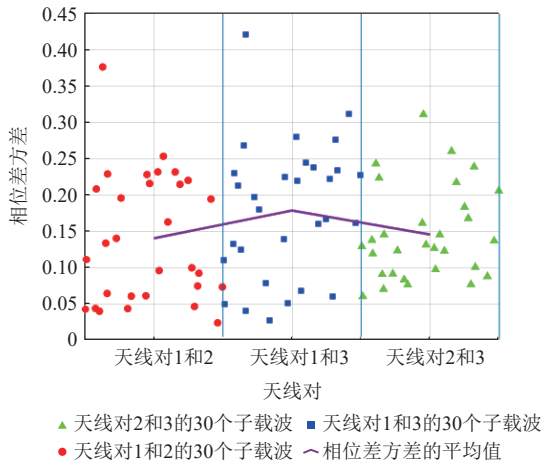


Fig. 2 Phase difference variance of 30 subcarriers in different antenna pairs

图 2 不同天线对 30 个子载波中的相位差方差

由于收发装置自身硬件的发射功率或传输速率等状态可能发生变化，因此采集到的原始 CSI 信号可能会出现异常值并导致明显的突变. 为了排除这些突变值，本文采用了 Hampel 滤波器[26]，该滤波器在去除异常值方面具有显著的优势. 图 3 展示了在某个子载波上相位差信息经过 Hampel 滤波后的结果. 图 3 中用方框标记的圆点即为被识别为异常值的数据点.

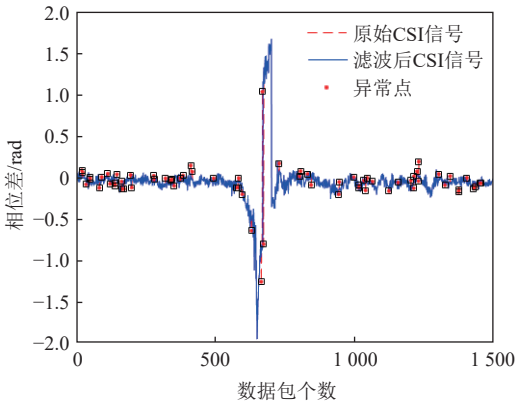


Fig. 3 Result graph of Hampel filtering

图 3 Hampel 滤波结果图

相较于振幅滤波，对相位差进行滤波的关键在于确保滤波器不引起相位偏移，并且不改变信号的域. 因此，本文采用巴特沃斯滤波器来实现相位差的

滤波操作. 该滤波器的传递函数为：

$$|H(\omega)|^2=\frac{1}{1+\left(\frac{\omega}{\omega_c}\right)^{2N}}=\frac{1}{1+\varepsilon^2\left(\frac{\omega}{\omega_p}\right)^{2N}},\qquad(13)$$

其中N表示滤波器的阶数，ω_c表示截止频率，ω_p表示通频带边缘频率. 由于人行走的频率在 20~80 Hz 之间，所以巴特沃斯滤波器的截止频率被设置为经验值 60. 该滤波器在很大程度上去除了噪声，在保留低频成分的同时对高频噪声进行了基本的滤波，以使波形更加清晰和平滑.

当人体靠近或远离收发装置时，各子载波的相位信息发生相应改变.尤其当人体位于收发装置的视距位置时，CSI 相位差的变化更为显著.为了获取人体在通过收发装置的视距位置时的最大信息量，需要提取相应的数据包. 图 4 展示了 30 个子载波相位差方差的平均值. 600~750 区间的数据包展现出比其他数据包更为显著的相位差方差. 因此，本文采用滑动窗口的方法提取信息量最大的 150 个数据包.

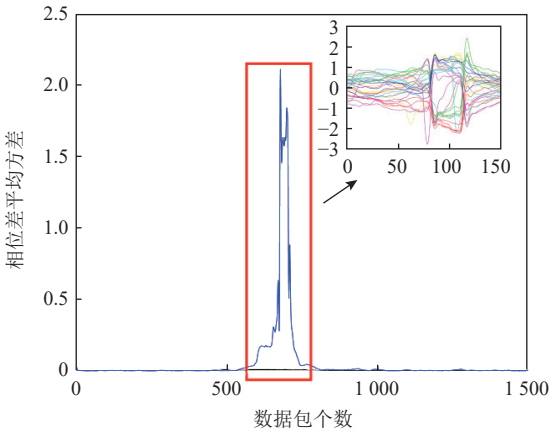


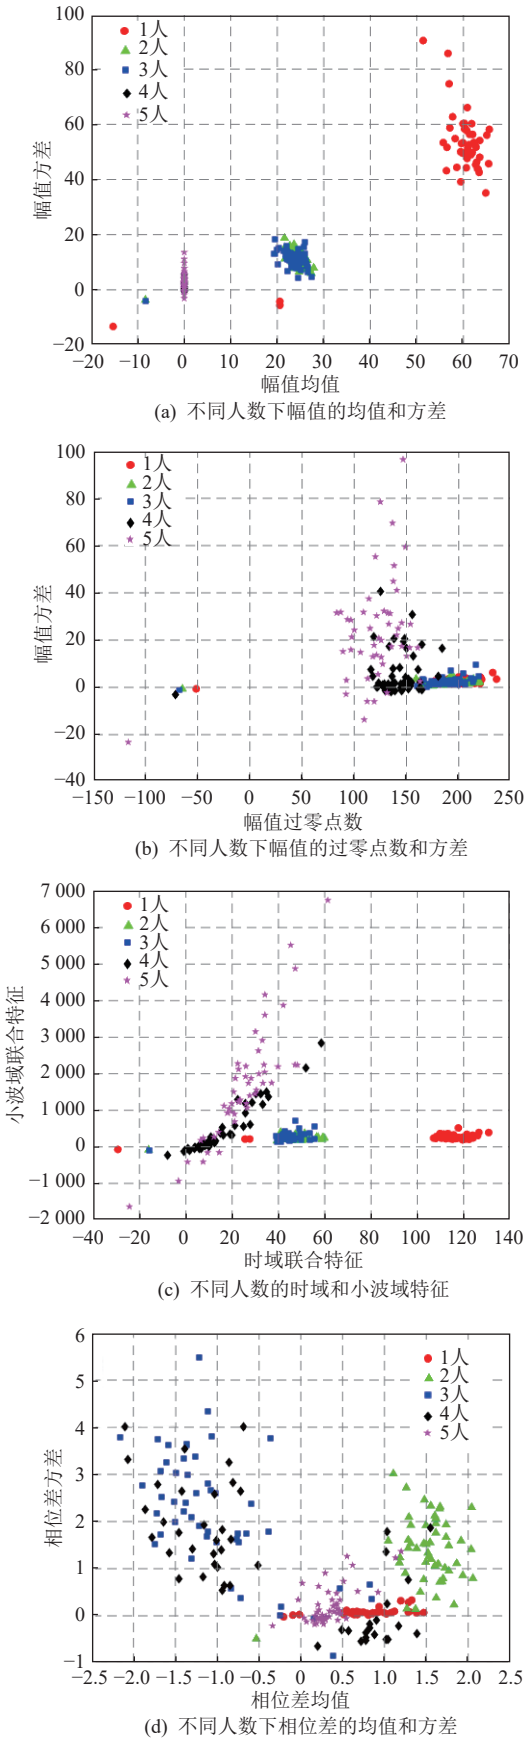
Fig. 4　Average variance of phase difference for 30 subcarriers

图 4　30 个子载波的相位差平均方差

3.2　确定人流量特征信号

为了确定最佳的人流量特征信号，本文先对经过清洗的振幅和相位差信息进行特征提取，包括时域特征和小波域特征. 接着对这些特征进行降维处理，并通过两两组合这些特征的方式来验证其有效性. 在时域特征中，本文手工设计了均值、方差和峰峰值 3 个传统特征. 而在小波域特征中，也手工设计了过零点数量、方差和能量这 3 个特征. 考虑到 CSI 数据维度较高，本文采用 PCA 算法选取贡献率最高的第一主成分，以便更加直观地比较传统特征的显著程度.

图 5 展示了不同人数与不同特征之间的散点图，其中横坐标和纵坐标分别表示不同的特征. 图 5(a)



(a) 不同人数下幅值的均值和方差

(b) 不同人数下幅值的过零点数和方差

(c) 不同人数的时域和小波域特征

(d) 不同人数下相位差的均值和方差

Fig. 5　Performance of different combination features

图 5　不同组合特征的性能

时域中的均值特征和方差特征在区分 1 人和 5 人方面具有明显差异, 但在区分 2 人、3 人和 4 人之间存在完全的重叠, 因此难以进行区分. 图 5(b)小波域的过零点和方差特征对不同人数的区分度非常低, 几乎所有人数都彼此重叠. 图 5(c)时域联合特征和小波域联合特征也存在着相似的问题, 区分 1 人相对容易, 但区分其他人数也面临困难. 然而, 图 5(d)中的相位差在时域上的特征呈现较为均匀的分布, 重叠较少, 因此具有较高的区分度.

综上所述, 可以确定在时域上相位差信息作为人流量监测的特征信号. 然而, 值得注意的是, 提出的特征仍然存在轻微的重叠, 不能完全区分出所有的人数. 由于手工设计的特征存在一定的限制, 因此需要采用更高效的方法来挖掘人数与相位差中的潜在特征. 在 3.4 节中, 本文将详细介绍如何利用深度学习来提取信号中的潜在信息.

3.3 多排人数据处理

3.1 节和 3.2 节是基于单排人数据的分析结果, 然而, 在实际场景中, 还会收集到连续多排人经过收发装置的数据. 如图 6 所示, 这是经过数据清洗处理的部分多排人数据图, 其中横坐标表示数据包个数, 纵坐标表示相位差.

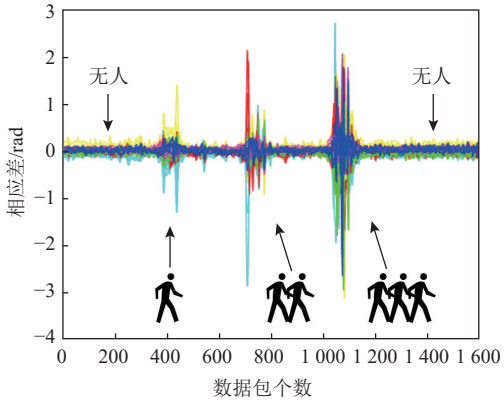


Fig. 6 Partial multi-row people data graph

图 6 部分多排人数据图

从图 6 中可以观察到, 收集到的数据中存在多个明显的数据波动, 每个波动对应着一排人通过收发装置. 因此, 有效处理多排人数据的关键在于从连续的 CSI 数据中提取出有效的人流区间, 并从这些区间中提取包含人在收发设备视距位置经过的最重要信息的数据包.

本文提出了利用标准差和方差来提取多排人数据中的有效数据包的方法. 该方法使用滑动窗口计算数据包的标准差, 并与预设的阈值进行比较, 以确定一排人的人流区间的起始点和结束点. 接着利用方差在这些起始点和结束点之间的数据段上确定人流通过收发装置视距的数据包, 这些数据包被认为是最具信息价值的 CSI 数据段. 具体步骤为:

1)假设有一个连续的 CSI 数据时间序列 $x[i]=\{x_1,x_2,\cdots,x_j\}$, 其中第 j 个数据点为 x_j, 在这种情况下, 计算窗口内的标准差值:

$$STD_j[i]=\sqrt{\frac{1}{w-1}\sum_{j=1}^{w}\left(x_j-\bar{x}\right)^2}, \tag{14}$$

其中 i 表示子载波个数, 本文 $i\in\{1,2,\cdots,30\}$, j 表示 CSI 数据时间序列上的第 j 个数据包, w 表示窗口长度, 本文中 w=150. 此外, x_j 表示 CSI 数据时间序列上的第 j 个数据包的相位差, 而 $\bar{x}$ 表示 CSI 数据时间序列上的窗口大小为 w 的平均值.

2)计算第 j 个数据点上所有子载波的标准差:

$$STD_j=\sum_{i=1}^{30}STD_j[i]. \tag{15}$$

3)根据实验确定阈值 T, 本文中 T=2.5. 这些起始点和终止点构成了连续的 CSI 数据时间序列, 并满足:

$$\begin{cases}STD_{j_{\text{begin}}}>T,\\ STD_{j_{\text{end}}}>T.\end{cases} \tag{16}$$

4)确定好起始点和终止点后, 人流区间 CSI 数据时间序列表示为

$$x[i]=\left\{x_{j_{\text{begin}}},x_{j_{\text{begin}}+1},\cdots,x_{j_{\text{end}}}\right\}. \tag{17}$$

5)人流通过收发装置视距的 CSI 数据时间序列应当符合条件

$$y=\max\left(\frac{1}{w-1}\sum_{k=j_{\text{begin}}}^{w}(x_k-\bar{x})^2\right). \tag{18}$$

3.4 分类识别

Wi-HFM 使用时域上的相位差来识别通道经过的人数. 人体经过 WiFi 设备的过程在空间和时间上都是动态的, 这使得 CSI 信号会随着人数的改变和时间推移而变化, 因此时域上的相位差具有潜在的空间特性和时间关联性. 为了捕获这 2 种潜在特性, 本文采用深度学习中的 CLDNN 模型来自动学习 CSI 数据的抽象特征表示, 以解决传统机器学习方法中手工设计特征的问题.

CLDNN[27] 是将 CNN, LSTM, DNN 这 3 种网络模型中的核心部分融合在一起的一种新型神经网络. CNN 具有局部连接、权值共享和池化操作等特点, 在处理具有空间结构的数据时表现出色, 因此本文采用 CNN 来提取 CSI 天线对中相位差的空间特征.

同时 CSI 是与时间相关的长序列数据，该数据在时域上对不同人数具有较强的区分度，故采用 LSTM 提取时间序列上的关联性特征. 由于 CNN 输出为高维而 LSTM 需要输入为低维，在两者中间添加了一个线性层以降低数据维度. 为了将前面提取的空间特征和时间特征映射到更具可区分性的空间中，将 LSTM 的输出传递给全连接层后采用 Softmax 函数进行人数分类.

本文的 CNN 模型由 1 个卷积层和 1 个池化层组成，卷积层提取 CSI 相位差数据中的局部特征信息，池化层减小数据尺寸，降低运算量的同时为后续处理提供更好的输入. CNN 通过滑动窗口的方式与卷积核做卷积操作得到不同的输出特征图，输出特征图的数量与使用的卷积核的数量相同. 卷积运算的具体公式为：

$$\boldsymbol{X}_m = f\left(\sum_n \boldsymbol{W}_m^n \cdot \boldsymbol{X}^n + \boldsymbol{b}_m\right), \tag{19}$$

其中 $\boldsymbol{X}_m$ 表示第 m 个输出特征图，$\boldsymbol{W}_m^n$ 表示卷积核参数，$\boldsymbol{b}_m$ 为偏置参数，$f(\cdot)$ 为激活函数，本文采用 ReLU 函数作为激活函数，用来缓解过拟合和梯度消失等问题.

传统的 RNN 模型可以处理 CSI 这种长序列数据存在梯度消失或梯度爆炸的问题，因此本文采用基于 RNN 改进的 LSTM 以捕获数据中的时间相关性. LSTM 设计了 3 个门控单元来控制细胞的长期状态. 首先遗忘门会根据当前时刻输入的 $\boldsymbol{x}_t$ 和前一时刻隐藏层输出的外部状态 $\boldsymbol{h}_{t-1}$，通过 Sigmoid 函数 σ 决定哪些信息应该从细胞状态 $\boldsymbol{c}_{t-1}$ 中被遗忘. $\boldsymbol{f}_t$ 表示每个细胞状态元素被遗忘的程度，并在 [0,1] 区间内取值，公式为：

$$\boldsymbol{f}_t = \sigma\left(\boldsymbol{W}_f \cdot [\boldsymbol{x}_t, \boldsymbol{h}_{t-1}] + \boldsymbol{b}_f\right). \tag{20}$$

其次通过输入门来更新细胞状态，以确定要存储哪些信息到细胞状态中. 输入门的 Sigmoid 函数用于确定更新的权重，而函数 tanh 则生成一个候选向量 $\tilde{\boldsymbol{c}}_t$，该候选向量会被添加到细胞状态中. 输入门的输出 $\boldsymbol{i}_t$ 和候选者向量 $\tilde{\boldsymbol{c}}_t$ 的计算公式为：

$$\boldsymbol{i}_t = \sigma(\boldsymbol{W}_i \cdot [\boldsymbol{x}_t, \boldsymbol{h}_{t-1}] + \boldsymbol{b}_i), \tag{21}$$

$$\tilde{\boldsymbol{c}}_t = \tanh(\boldsymbol{W}_c \cdot [\boldsymbol{x}_t, \boldsymbol{h}_{t-1}] + \boldsymbol{b}_c). \tag{22}$$

将旧细胞状态 $\boldsymbol{c}_{t-1}$ 更新成 $\boldsymbol{c}_t$，公式为：

$$\boldsymbol{c}_t = \boldsymbol{f}_t \odot \boldsymbol{c}_{t-1} + \boldsymbol{i}_t \odot \tilde{\boldsymbol{c}}_t. \tag{23}$$

最后由输出门来产生所需的输出值，这个最终的输出值是基于细胞状态的内容来决定的. 输出门的 Sigmoid 函数确定了细胞状态中的哪些成分被输出，接着细胞状态 $\boldsymbol{c}_t$ 会经过函数 tanh 的处理，然后与之前 Sigmoid 函数的输出 $\boldsymbol{o}_t$ 相乘，得到最终的输出结果. 具体的计算公式为：

$$\boldsymbol{o}_t = \sigma(\boldsymbol{W}_o \cdot [\boldsymbol{x}_t, \boldsymbol{h}_{t-1}] + \boldsymbol{b}_o), \tag{24}$$

$$\boldsymbol{h}_t = \boldsymbol{o}_t \odot \tanh(\boldsymbol{c}_t), \tag{25}$$

其中 $\boldsymbol{W}$ 为各个门的权重矩阵，$\boldsymbol{b}$ 为偏置向量. 接着在 CNN 和 LSTM 之间引入线性层以调整特征表示和维度，而 LSTM 的输出会被传递给全连接层，用于后续的分类任务. 由此构建的人流量监测网络模型称为 CLDNN，其结构如图 7 所示.

模型使用 1 对天线采集的 CSI 数据作为输入，因此设置了单个输入通道. 第 1 层卷积层采用 3×15 的卷积核，步幅为 1×1，输出通道为 32. 为了提取主要特征并防止过拟合，卷积层后接一个池化层，下采样大小和步幅均为 2×4. 最后将池化层的输出传递给一个线性层，获得 256 个输出.

本文采用包含 64 个神经元的 LSTM 隐藏层，并使用函数 tanh 作为内部状态的激活函数，遗忘系数设定为 0.9. 深度神经网络的输出结果由众多网络参数共同决定，因此本文选择广泛使用的 Adam 算法作为训练算法. Adam 算法能够根据损失函数动态调整每个参数的学习速率，避免因梯度过大导致的学习步长过大问题，从而提高训练效率.

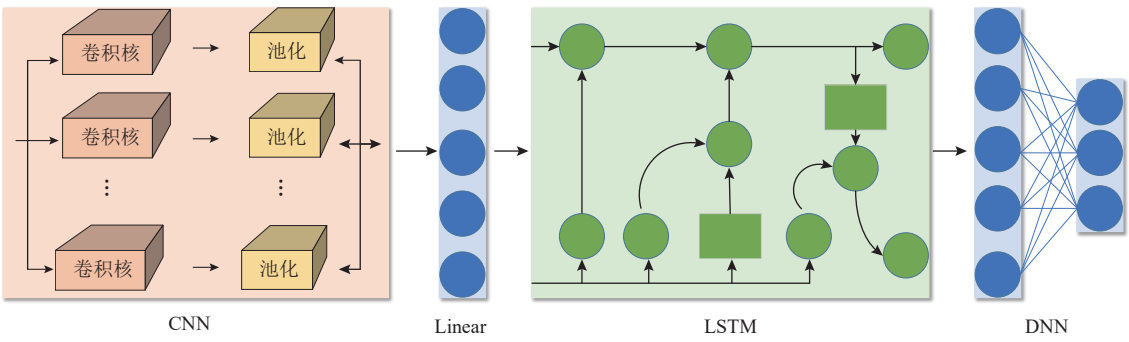


Fig. 7 CLDNN structure diagram

图 7 CLDNN 结构图

CLDNN 模型最后使用 Softmax 层输出人数分类结果. 假设样本集合为 $X=\{\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_n\}$，共有 l 个类别（本文中 $l=5$），$\boldsymbol{\psi}_j$ 为第 j 类的权重. 模型计算每个样本所有类别概率的公式为：

$$P\left(y_i=j|\boldsymbol{x}_i,\boldsymbol{\psi}_j\right)=\mathrm{e}^{\boldsymbol{\psi}_j^{\mathrm{T}}\boldsymbol{x}_i}/\sum_{j=1}^{l}\mathrm{e}^{\boldsymbol{\psi}_j^{\mathrm{T}}\boldsymbol{x}_i}. \tag{26}$$

对于每个样本向量 $\boldsymbol{x}_i$，模型输出的结果是一个 l 维列向量. 该向量中的每个元素代表样本属于对应类别的概率，且所有元素之和为 1. 最终，模型将概率最高的类别判定为该样本的类别.

Wi-HFM 的分类识别包括 2 个阶段：离线训练和在线识别. 在离线训练阶段，深度学习网络的参数是通过单排人数据集和多排人数据集进行离线学习得到的. 而在在线识别阶段，模型使用当前采集到的多排人数据信息来输出人数的估计值. 通过上述方法，Wi-HFM 能有效识别出单排人数和连续性人流人数.

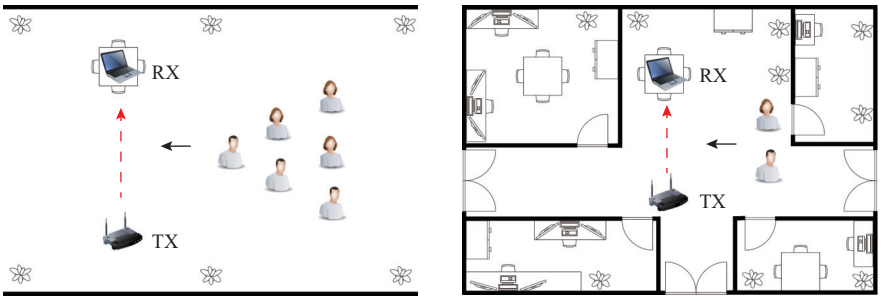
4 实验与结果

4.1 实验设置

实验采用 AP 模式，即借助一个 Tenda F3 WiFi 路由器和一个带有 Intel WiFi Link 5300 网卡的小型主机，以收集人流量数据. 数据解析工作使用了 CSI Tool 开源软件包. 发送端的路由器工作在 2.4 GHz 频段，仅装备有 1 根天线，而接收端的小型主机则配备了外接的 3 根天线，这两者被安置在高 1.1 m 的三角支架上，形成了 1×3 的 MIMO 系统，以 500 packet/s 的采样率进行数据收集.

为了构建室外和室内场景模型，本文选取了 2 栋教学楼之间的走廊和 1 栋教学楼内的通道作为实验场地. 实验环境布局如图 8 所示. 图 8(a)表示的室外场景位于走廊，宽度约为 5.5 m，无其他障碍物，因此多径效应较少，信号损失较小. 而图 8(b)表示的室内场景位于通道，宽度约为 7 m，但存在桌子、电梯等障碍物，导致多径效应明显，信号损失较大.

为了收集 CSI 数据，邀请了 16 名不同身高体重的志愿者，其中男女各 8 位. 志愿者们参与了多次实验，其中包括单排 0~5 人通过收发装置和连续人流通过收发装置的情况. 本文总共收集了 2 000 个人流数据样本，其中一半是单排人流数据，另一半是多排人流数据，文献 [28] 给出了 Wi-HFM 数据集的开源地址. 本文将 80% 的单排和多排人流数据样本用作训练数据集，剩下的 20% 用于测试数据集，最后根据测试集的准确率来评估系统性能.



(a) 室外环境　　(b) 室内环境

Fig. 8 Layout of experimental environment

图 8 实验环境布局图

4.2 实验因素分析

4.2.1 实验场景设置的影响

在 Wi-HFM 的应用场景中，收发端之间的距离和多排人之间的间隔都对实验结果产生影响. 本研究对这 2 个因素进行了详细调查，以寻找实现最佳人流量识别效果的条件.

收发设备之间的距离会对信号产生影响. 如果设备距离太近，通道容量不足以容纳更多人；而如果距离太远，会导致信号衰减. 鉴于现实中存在多人通行的情况，实验将最小距离设置为 2.5 m，而室外通道的最大距离设置为 4.5 m. 在实验中，将设备之间的距离设置在 2.5~6.5 m，单排人数据实验结果如表 1 所示. 从表 1 中可以发现，当收发设备之间的距离超过 4.5 m 时，识别准确率下降. 因此，最佳的收发设备距离应该在 2.5~4.5 m.

连续的人流通过监测装置时，由于人与人之间可能相互干扰，所以需要分析多排人之间的距离对监测性能的影响. 本文在连续人流中设置了不同的排与排之间的距离，分别为 0.5 m，1 m，1.5 m，2 m 以及 2 m 以上，多排人数据的实验结果见表 2. 研究结果表明，只要排与排之间的距离大于 1 m 以上，就可以准确地识别人数.

Table 1 Accuracy of Different Distances Between Transmitting and Receiving Devices

表 1 收发设备之间不同距离的准确率

距离/m	室外准确率/%	室内准确率/%
2.5	98.3	96.5
3.5	98.6	96.6
4.5	98.2	96.6
5.5		90.3
6.5		75.6

注：室外通道最大距离为 4.5 m.

Table 2 Accuracy of Different Distances Between Multiple Rows of People

表 2 多排人之间不同距离的准确率

距离/m	室外准确率/%	室内准确率/%
0.5	70.8	64.3
1.0	91.3	90.5
1.5	95.2	94.8
2.0	95.2	94.8
>2.0	95.2	94.8

4.2.2 CLDNN 模型参数的影响

CLDNN 模型具有大量参数，模型的输出受这些参数共同影响，因此参数调整成为构建 CLDNN 网络模型的关键步骤. 在深度学习中，样本数量对准确率有显著影响. 如图 9 所示，不同样本数量下的准确率表现差异明显. 单排人数据的拟合度最高，通常只需要少量的样本数. 而对于多排人数据，由于人与人之间的距离有差异，模型需要更多数据来学习. 然而，无论是单排人数据还是多排人数据，CLDNN 都能够良好地拟合模型，实现高精度的识别，这体现了 CLDNN 在应对不同数据情境时的优越性.

为了快速达到最低损失值，以避免学习率过大引发的震荡和误差，需要随着训练轮数的增加逐渐降低学习率. 不同的学习率衰减函数会影响收敛速度等结果. 本研究比较了 5 种经典的衰减函数，它们使用了初始学习率 0.01 或 0.001，并设置衰减率为 0.9. 不同衰减函数的迭代次数结果列于表 3 中.

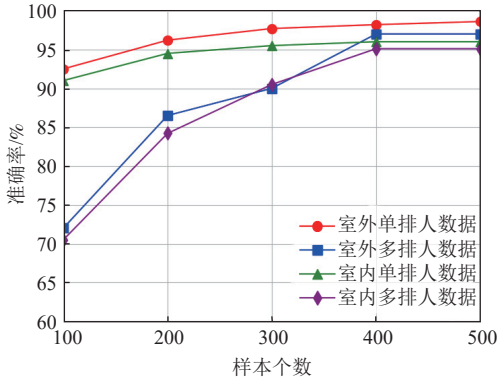


Fig. 9 Accuracy of different sample numbers

图 9 不同样本数的准确率

Table 3 Iterative Convergence Times for Different Decay Functions

表 3 不同衰减函数的迭代收敛次数

衰减函数	初始学习率	迭代次数
exponential_decay	0.001	100
natural_exp_decay	0.010	150
polynomia_decay	0.001	>400
inverse_time_decay	0.001	>650
cosine_decay	0.001	>580

从表 3 中可以观察到，指数衰减函数和自然指数衰减函数的迭代次数明显少于其他衰减函数. 它们能在不到 200 次迭代中收敛，而其他衰减函数则需要超过 400 次. 值得注意的是，指数衰减函数的收敛速度最快，而其他函数很难达到收敛，并且其准确率在一定范围内波动，非常不稳定.

为了验证 CLDNN 模型的有效性，本文进行了消融实验，使用室外单排人数据构建了 6 个不同的人流量监测模型. 这些模型的准确率如图 10 所示，只有 CLDNN 和 LSTM+DNN 这 2 个模型在小样本数据的情况下达到较高的准确率，其他 4 个模型对样本数据量较为敏感，并且其准确率相对较低. CLDNN 能够在较少的样本下表现出色，在样本数据充足时实现高精度的识别.

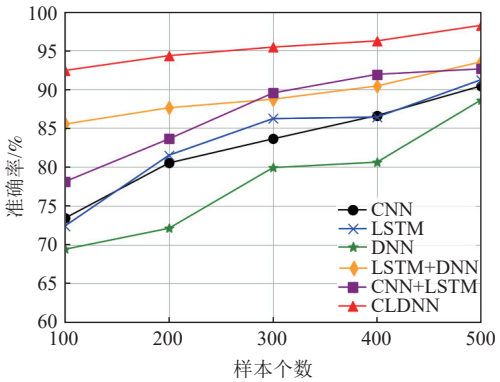


Fig. 10 Accuracy of different models

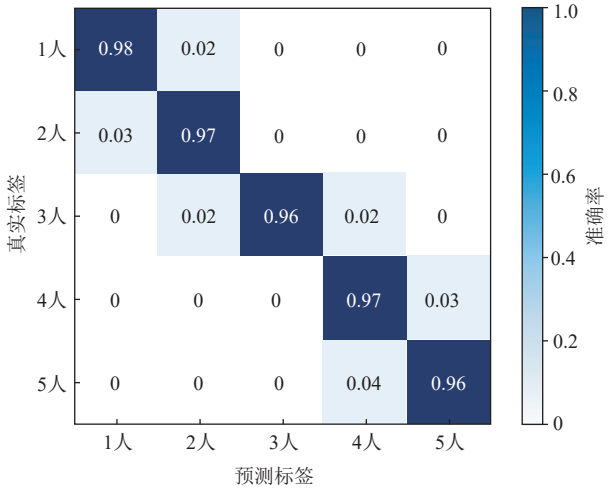
图 10 不同模型的准确率

4.3 人流量监测系统性能评估

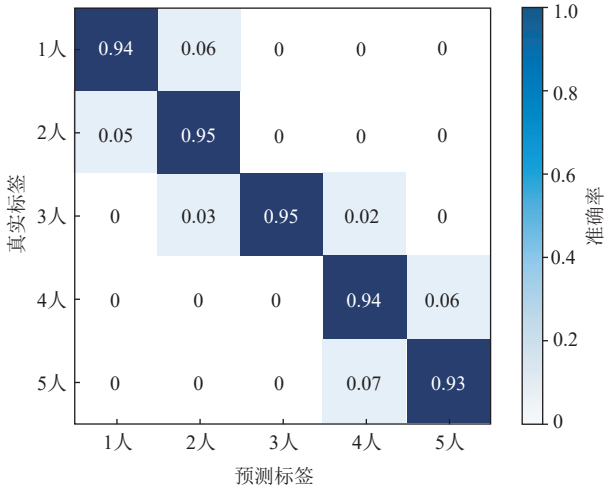
4.3.1 不同环境下的系统性能

人流量监测系统的性能如图 11 所示，分别展示了室外和室内环境下系统的混淆矩阵. 从图 11 中可

以观察到, 室外环境下各个标签的准确率均高于室内环境. 这是因为室外环境相对于室内环境更加简单, 信号损失较少. 无论是室外还是室内环境, 各个标签的准确率均高于 93% 以上, 系统准确率分别达到 96% 和 94%. 以上结果表明 Wi-HFM 能满足实际生活中的应用需求.



(a) 室外环境的混淆矩阵图



(b) 室内环境的混淆矩阵图

Fig. 11 Confusion matrix diagram of system in different environments

图 11 不同环境下系统的混淆矩阵图

4.3.2 与现有工作比较

为了验证 Wi-HFM 模型在无线感知人流量方面的有效性, 本文工作与现有工作进行了比较研究, 并将比较结果汇总于表 4 中. 文献 [17] 提出的 Door-Monitor 模型将相位差序列生成的频谱图输入到 7 层 CNN 网络中, 对进出门的访客进行动态计数, 其平均准确率为 94.5%. WiCrowd[29] 模型使用振幅和相位的协方差矩阵的特征值, 有效地检测到视距附近由人群运动引起的显著信号变化, 人数识别准确率最高可达 82.4%. HFD[30] 利用 WiFi 信号的偏度和峰度作为特征, 并采用 SVM 对特征进行分类以此估计当前队列中的人数, 其准确率能够保持在 90% 左右. 当区域仅有一排人流时, 上述方法可有效估算人数; 但面对多排连续人流, 便无法准确处理.

Table 4 Results Compared with Existing Work

表 4 与现有工作的比较结果

模型	分类方法	识别人数	准确率/%
Door-Monitor	CNN	1~6	94.5
WiCrowd	SVM	1~4	82.4
HFD	SVM	1~5	90.0
WiFlowCount	CNN	1~6	94.3
Wi-HFM	CLDNN	1~5	96.7

文献 [18] 中的 WiFlowCount 提出了一种最优旋转分割算法, 将连续人流的频谱图分割成子人流的子频谱图. 通过卷积神经网络从子谱图中估算出每个子流中的人数, 然后相加得出连续人流中的总人数. 该方案实现了连续的人流量计数, 准确率也高达 94.3%. 然而, WiFlowCount 要求人与人之间的间隔至少 8 m 才能获得较好的效果, 因此应用场景具有很大局限性. 与现有方法相比, Wi-HFM 在连续人流计数方面表现出色. 只要排与排之间的距离大于 1 m, 无论是在室外还是室内环境中, 本文方法的准确率均高达 96.7% 和 94.1%. 综上所述, 本文方法在实用性上明显优于现有方法.

5 结 论

本文提出了 Wi-FHM, 一种基于商用 WiFi 信道特征信息的人流量监测方法. 该方法包含多个处理步骤: 首先, 采用相位校准算法消除随机相位偏移, 接着使用巴斯特沃滤波器消除高频噪声, 然后通过标准差和方差提取连续性人流数据中的有效数据包, 利用 PCA 算法确定了时域上的相位差信息作为特征信号. 最后, 借助相位差设计的传统特征信号输入到 CLDNN 模型中以实现连续性人流的人数统计. 实验结果表明, 与传统人流量监测方案相比, Wi-FHM 拥有较高的准确率和更为优异的实用性.

未来的研究将聚焦在 2 个方面: 1)将增加 Wi-FHM 的功能以进行人流的方向判定, 以便系统能够识别进出人群的方向; 2)将尝试使用模型迁移方法, 以便在不同场景下仅使用 1 个模型监测人流量.

作者贡献声明：杨志勇设计了论文整体逻辑架构并修改论文；卢超负责数据整理和撰写论文；王俊杰提出算法思路并完成实验.

参 考 文 献

[1] Wang Xuyu, Gao Lingjun, Mao Shiwen, et al. CSI-based fingerprinting for indoor localization: A deep learning approach[J]. IEEE Transactions on Vehicular Technology, 2016, 66(1): 763−776

[2] Hao Zhanjun, Qiao Zhiqiang, Dang Xiaochao, et al. Wi-Do: Highly robust human motion perception model under WiFi signal[J]. Journal of Computer Research and Development, 2022, 59(2): 463−477 (in Chinese)
(郝占军, 乔志强, 党小超, 等. Wi-Do: WiFi信号下的高鲁棒人员动作感知模型[J]. 计算机研究与发展, 2022, 59(2): 463−477)

[3] Li Bo, Huang Hongbo, Zhang Ang, et al. Approaches on crowd counting and density estimation: A review[J]. Pattern Analysis and Applications, 2021, 24(3): 853−874

[4] Yang Zheng, Zhou Zimu, Liu Yunhao. From RSSI to CSI: Indoor localization via channel response[J/OL]. ACM Computing Surveys, 2013, 46(2). [2023-07-30]. https://ink.library.smu.edu.sg/sis_research/4538/

[5] Ma Yongsen, Zhou Gang, Wang Shuangquan. WiFi sensing with channel state information: A survey[J/OL]. ACM Computing Surveys, 2019, 52(3). [2023-07-30]. https://gzhou.pages.wm.edu/wp-content/blogs.dir/5736/files/sites/13/2017/12/WiFiSenseSurvey_CSUR19.pdf

[6] Kumar S, Cifuentes D, Gollakota S, et al. Bringing cross-layer MIMO to today's wireless LANs[C]//Proc of the ACM SIGCOMM 2013 Conf on SIGCOMM. New York: ACM, 2013: 387−398

[7] Gao Can, Zhou Jie, Miao Duoqian, et al. Three-way decision with co-training for partially labeled data[J]. Information Sciences, 2021, 544: 500−518

[8] Lin Hui, Ma Zhiheng, Ji Rongrong, et al. Boosting crowd counting via multifaceted attention[C]//Proc of the 2022 IEEE/CVF Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022: 19628−19637

[9] Liu Lingbo, Chen Jiaqi, Wu Hefeng, et al. Cross-modal collaborative representation learning and a large-scale RGBT benchmark for crowd counting[C]//Proc of the 2021 IEEE/CVF Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 4823−4833

[10] Liu Yan, Liu Chao, Peng Ke Wei, et al. Crowd counting using wireless infrared distance sensors for indoor environments[C]//Proc of the 2014 Informatics and Communication Technologies for Societal Development. Berlin: Springer, 2015: 1−8

[11] Orrite-Uruñuela C, Vicente-Dueñas D. Counting people by infrared depth sensors[C]//Proc of the 15th IEEE Int Conf on Advanced Video and Signal Based Surveillance. Piscataway, NJ: IEEE, 2018: 133−138

[12] Choi J W, Quan Xuanjun, Cho S H. Bi-directional passing people counting system based on IR-UWB radar sensors[J]. IEEE Internet of Things Journal, 2017, 5(2): 512−522

[13] Ibrahim O T, Gomaa W, Youssef M. CrossCount: A deep learning system for device-free human counting using WiFi[J]. IEEE Sensors Journal, 2019, 19(21): 9921−9928

[14] Sharma A, Li Junye, Mishra D, et al. Passive WiFi CSI sensing based machine learning framework for COVID-Safe occupancy monitoring [C/OL]//Proc of the 2021 IEEE Int Conf on Communications Workshops. Piscataway, NJ: IEEE, 2021[2023-07-30]. https://ieeexplore.ieee.org/document/9473673

[15] Mao Fei, Kong Huihui, Li Hongsheng, et al. Research on intelligent identification in rail transit station gate machine[J]. Urban Mass Transit, 2017, 20(12): 123−126 (in Chinese)
(茅飞, 孔慧慧, 李宏胜, 等. 轨道交通车站闸机智能识别研究[J]. 城市轨道交通研究, 2017, 20(12): 123−126)

[16] Yoshida T, Taniguchi Y. Estimating the number of people using existing WiFi access point in indoor environment[C]//Proc of the 6th European Conf of Computer Science. Hershey, PA: IGI Global, 2015: 46−53

[17] Yang Yanni, Cao Jiannong, Liu Xiulong, et al. Door-Monitor: Counting in-and-out visitors with COTS WiFi devices[J]. IEEE Internet of Things Journal, 2020, 7(3): 1704−1717

[18] Zhou Rui, Gong Ziyuan, Lu Xiang, et al. WiFlowCount: Device-free people flow counting by exploiting doppler effect in commodity WiFi[J]. IEEE Systems Journal, 2020, 14(4): 4919−4930

[19] Sharif Z, Sha'ameri A Z. The application of cross correlation technique for estimating impulse response and frequency response of wireless communication channel[C/OL]//Proc of the 5th Student Conf on Research and Development. Piscataway, NJ: IEEE, 2007[2023-07-30]. https:// ieeexplore.ieee.org/document/4451386

[20] Lu Yong, Lv Shaohe, Wang Xiaodong, et al. A survey on WiFi based human behavior analysis technology[J]. Chinese Journal of Computers, 2019, 42(2): 231−251 (in Chinese)
(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): 231−251)

[21] Rappaport T S. Wireless Communications: Principles and Practice[M]. Chennai, India: Pearson Education, 2010

[22] Zhang Liu, Zeng Zheng, Chen Junchang, et al. Indoor crowed accounting method based on multi-channel state information[J]. Computer Engineering and Design, 2020, 41(4): 1125−1132 (in Chinese)
(张六, 曾正, 陈俊昌, 等. 基于信道状态信息的室内人数统计方法[J]. 计算机工程与设计, 2020, 41(4): 1125−1132)

[23] 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

[24] Long Baoren. Single node WiFi indoor positioning system based on RSSI and CSI fusion[D]. Guangzhou: Guangdong University of Technology, 2019 (in Chinese)
(龙保任. 基于RSSI与CSI融合的单节点WiFi室内定位系统[D].

广州:广东工业大学,2019)

[25] Sen S, Radunovic B, Choudhury R R, et al. You are facing the Mona Lisa: Spot localization using PHY layer information[C]//Proc of the 10th Int Conf on Mobile Systems, Applications, and Services. New York: ACM, 2012: 183−196

[26] Xiao Yuxi, Cui Zhe, Lu Xiao, et al. A passive indoor localization with convolutional neural network approach[C]//Proc of the 2020 Chinese Automation Congress. Piscataway, NJ: IEEE, 2020: 1140−1145

[27] Sainath T N, Vinyals O, Senior A, et al. Convolutional, long short-term memory, fully connected deep neural networks[C]//Proc of the 2015 IEEE Int Conf on Acoustics, Speech and Signal Processing. Piscataway, NJ: IEEE, 2015: 4580−4584

[28] Lu Chao. Wi-HFM datasets [DB/OL]. [2024-01-31]. https://gitee.com/Positivelucas/wi_hfm

[29] Zhang Lei, Zhang Yueqiang, Wang Beibei, et al. WiCrowd: Counting the directional crowd with a single wireless link[J]. IEEE Internet of Things Journal, 2021, 8(10): 8644−8656

[30] Xiao Fu, Guo Zhengxin, Ni Yingying, et al. Artificial intelligence empowered mobile sensing for human flow detection[J]. IEEE Network, 2019, 33(1): 78−83



Yang Zhiyong, born in 1982. PhD, associate professor. Member of CCF. His main research interests include wireless sensing, artificial intelligence, and Internet of things.

杨志勇, 1982 年生. 博士, 副教授. CCF 会员. 主要研究方向为无线感知、人工智能、物联网.



Lu Chao, born in 2000. Master. His main research interests include wireless sensing and machine learning.

卢　超, 2000 年生. 硕士. 主要研究方向为无线感知、机器学习.



Wang Junjie, born in 1996. Master. His main research interests include wireless sensing and machine learning.

王俊杰, 1996 年生. 硕士. 主要研究方向为无线感知、机器学习.