

基于图卷积神经网络的室内穿墙无源目标检测算法

杨小龙, 唐婷*, 李兆玉, 唐鑫星

(重庆邮电大学通信与信息工程学院, 重庆 400065)

摘要: 针对室内穿墙场景下目标状态差异而导致的信道状态信息(Channel State Information, CSI)功率谱密度在时序发生相应变化规律的不同, 本文提出了一种基于图卷积神经网络(Graph Convolutional Neural, GCN)的室内穿墙无源目标检测算法. 不同于传统的基于CSI的统计特征实现目标检测的相关系统, 该算法从CSI的图域出发, 基于CSI时频图特征构建得到GCN图结构后, 使用可实现对复杂图中各节点进行分类的GCN作为分类器, 提高了室内复杂环境下目标检测的性能. 该方法在对原始CSI进行异常值去除和小波阈值去噪的基础上, 利用短时傅里叶变换得到每个子载波上CSI幅值的时频图; 然后根据各子载波CSI时频图特点, 将存在能量的频率平均分为5个频段, 再计算每个频段的平均功率谱密度, 并在每个时序对其进行排序; 最后基于对平均功率谱密度排序后各频段索引的变化规律构造GCN图, 并将其邻接矩阵和特征矩阵输入GCN网络中进行训练, 最终实现图节点特征与目标状态的一一映射. 实验结果表明, 在玻璃墙和砖墙场景下, 本文提出的算法能够很好地刻画目标状态不同而导致的CSI功率谱密度变化规律的差异, 且其平均检测准确率均高于现有的R-TTWD(Robust device-free Through-The-Wall Detection)和TWMD(The-Wall Moving Detection)目标检测算法.

关键词: Wi-Fi; 信道状态信息; 穿墙目标检测; 短时傅里叶变换; 图卷积神经网络

基金项目: 国家自然科学基金(No.62101085); 重庆市九龙坡区科技计划项目(No.2022-02-005-Z)

中图分类号: TN929.5 **文献标识码:** A **文章编号:** 0372-2112(2024)02-0614-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220561

Indoor Through-The-Wall Passive Target Detection Algorithm Based on Graph Convolutional Neural Network

YANG Xiao-long, TANG Ting*, LI Zhao-yu, TANG Xin-xing

(School of Communication and Information Engineering, Chongqing, University of Posts and Telecommunications,
Chongqing 400065, China)

Abstract: According to variation laws of channel state information (CSI) power spectral density (PSD) in the timing series caused by different target states in indoor through-the-wall scenarios, this paper proposes a passive target detection algorithm based on graph convolutional neural (GCN). Different from the traditional correlation system for target detection based on CSI statistical features, this algorithm starts from the graph domain of CSI, constructs the GCN graph structure based on CSI time-frequency diagram, and uses the GCN that can classify the nodes in the complex graph as the classifier, which improves the performance of target detection in the indoor complex environment. Based on outlier removal and wavelet threshold denoising for original CSI information, it uses the short-time Fourier transform to obtain the time-frequency diagram of the CSI amplitude on each subcarrier. Then, according to the characteristics of each subcarrier's CSI time-frequency diagram, the total spectrum is divided into five frequency bands on average, and the average PSD of each frequency band is calculated and sorted at every sample time. Finally, a GCN graph is constructed based on the variation law of the index of each frequency band after sorting the average PSD, and then its adjacency matrix and feature matrix are input into the GCN network for training, which can finally realize the one-to-one mapping between graph node features and target states. Experimental results show that under the scenarios of glass wall and brick wall, the proposed algorithm can essentially characterize the difference of CSI PSD change regularity caused by different target states; and its average detection accuracy is higher than that of the existing R-TTWD (Robust device-free Through-The-Wall Detection) and TWMD (The-Wall

Moving Detection) target detection algorithms.

Key words: Wi-Fi; channel state information; through-the-wall target detection; short-time Fourier transform; graph convolutional neural network

Foundation Item(s): National Natural Science Foundation of China (No.62101085); Science and Technology Research Project of Chongqing Jiulongpo District (No.2022-02-005-Z)

1 引言

室内无源目标检测作为无线感知的重要研究内容,是实现工业和信息化部和国家标准化委员会共同印发的《智慧家庭综合标准化体系建设指南》中所提及的智慧家庭的关键技术,在室内入侵检测、智能家居以及人机交互等众多领域具有广阔的应用前景。目前,无源目标检测技术主要基于摄像机^[1]、红外^[2]、超宽带雷达^[3]、射频^[4]和 Wi-Fi 设备^[5]等。基于摄像机和红色的目标检测技术,能够实现可视距(Line-Of-Sight, LOS)场景下目标的检测。然而,在非视距(Non-Line-Of-Sight, NLOS)条件下,比如当目标处于墙体等遮挡物后时,该类技术无法实现无源目标检测。在非视距条件下,基于超宽带雷达、射频和 Wi-Fi 设备等的目标检测技术,由于信号衰减严重,在目标检测的精度和范围方面也面临着巨大的挑战。

Wi-Fi 设备具有成本低、覆盖范围广、功耗低、对光线不敏感、可保护隐私等特点,因此基于 Wi-Fi 设备的相关研究得到了广泛的关注。基于 Wi-Fi 的无源目标检测技术借助 Wi-Fi 信号从发射端经过多条路径传输到接收端,从而通过提取 Wi-Fi 信号的接收信号强度(Received Signal Strength, RSS)或信道状态信息(Channel State Information, CSI)来获得信号传输信道的变化,以表征目标存在与否。但是, RSS 反映的是总的信号变化情况,而且易受环境影响,因此无法很好地反映每条路径的变化情况。相比之下, CSI 不仅包含多条路径的幅值和相位信息,而且其丰富的子载波维度信息使 CSI 可以更细精度地表征环境的变化^[6]。因此基于 CSI 的无源目标检测成为近些年的研究热点。


在视距场景下,基于 Wi-Fi 的无源目标检测技术的研究已经趋于成熟。提取 CSI 的相关统计特征可以实现该场景下的高准确率检测。如 Xiao 等人^[7]基于 CSI 的各数据包相关矩阵的最大特征值, Qian 等人^[8]基于 CSI 幅值和相位相关矩阵的前两大特征值等,来实现目标检测。然而,当 Wi-Fi 信号穿过墙体等遮挡物时,信号强度会发生很大程度的衰减^[9],信噪比大幅下降。因此,现有的基于时域特征的系统检测性能会受到一定的影响。为实现穿墙场景下目标的检测, Zhu 等人^[10]提出 R-TTWD (Robust device-free Through-The-Wall Detec-

tion)系统,该系统利用子载波维度的相关统计特征,可以高精度实现穿墙(Through-The-Wall, TTW)场景下的目标检测。Zhang 等人^[11]从统计电磁理论的角度出发,建立了 CSI 的自相关函数和环境中运动目标之间的联系,从而实现了复杂的穿墙场景下的目标检测。He 等人^[12]提出基于奇异值分解算法的干扰抑制模块,可以较好地获得被干扰信号淹没的人体反射信号。杨小龙等人^[13]提出 TWMD (The-Wall Moving Detection) 系统,该系统结合 CSI 多维度的特征,且选取了比以往的检测系统更多的特征数量用于检测,最后基于反向传播(Back Propagation, BP)神经网络获得多特征和检测结果的映射关系后,可在穿墙场景下实现对静止目标以及不同数量运动目标的检测。但该类系统是从 CSI 的时域或者频域提取相关统计特征用于检测,未充分挖掘时频域联合变化规律。

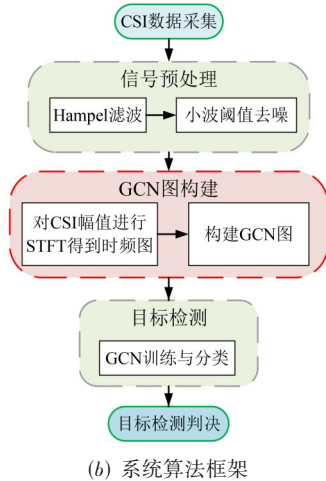
综上所述,以往的目标检测的系统仅基于 CSI 时域或频域特征实现检测,存在不稳定、特征维度少等问题。而本文结合 CSI 的时频特征进行分析,对 CSI 的时频特征进行相关变换之后,提出一种新颖的基于 CSI 的时频图构建输入到图卷积神经网络(Graph Convolutional Network, GCN)的图网络结构的方法。相比以往的检测系统,该方法可以获得更多的表征环境状态的特征数,同时,利用更高性能的 GCN 网络,能更优地实现对目标的检测分类。据悉,目前没有相似的研究。本文首先在对 CSI 数据进行预处理的基础上,提取各子载波上 CSI 的幅值信息,并对其进行短时傅里叶变换(Short Time Fourier Transform, STFT),从而获得 CSI 的时频图;其次,对各子载波的 CSI 时频图上的功率谱密度大小关系进行变换,以构建 GCN 图;最后,将 GCN 图的邻接矩阵和特征矩阵输入到 GCN 中,以实现目标的高精度检测。实验结果表明,在玻璃墙和砖墙场景下,本文所提算法的平均检测精度均高于现有的 R-TTWD 和 TWMD 目标检测算法。另外,本文对所提算法的鲁棒性进行了验证,可以综合考虑提取的 CSI 数据去调整算法参数,以最优化系统性能。

2 穿墙检测模型

本文的穿墙检测模型和系统算法框架如图 1 所示。



(a) 穿墙检测模型



(b) 系统算法框架

图1 穿墙检测模型和算法框架图

Wi-Fi 信号从发射机穿过墙发送到达接收端, 会经历人体反射或室内其他物体的反射. 本文的目的是通过人体反射信号来检测目标的存在. 整个系统的算法框架: 首先进行 CSI 数据的收集; 其次, 在对原始 CSI 数据进行预处理基础上, 对 CSI 幅值进行 STFT 得到时频图, 并依据时频图特征构造 GCN 图网络结构; 最后, 输入 GCN 图网络结构到 GCN 网络进行训练与分类, 以实现穿墙场景下的无源目标检测.

2.1 信道状态信息

假设接收机 (Access Point, AP) 是由 I 根天线间距为半波长的天线组成的线性阵列, 发射机配置一根天线发射正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 信号. 每个 OFDM 信号包含多个子载波, 每个子载波上包含信道环境的振幅衰减和相移信息, 可用 CSI 表示. 通过商用 Wi-Fi 无线网卡 (Network Interface Cards, NICs) 可以提取 CSI 数据, 其表示 OFDM 信号各子载波的信道频率响应 (Channel Frequency Response, CFR), 可以直观地反映信道的特征.

假设一段连续时间内共接收到 M 个 CSI 数据包, 可以表示为

$$\mathbf{H} = \begin{bmatrix} \mathbf{H}_1(1) & \cdots & \mathbf{H}_1(m) & \cdots & \mathbf{H}_1(M) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \mathbf{H}_i(1) & \cdots & \mathbf{H}_i(m) & \cdots & \mathbf{H}_i(M) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \mathbf{H}_I(1) & \cdots & \mathbf{H}_I(m) & \cdots & \mathbf{H}_I(M) \end{bmatrix} \quad (1)$$

其中, $\mathbf{H}_i(m)$ 表示第 m ($m \in [1, M]$) 个数据包中第 i ($i \in [1, I]$) 根天线上接收到的 CSI, 可以表示为

$$\mathbf{H}_i(m) = [h_{i,1}(m), h_{i,2}(m), \dots, h_{i,K}(m)]^T \quad (2)$$

其中, T 为转置符号; $h_{i,k}(m)$ 表示第 m 个数据包中第 i 根天线上第 k 个子载波的 CSI, 可以用幅值和相位表示为

$$h_{i,k}(m) = \|h_{i,k}(m)\| \exp(-j\angle h_{i,k}(m)) \quad (3)$$

其中, $\|h_{i,k}(m)\|$ 和 $\angle h_{i,k}(m)$ 分别表示 $h_{i,k}(m)$ 的幅值和相位.

2.2 数据预处理

由于收发机之间的随机噪声和时钟不同步等, 接收到的 CSI 相位往往和实际相位有偏差, 而且目前存在的相位校正方法暂时无法完全恢复真实的 CSI 相位信息, 利用准确的相位信息进行目标的高精度检测可能存在困难. 不过本文仅使用 CSI 的幅值信息用于检测, 减少了对 CSI 相位进行处理的过程, 相位信息对本文的算法没有影响.

受设备等因素的影响, 接收到的 CSI 数据往往存在一些偏离主体数据的异常值, 因此本文首先使用 Hampel 滤波法^[14]对异常值进行处理. 如图 2 所示, 红框中标记的即为 Hampel 滤波法中识别得到的异常值, 该类异常值偏离主体数据. 除此之外, 图 3 是 Hampel 滤波之后的 CSI 数据图. Hampel 滤波法去除异常值点之后, 使用中位数代替了异常值, 很好地保证了 CSI 数据在一段时间内的连续性. 因此 Hampel 滤波之后原始 CSI 数据整体的变化特征不会受到影响, 同时也保证了数据整体的稳定性.

另外, 为了进一步去除周围电磁、温度变化等带来




图2 Hampel 滤波前的 CSI




图3 Hampel滤波后的CSI

的干扰,本文使用小波阈值去噪方案^[15]对CSI的幅值进行处理.小波阈值去噪方法对非平稳信号具有较好的滤波效果,而且小波阈值去噪不仅滤除了大部分环境噪声,同时也保留了信号原本的变化特性.

3 基于GCN的穿墙目标检测算法

由于本文方法是基于GCN实现CSI特征和有无目标的一一映射的,所以关键的点是构建输入到GCN网络的图网络结构.由于有人、无人时,CSI信号的时频图上功率谱密度(Power Spectral Density, PSD)的变化存在较大的差异,因此,本文借助CSI信号的时频图特征构建GCN图网络结构.显然,不同状态构建得到的GCN图网络结构不同,因此不同GCN图对应节点的特征也存在差异,由GCN节点之间的关系构成的邻接矩阵也不同.因此借助GCN网络可以很好地实现有人、无人的检测分类.

3.1 构建GCN图网络结构

本文GCN图网络的构建是基于CSI的时频图实现的.为了获得CSI的时频图,本文首先提取预处理后的CSI幅值信息,再使用STFT算法对CSI幅值进行处理,以得到CSI的时频图.

STFT利用滑动窗口的思想,设定窗口大小和步长后,让窗口在时域信号上滑动,分别计算每个窗口的傅里叶变换,形成不同时间窗口对应的频域信号后,将每个频域信号进行拼接,即可得到STFT时频图,该图反映了频率随时间变化情况^[16].针对离散信号 $s(m)$,其STFT表达式为

$$G(n, f) = \sum_{m=-\infty}^{\infty} s(m)g(n-m)\exp(-j2\pi mf) \quad (4)$$

其中, $g(n)$ 是窗函数,它在时间上翻转并且有 n 个采样点的偏移量; $G(n, f)$ 是关于离散时间 n 和频率 f 的二维函数.输入信号的时频图对应的功率谱密度 $S(n, f)$ 定义为

$$S(n, f) = |G(n, f)|^2 \quad (5)$$

其中, $|\cdot|$ 表示对“ \cdot ”求幅值. $S(n, f)$ 的维度和 $G(n, f)$ 维度相等,假设为 $T_s \times F_s$, T_s 为总的信号采样点数, F_s 表示频谱对应的频点范围,两者的值和窗函数窗长、采样率、窗口重叠数等有关,计算方式如下:

$$T_s = (l - l_{\text{overlap}}) / (l_w - l_{\text{overlap}})$$

$$F_s = \begin{cases} \text{nfft}/2 + 1, & \text{nfft为偶数时} \\ (\text{nfft} + 1)/2, & \text{nfft为奇数时} \end{cases} \quad (6)$$

其中, nfft 表示傅里叶变换的点数, l 表示信号的总长度, l_w 表示滑动窗口长度, l_{overlap} 表示窗口重叠数.

图4是本文对某个子载波上接收到的CSI幅值进行STFT后得到的时频图,图中颜色深浅表示PSD的强度.信号总长度 l 为2000个CSI数据包,窗函数选择汉宁窗, $g(m) = a_0 - (1 - a_0) \cdot \cos(2\pi m / (l_w - 1))$, $0 \leq m \leq l_w - 1$, $a_0 = 0.54$,并设置窗口长度 l_w 为400个CSI数据包,窗口重叠数 l_{overlap} 为窗口长度 l_w 的50%,傅里叶变换点数 nfft 为256,采样率 f_s 为200 Hz.结合时频图可以看出,有人和无人的时频图上PSD分布情况不同,因此,PSD可以用来表征两者的特征.

结合图4(b)所示时频图,频率的最大范围为 $f_s/2$.为构建GCN图,本文对CSI时频图总频率进行了划分.类比现有无线领域对频率分布可表示低频、中低频、中频、中高频以及高频5类的思想,同时考虑到各频段要包含足够多数量的PSD以反映有人或无人时的环境特征.本文将时频图总频率平均划分为5个频段.则每一频段的长度为 $\text{len} = F_s/5$,即每个频段包含 len 个频点.然后,对各频段中所有频率成分的能量(即PSD)求平均值,得到各频段的平均能量值.用 $P(n, m)$ 表示在时间 n 时第 m 个频段中所有频率的平均能量值,计算方法如下:

$$P(n, m) = \frac{\sum_f p(n, f)}{\text{len}}, \quad (7)$$

$$(m-1)\text{len} + 1 \leq f \leq m\text{len},$$

$$(1 \leq m \leq 5, 1 \leq n \leq T_s)$$

其中, $p(n, f)$ 是时间为 n 、频率为 f 时对应的能量值; len 表示每一个频段的频点数.因此,在 T_s 时间内,各频段每个时间点上的平均能量值可构成平均能量值矩阵 \mathbf{P} ,其维度为 $T_s \times 5$,即

$$\mathbf{P} = \begin{bmatrix} P(1, 5) & \cdots & P(T_s, 5) \\ \vdots & \ddots & \vdots \\ P(1, 1) & \cdots & P(T_s, 1) \end{bmatrix}^T \quad (8)$$

为了去除数据采集偏移带来的影响,集中分析能量值本身的波动情况,对 \mathbf{P} 中每个频段得到的平均能量值进行“去趋势”处理.即将 \mathbf{P} 中每个频段得到的平均能量值减去一条通过最小二乘法拟合得到的拟合直

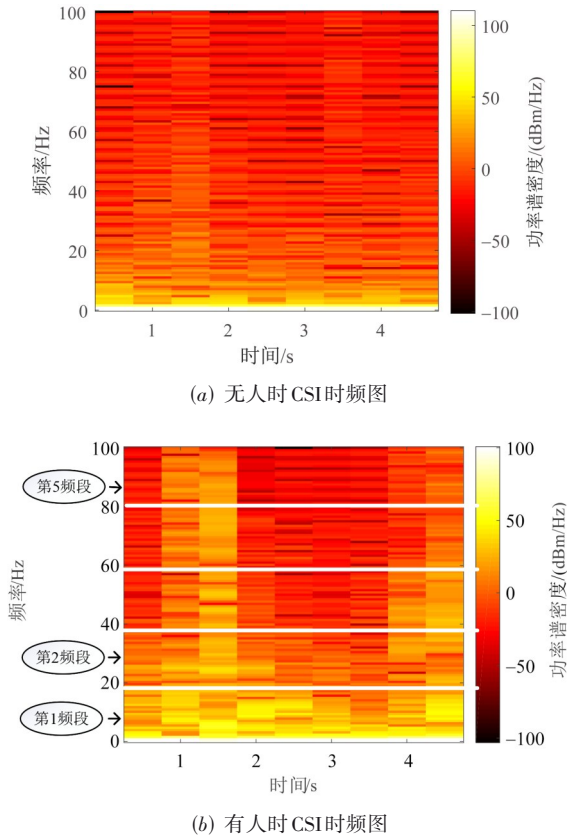


图4 CSI时频图对比

线、平面或曲面,使“去趋势”之后的平均能量值均值为零. 图5是平均能量值“去趋势”前后的对比图. 由图可以看出:经过“去趋势”操作之后,各频段之间的平均能量增加了相关性,更加易于寻找GCN图网络结构中各节点之间的相互关系. 本文记“去趋势”之后得到的平均能量矩阵为 \mathbf{P}' ,将 \mathbf{P}' 在时间 T_s 内的索引矩阵记为 \mathbf{S} ,其维度为 $T_s \times 5$,则

$$\mathbf{S} = [\mathbf{S}_1 \quad \mathbf{S}_2 \quad \cdots \quad \mathbf{S}_{T_s}]^T \quad (9)$$

其中, $\mathbf{S}_n = [1, 2, \dots, 5]^T$ 表示每个时间点 n 处所有频段对应的索引矩阵.

本文构造GCN图的本质是基于索引矩阵实现的. 如果仅基于式(9)的 \mathbf{S} 矩阵构造两状态的GCN图,会得到相同结构的GCN图,因为在相同的参数设置下,式(9)的 \mathbf{S} 矩阵不变. 显然,如果将此时的GCN图的相关特征输入到GCN网络进行训练,本文的检测效果将达不到预期. 但是,通过本文的实验观察到:有人、无人场景下,CSI时频图中PSD的分布不同. 因此,如果对PSD进行排序等变换,不同状态下的排序结果会出现差异,相应变化后得到的索引矩阵会不一样,随之构建得到的两状态下的GCN图网络结构会存在差异. 所以本文对PSD的排序等变换之后,增加了有人、无人时

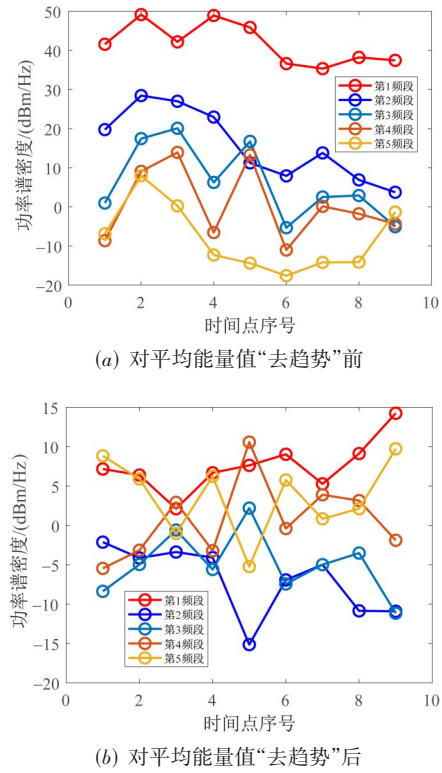


图5 平均能量值“去趋势”前后对比图

对应索引矩阵的差异性. 因此可以构建出有效的GCN图网络结构,增加本文的目标检测分类效果. 下面将详述本文的排序方法.

为了使每个时间点上的平均能量值按同样的规律进行排序,且构造不同时间点能量值之间的相互关系,本文对 \mathbf{P}' 每个时间点 n 处的平均能量值进行升序排序. 各时间点的平均能量值排序之后,引起其原始频段相应的索引值的变化,而且此时原始时频图中的能量分布也会相应变化. 本文按照平均能量值排序之后第一时间点的能量大小关系重新构造CSI的时频图,以表征图节点的特征. 并记录 T_s 时间内变化后的索引矩阵为 \mathbf{S}' ,其维度为 $T_s \times 5$. 另外,为了使索引值一一对应GCN图网络结构中的节点编号,以及方便后续构造GCN图节点的邻接矩阵,本文构建一个新的变换矩阵 \mathbf{B} 与 \mathbf{S}' 相加,得到新的矩阵记为 $\mathbf{\Gamma}$,其值即对应GCN图网络结构的某个节点. 具体方法如下:

$$\mathbf{\Gamma} = \mathbf{B} + (\mathbf{S}' - 1) * T_s \quad (10)$$

其中, \mathbf{B} 是本文构建的变换矩阵,维度为 $T_s \times 5$,且该矩阵每一行为 $\mathbf{B}_1 = [1, 2, \dots, T_s]^T$; $\mathbf{\Gamma}$ 即为最终变换得到的索引矩阵,维度为 $T_s \times 5$,其值即表示GCN图网络结构的节点编号,即每个GCN图包括 $T_s \times 5$ 个节点.

本文通过连接 $\mathbf{\Gamma}$ 矩阵的各列(即连接属于同一频段的节点),即可构建GCN图网络结构图,每个GCN图节点的特征值即为每个频段的能量值,所以每个节点包

括 len 个的特征值。特别地,每个子载波的 CSI 幅值信息,可分别构造一个图网络结构。图 6 是本文构造的两个 GCN 图网络结构。图中相同颜色的节点表示该类节点来自同一频段,每个圈标记的数字表示节点编号。




图 6 GCN 图网络结构

如图 6 所示,由于有人、无人两个场景下 CSI 的 PSD 分布不同,而本文的 GCN 图是基于 PSD 实现的,因此本文构造的 GCN 图在两个情况下的结构不同。图的结构不同,使每个图的节点相互关系不同,即每个图节点的邻接矩阵不同,而且每个 GCN 图节点的特征也不同。因此,本文将构造的 GCN 图的邻接矩阵和节点特征输入到 GCN 网络进行训练分类,可以实现目标检测的目的。

综上所述,本文提出的 GCN 图网络结构构建算法如算法 1 所示。

算法 1 本文提出的 GCN 图网络结构构建算法

输入: M 个 CSI 数据包

输出: Γ

初始化:天线个数 $I=4$,每天线子载波个数 $K=49$,输出 GCN 图网络结构个数 $F=0$

算法步骤:

- (1) 循环 $k=1:I*K$
- (2) 用第 2.2 节算法对式(1)的 CSI 数据进行预处理
- (3) 循环结束
- (4) 循环 $k=1:I*K$
- (5) 对第 k 个子载波进行 STFT,用式(5)计算 PSD
- (6) 将 PSD 的频率分量平均分为 5 个频段,用式(7)计算每个时间点上各频段的平均能量,构造平均能量矩阵 P
- (7) 对每个频段的平均能量“去趋势”,并记“去趋势”的平均能量矩阵 P' 对应的索引矩阵为 S
- (8) 对 P' 上各时间点的频段能量进行升序排序,记录此时新的索引矩阵 S'
- (9) 构造矩阵 B ,使用式(10)构造最终的索引矩阵 Γ 来一一对应图网络结构的节点
- (10) 连接 Γ 的各列, $F++$. 至此,第 k 个子载波的 GCN 图网络结构构造完成
- (11) 循环结束

3.2 基于 GCN 实现穿墙目标检测

GCN 充分利用了图中各节点与节点之间的相互关系以及各节点的特征信息,通过聚合周围节点的特征,更新自身节点,以实现复杂图中节点的分类。因此本文利用 GCN 作为训练器,输入构建的 GCN 图到 GCN 中以实现本文的目标检测目的。图 7 是 GCN 的示意图。

如图 7 所示,GCN 包括输入层、隐藏层和输出层。在输入层输入多个 GCN 图的邻接矩阵和节点特征矩阵,经过中间的多个隐藏层更新节点特征后,在输出层得到多个节点的输出特征,该特征与检测类别对应,最终即可实现节点的分类。

GCN 的输入层 $H(0)=X(X \in \mathbb{R}^{V \times C})$ 为 GCN 图中节

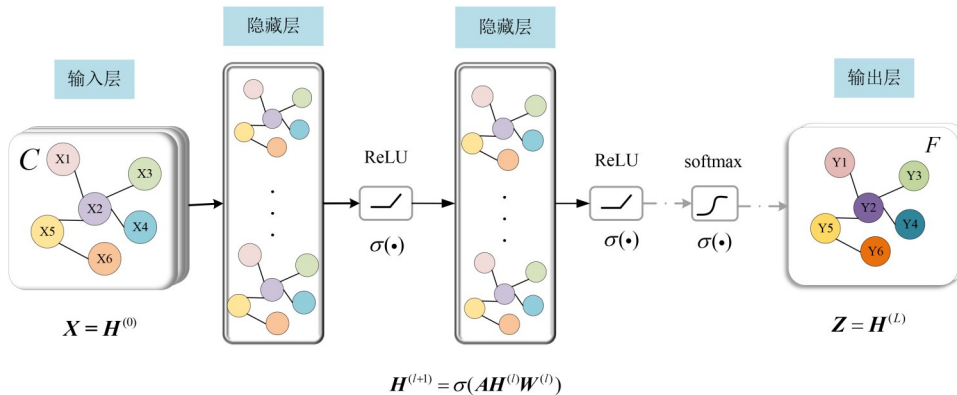


图 7 GCN 示意图

点的特征矩阵(其是一个 $N \times C$ 维的矩阵, $N = T_s \times 5$ 为每个图网络结构中的节点数量, C 为每个节点的特征维度,在本文 $C = \text{len}$);输出层 $\mathbf{Z} \in \mathbb{R}^{N \times F}$ (F 表示节点类别数,在本文等于2);GCN中每一个隐藏层实现空间信息的聚合,经过隐藏层之后节点特征得到更新,层与层之间的传播方式是

$$\mathbf{H}^{(l+1)} = f(\mathbf{H}^{(l)}, \mathbf{A}) = \sigma(\mathbf{A}\mathbf{H}^{(l)}\mathbf{W}^{(l)}) \quad (11)$$

其中, \mathbf{W} 为权重矩阵, l 表示隐藏层的层数, $\sigma(\cdot)$ 表示每一层的激活函数; \mathbf{A} 表示每个GCN图的邻接矩阵(其维度为 $N \times N$),其是主对角线为0的对称矩阵.

由于直接使用 \mathbf{A} 和 \mathbf{X} 相乘时得到的只是邻居节点对应特征的加权和,因此,为了在信息传播时使节点自身的特征信息也得到保留,对矩阵 \mathbf{A} 加上一个单位矩阵 \mathbf{I}_N ,即 $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N$.又因为直接使用 $\tilde{\mathbf{A}}$ 和 \mathbf{X} 相乘时,会改变特征原本的分布,所以一般情况下会在保持矩阵 $\tilde{\mathbf{A}}$ 原本的对称性下对其做归一化处理:

$$\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \quad (12)$$

其中, $\tilde{\mathbf{D}}_{ii} = \mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} = \sum_j \tilde{\mathbf{A}}_{ij}$, \mathbf{D} 为度矩阵,维度为 $N \times N$.经过式(12)归一化处理之后得到 $\hat{\mathbf{A}}$,显然,将其与每一层的特征矩阵相乘,能够很好地保留特征原本的分布情况.

本文依次通过上述各部分构建有人、无人状态下的GCN图网络结构之后,输入每个CSI子载波上构建的GCN图的邻接矩阵和节点特征矩阵到GCN网络中进行学习,最终实现节点特征和有无目标类别的映射,从而实现目标检测.特别地,本文将输入GCN网络的总样本按照7:3的比例分为训练样本和测试样本.设置GCN隐藏层数为两层,两个隐藏层的激活函数都为ReLU函数,神经元的个数分别为32和64;输出层的激活函数为softmax函数,神经元个数为16;每一层的 $\mathbf{W}^{(l)}$ 通过梯度下降法更新.

ReLU函数表达式如下:

$$g(z) = \begin{cases} z, & z > 0 \\ 0, & z < 0 \end{cases} \quad (13)$$

softmax函数表达式如下:

$$\text{softmax}(a_i) = \frac{\exp(a_i)}{\sum_{k=1}^F \exp(a_k)} \quad (14)$$

其中, a_1, a_2, \dots, a_F 为 \mathbf{Z} 中某个节点的特征,通过softmax函数可以求得 a_i 属于类别 i 的概率.因此,最终在输出层可以实现节点的分类预测.得到预测的分类结果后,根据已知的标签和预测进行对比,可以得到分类准确率.

本文的输出在GCN中可以表示为

$$\begin{aligned} \mathbf{Z} &= f(\mathbf{X}, \mathbf{A}) \\ &= \text{softmax}(\hat{\mathbf{A}}\text{ReLU}(\hat{\mathbf{A}}\text{ReLU}(\hat{\mathbf{A}}\mathbf{X}\mathbf{W}^{(0)}))\mathbf{W}^{(1)})\mathbf{W}^{(2)} \end{aligned} \quad (15)$$

4 实验与结果分析

4.1 实验数据采集

为了验证本文的穿墙目标检测算法的性能,本文实验采用搭载Ubuntu操作系统的笔记本以及两台配有Nexmon固件^[17]的ASUS RT-AC86U路由器进行CSI数据的采集,该设备基于802.11ac协议且支持80 MHz信道带宽,可以工作在5G频段.两台路由器分别用作发射机和接收机.发射机外接一根全向天线,并借助一台配有Wi-Fi网卡的笔记本通过ping命令来使其发射信号;接收机外接4根天线用于接收信号,最终信号通过与其通信的笔记本提取出来.在接收端每根天线上,通过网卡可以得到256个子载波的CSI数据,但是在数据处理阶段,等间隔选择49个子载波来进行检测.实验详细的参数如表1所示.

表1 系统详细参数设置

参数类型	参数值
天线数量(l)	4根
带宽	80 MHz
信道编号	161 (5.805 GHz)
子载波数量(K)	49个
发包速率	200包每秒
发射功率	15 dBm

实验在典型的办公室和会议室场景进行,两个数据采集环境中都包含较多的桌子和其他杂物,会议室长和宽分别为8.9 m和7.9 m,墙体为玻璃墙,厚度为3 cm;办公室长和宽分别为14.2 m和6.5 m,墙体为厚10 cm的砖墙.两种场景的墙体材料不同,对Wi-Fi信号造成的衰减不同,据此可以验证本文算法在不同场景下的鲁棒性.在实测数据时,发射机和接收机放置在墙体的不同侧,高度都为1.5 m,实验场景中有3名男性和2名女性志愿者.在数据采集过程中,志愿者在如图8所示的检测区域随机行走.实验总共采集了100组无人数据和270组有人数据,每组数据采集时间持续10 s,即每组数据的每根接收天线上总共采集到2 000个左右CSI数据包(存在较小的丢包率,可忽略).

4.2 性能评估

4.2.1 评估指标

本文使用下面的指标来评估系统性能.

(1) TP(True Positive)率.其表示在本文的玻璃墙和砖墙实验场景下,系统能够正确检测到环境中有人存在的准确率.


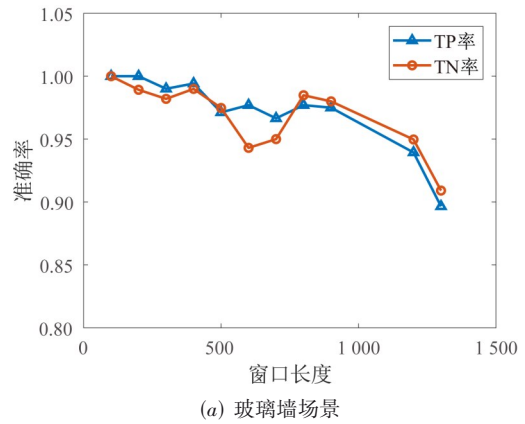



图 9 不同场景下检测准确率和窗口长度的关系

(2)TN(True Negative)率. 其表示本文能够正确判断室内无人存在的检测准确率.


4.2.2 窗口长度对检测性能的影响

本文使用STFT算法转换CSI幅值,从而得到CSI时频图. 由于窗函数的窗口长度会影响STFT的时间点数,因此为了检测窗口长度对检测性能的影响,本文设置不同的窗口长度分别进行检测. 两种场景下的检测准确率随窗口长度的变化情况结果如图9所示.

从图9可以看出,本文提出的算法在STFT窗函数的窗口长度设置不同的情况下,检测准确率会有一定程度的不同. 两个场景下当窗口长度设置为1200时达到最低准确率,这主要是由于窗口长度设置过长,总体CSI数据长度一样的情况下,此时构建的GCN图的节点特征相对其他窗口长度来说较少. 因此最终测试样本得到的准确率低于窗口长度更小的,但是系统的检测准确率仍然能够保证在90%以上.

同时,由于不同窗口长度时,STFT算法将得到不同的 T_s 和 F_s ,且STFT算法所耗时也不等. 因此在不同的窗口长度下,本文构造得到的GCN图节点数 $T_s \times 5$ 不等,系统的时间复杂度也随之不同. 为了研究不同的窗口长度下本文算法的实时性,本文将算法的代码运行时间来定性的描述该特性. 具体地,本文的信号预处理过程以及图网络构建过程在MATLAB平台完成,

基于GCN的目标检测在Pycharm平台完成(两个平台软件装在配有i3处理器,3.3 GHz双频CPU以及8 GB内存的个人计算机上),其中,在玻璃墙场景下验证结果如图10所示.



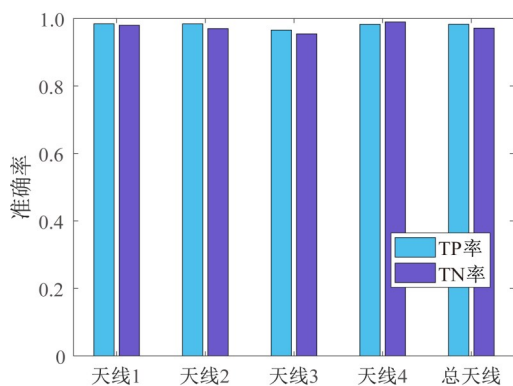
从图10可以看出,窗口长度仅为CSI数据总长的1/20时,系统运行时间最长,为450s. 此时构建的GCN图节点数最多,因此节点之间的相互关系复杂,构成的邻接矩阵维度大,GCN网络训练时间长. 由图10也可以看出,虽然窗口长度越长,系统运行时间越长,但是

最终会接近平稳。

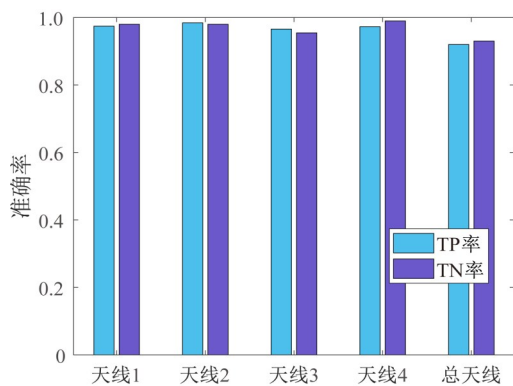
从图9(a)和(b)所示的窗口长度和准确率的关系可以看出,理论上本文两种场景下的最佳窗口大小都为100,此时准确率可以达到100%。但是本文的STFT算法时间复杂度和窗口大小有关,窗口选择较小,STFT的时间点数增多,构造的图节点也相应增多,时间复杂度也会相应较大。结合如图10所示的窗口长度和运行时间的关系,样本总长为2000个数据包,窗口大小设置为800,滑动步长为窗口大小的50%的情况,不仅能够保证系统达到较优的检测效果,而且运行时间也较短。因此,相比其他窗口长度,本文选择STFT的最优时间窗口大小为800。

4.2.3 天线数对检测性能的影响

本文使用的是一发多收系统,接收端可以接收到4天线的CSI数据。本部分将在前面窗口长度和数据包长度的基础上添加天线信息。此时子载波信息增加,因此构造的图网络结构也相应增加。不过,随着图网络结构的增加,系统的检测时间会随之增加。因此本文将选择最佳天线进行检测,以达到检测性能的最大化。两种场景下不同天线的检测准确率结果如图11所示。



(a) 玻璃墙场景



(b) 砖墙场景

图11 两种场景下不同天线的检测准确率对比

如图11所示,本文的检测系统仅使用单天线的CSI数据进行检测时,有人、无人的平均检测准确率不管是在玻璃墙场景还是砖墙场景都可达到97%及以上。在砖墙场景的情况下使用全部4根天线一起检测时,准确率较低,是因为Wi-Fi信号穿过砖墙时受到的衰减大于玻璃墙,因此砖墙场景下接收端接收到的CSI信号比玻璃墙场景下接收到的CSI信号模糊,4根天线各自接收到的CSI信号波动情况有差异,结合起来进行检测时检测准确率有可能受到影响。但是从图11也可以看出,砖墙场景下使用全部天线一起检测时,准确率也在90%以上,说明本文的检测系统能达到检测的目的。

4.2.4 STFT点数对检测性能的影响

由式(6)可知,STFT点数会影响到GCN图节点的特征数,因此,本节结合STFT点数对检测准确率的影响,选择合适的STFT点数进行目标检测。图12展示了玻璃墙场景下检测准确率和nfft的关系以及运行时间和STFT点数的关系。

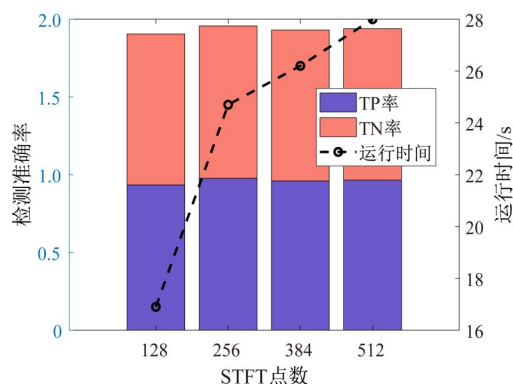


图12 STFT点数对检测准确率和运行时间的影响

由图12可以看出,本文算法的运行时间随着STFT点数的增加而增加,主要是因为节点特征数随着STFT点数增加。因此本文构造得到的GCN图结构更加复杂。相应地,GCN网络训练时间增加,系统的运行时间更长。同时,结合检测准确率和运行时间在不同STFT点数下的值可以得到,本文最优的STFT点数应该为256点,此时不仅可以保证最优检测准确率,而且系统运行时间也折中。

4.2.5 环境对检测性能的影响

为了验证本文算法的鲁棒性,本文在图8(b)所示的衰减更强的砖墙场景下改变室内环境以分析系统的稳定性。具体地,在采集数据时,改变室内原始椅子、物品的位置,或向室内中增加物品。环境改变前后准确率对比如表2所示。

如表2所示,通过上述方式改变环境后,TP率和TN率仍然在97%左右。这主要是由于本文构建的GCN图是基于每个子载波上的CSI幅值,每根天线上的子载波

表2 环境改变前后准确率对比

环境状况	原始环境	改变室内物品位置	添加物品
TP率	0.984	0.989	0.979
TN率	0.973	0.965	0.977

表现出很强的相关性,而且有人和无人环境下该相关性不同,环境改变不会影响该相关性.同时,室内环境的变化影响的是静态路径,对动目标的检测没有太大的影响.

4.2.6 和其他检测系统对比

为了评估本文系统性能,将本文系统和现有的穿墙检测系统R-TTWD以及TWMD进行对比.本文从系统的时间开销和系统的检测准确率两方面进行比较.

由于比较的2个系统都利用了CSI的相位信息,因此本文在对数据进行处理前,首先对采集的CSI数据进行了相位校正.同时,对比的两个系统都是利用相关性来对目标进行检测,需要对采集到的CSI数据进行滑动窗以提取每个窗口中的相关特征,而且相关特征数和采集的CSI总长度成正比,每个窗口中仅能得到一个相应的各类特征.本文一根天线上使用49个子载波,即可以得到49个样本,CSI数据包数只需要2000甚至更少.而对比的两个系统要得到49个样本,即使窗口长度设置为100(小于本文设置的窗口长度800),也需要 $49 \times 100 = 4900$ 个CSI数据包,而且这两个系统求特征值的过程时间复杂度随着样本数的增加而增加.为了验证本文及两个算法的时间开销,本文定性地从代码执行时间进行分析,把代码执行时间作为评价指标.为了保证验证的可靠性,本文使用相同数据包长度的CSI数据进行验证.

同时,为了使R-TTWD和TWMD系统得到的特征数尽量多,本文在分析两个系统时,对2000个CSI数据包进行重叠滑动窗,窗长设置为100,窗口重叠步长为50%,并记录各自系统的时间开销.图13是3个系统的时间开销对比图.

如图13所示,在窗口长度均为100和CSI数据包长度均为2000的条件下,本文的系统时间开销大于


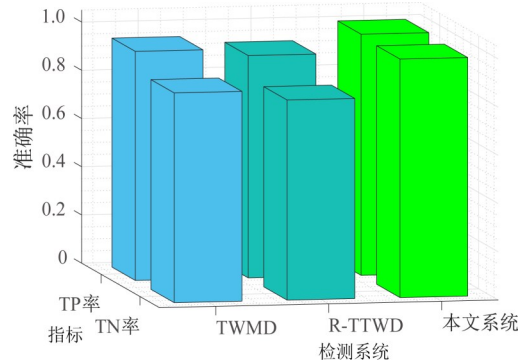


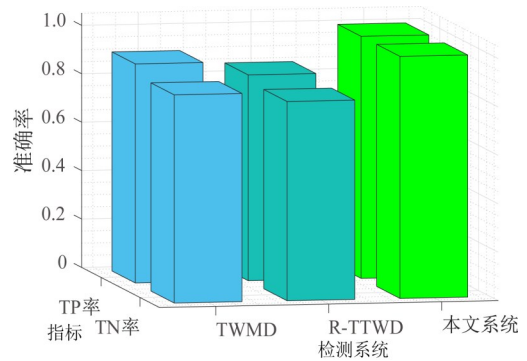
图13 不同系统的时间开销对比图

TWMD和R-TTWD系统,这主要是由于本节在相同的CSI数据总长度下,窗口长度设置为100,结合第4.2.2节可知本节中本文系统所用时间较长的原因. TWMD系统的时间开销大于R-TTWD系统,这主要是由于采取了多数量、多维度(幅值、相位、子载波)的相关统计特征进行目标的检测,特征提取复杂度高.另外,R-TTWD系统由于仅采用了相位统计特征,因此所用时间少于TWMD系统.实际上,本文系统窗口长度为800即可达到高检测准确率需求,而TWMD和R-TTWD系统需要在窗口长度足够小的情况下样本数才能足够多,检测准确率才保证可靠.

接下来进行检测准确率的比较,以验证本文所提算法的可行性.此时窗口长度同样设置为100,其余设置和比较3个系统时间开销时一样.图14是在2个实验场景下本文的检测准确率和R-TTWD、TWMD系统准确率的比较.



(a) 玻璃墙场景



(b) 砖墙场景

图14 不同系统在不同场景下的检测准确率对比

如图14所示,在两个实验场景下,TWMD系统的TP率能达到93%,但是TN率较低,仅能达到83%,R-TTWD系统的检测准确率都在80%左右,而本文的算法TP率和TN率在两个场景下都能达到99%以上,优于另外两个系统.这主要是由于本文STFT点数为256

时,由式(6)可知,频谱的最大维度为 $256/2+1=129$,每个频段可以得到最多 $129/5=25.8$ (取整为25)个频点.即使在本文取最大频谱范围为100时,每个频段也可以得到20个频点,即每个节点包含20个特征值.相比之下,在相同的条件下,本文输入到训练网络的信息比TWMD(10个特征)和R-TTWD(3个特征)系统的丰富,能够更加精细地区分环境的不同状态.同时,由于GCN图的输入数据集中包含的邻接矩阵可很好地表征图中各节点与节点之间的相互关系,因此本文算法能够达到较对比的两个系统更高的检测准确率.

5 结论

本文提出一种基于图卷积神经网络的室内无源人体目标有无的检测算法.该算法首先在室内场景采集CSI数据,并对其降噪处理;其次,对各子载波的CSI幅值进行STFT并绘制得到各CSI对应子载波的时频图;随后,根据有人、无人场景下CSI时频图功率谱密度分布不同的特点,对功率谱密度进行相关变换,构建两场景相应的GCN图;最后输入多载波的GCN图的相关特征到GCN网络进行训练和分类,从而实现GCN图节点特征和检测类别的映射.实验表明,本文提出的算法在玻璃墙和砖墙环境下,能够保证高精度检测且具有较高的鲁棒性.未来将进一步研究特殊的墙体材料以及墙体厚度对目标检测性能的影响.

参考文献

- [1] 高洁, 朱元, 陆科. 基于雷达和相机融合的目标检测方法[J]. 计算机应用, 2021, 41(11): 3242-3250.
GAO J, ZHU Y, LU K. Object detection method based on radar and camera fusion[J]. Journal of Computer Applications, 2021, 41(11): 3242-3250. (in Chinese)
- [2] 苗壮, 张湧, 李伟华. 基于中心点的实时红外目标检测方法[J]. 红外与毫米波学报, 2021, 40(6): 858-864.
MIAO Z, ZHANG Y, LI W H. Real-time infrared target detection based on center points[J]. Journal of Infrared and Millimeter Waves, 2021, 40(6): 858-864. (in Chinese)
- [3] 蒋留兵, 周小龙, 车俐. 基于无载波超宽带雷达的小样本人体动作识别[J]. 电子学报, 2020, 48(3): 602-615.
JIANG L B, ZHOU X L, CHE L. Few-shot learning for human motion recognition based on carrier-free UWB radar[J]. Acta Electronica Sinica, 2020, 48(3): 602-615. (in Chinese)
- [4] FENG C, XIONG J, CHANG L Q, et al. RF-identity: Non-intrusive person identification based on commodity RFID devices[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2021, 5(1): 1-23.
- [5] LIN Y X, GAO Y, LI B J, et al. Revisiting indoor intrusion detection with WiFi signals: Do not panic over a pet! [J]. IEEE Internet of Things Journal, 2020, 7(10): 10437-10449.
- [6] WU C S, YANG Z, ZHOU Z M, et al. Non-invasive detection of moving and stationary human with WiFi[J]. IEEE Journal on Selected Areas in Communications, 2015, 33(11): 2329-2342.
- [7] XIAO J, WU K S, YI Y W, et al. FIMD: fine-grained device-free motion detection[C]//2012 IEEE 18th International Conference on Parallel and Distributed Systems. Piscataway: IEEE, 2012: 229-235.
- [8] QIAN K, WU C S, YANG Z, et al. PADS: Passive detection of moving targets with dynamic speed using PHY layer information[C]//2014 20th IEEE International Conference on Parallel and Distributed Systems (ICPADS). Piscataway: IEEE, 2014: 1-8.
- [9] ADIB F, KATABI D. See through walls with WiFi! [J]. ACM SIGCOMM Computer Communication Review, 2013, 43(4): 75-86.
- [10] ZHU H, XIAO F, SUN L J, et al. R-TTWD: Robust device-free through-the-wall detection of moving human with WiFi[J]. IEEE Journal on Selected Areas in Communications, 2017, 35(5): 1090-1103.
- [11] ZHANG F, WU C S, WANG B B, et al. WiDetect: Robust motion detection with a statistical electromagnetic model[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2019, 3(3): 1-24.
- [12] 何艾琳. 基于WiFi穿墙雷达的移动目标检测算法研究[D]. 重庆: 重庆邮电大学, 2019.
HE A L. Research on Moving Target Detection Algorithm Based on WiFi Through-The-Wall Radar[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2019. (in Chinese)
- [13] 杨小龙, 吴世明, 周牧, 等. 室内穿墙场景下的无源人体目标检测算法[J]. 电子与信息学报, 2020, 42(3): 603-612.
YANG X L, WU S M, ZHOU M, et al. Indoor through-the-wall passive human target detection algorithm[J]. Journal of Electronics & Information Technology, 2020, 42(3): 603-612. (in Chinese)
- [14] 戴欢, 蒋敬敬, 束沁冬, 等. 基于信道状态相位信息的生命体征监测算法[J]. 计算机科学, 2020, 47(10): 48-54.
DAI H, JIANG J J, SHU Q D, et al. Vital signs monitoring method based on channel state phase information[J].

Computer Science, 2020, 47(10): 48-54. (in Chinese)

- [15] 赵明富, 唐平, 汤斌, 等. 基于小波变换的压缩感知理论对水质检测紫外-可见光谱数据的去噪研究[J]. 光谱学与光谱分析, 2018, 38(3): 844-850.
- ZHAO M F, TANG P, TANG B, et al. Research on denoising of UV-vis spectral data for water quality detection with compressed sensing theory based on wavelet transform[J]. Spectroscopy and Spectral Analysis, 2018, 38(3): 844-850. (in Chinese)
- [16] 李淑雅, 施明, 张建秋. 时频分析的卡尔曼滤波匹配解调变换法[J]. 电子学报, 2018, 46(4): 769-774.
- LI S Y, SHI M, ZHANG J Q. Matching demodulation transform with a Kalman filter for time-frequency analyses[J]. Acta Electronica Sinica, 2018, 46(4): 769-774. (in Chinese)
- [17] GRINGOLI F, SCHULZ M, LINK J, et al. Free your CSI: A channel state information extraction platform for modern Wi-Fi chipsets[C]//Proceedings of the 13th International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization. New York: ACM, 2019: 21-28.

作者简介



杨小龙 男, 1987年6月出生, 四川人. 现为重庆邮电大学信息与通信工程专业副教授、硕士生导师. 主要研究方向为量子定位技术、无线感知与定位技术、认知无线电技术等.

E-mail: yangxiaolong@cqupt.edu.cn



唐婷 女, 1999年2月出生, 贵州人. 现为重庆邮电大学电子与通信工程专业硕士研究生. 主要研究方向为无线感知.

E-mail: tangting_gz@163.com