

NWI:基于CSI的非视距信号识别方法



田春元 余江 常俊 王彦舜

云南大学信息学院 昆明 650500

(tianchunyuan@mail.ynu.edu.cn)

摘要 由于室内环境复杂多变和多径效应对WiFi传播信号的影响,因此产生了大量的非视距路径,导致信号严重衰落,通信链路质量恶化,造成应用识别精度不高、实现系统复杂等问题。文中提出了一种基于CSI的非视距信号识别方法NWI(NLOS recognition based on Wavelet Packet Transform Identification),主要用于对WiFi的物理层信息——CSI信号进行特征提取,识别当前链路中是否存在遮挡。所提方法对CSI信号的幅值进行三层小波包分解,分别提取第3层8个频段的小波包系数、小波包能量谱、信息熵和对数能量熵作为特征向量,利用支持向量机进行分类,从而识别出非视距信号。相比其他方法,该方法无须对CSI信号进行预处理,最大程度地保留了环境对传播信号的影响,更真实地反映室内环境。实验结果表明,该方法在动态环境中的识别精度为96.23%,在静态环境中的识别精度为94.75%,证明了基于小波包变换的CSI信号特征提取方法能够有效识别非视距信号,具有较高的识别精度和普适性。

关键词:信道状态信息;非视距信号识别;小波包变换;特征提取;支持向量机

中图法分类号 TN99

NWI:CSI Based Non-line-of-sight Signal Recognition Method

TIAN Chun-yuan, YU Jiang, CHANG Jun and WANG Yan-shun

Department of Information, Yunnan University, Kunming 650500, China

Abstract Due to the influence of complex and changeable indoor environment and multipath effects on WiFi signal propagation, a large number of non-line-of-sight paths are generated, which lead to serious signal fading and communication link quality deterioration, resulting in low recognition accuracy and complex system implementation. In this paper, a CSI-based NWI (NLOS recognition based on Wavelet Packet Transform Identification) is proposed, which is mainly used for feature extraction of CSI signals, the physical layer information of WiFi, to identify whether there is blocking in the current link. The three-layer wavelet packet is used to decompose the amplitude of CSI signal, the wavelet packet coefficients, wavelet packet energy spectrum, information entropy and logarithmic energy entropy of 8 frequency bands in the third layer are extracted as feature vectors, and the support vector machine is used for classification. Thereby a non-line-of-sight signal is identified. Compared with other methods, the proposed method does not need to pre-process the CSI signal, and the influence of the environment on transmission signals is maximum retained, so as to reflect the indoor environment more realistically. The experimental results show that the recognition accuracy of the proposed method is 96.23% in the dynamic environment and 94.75% in the static environment. It is proved that the CSI signal feature extraction method based on wavelet packet transform can effectively identify non-line-of-sight signals and has high recognition accuracy and universality.

Keywords Channel state information, Non-line-of-sight signal recognition, Wavelet packet transform, Feature extraction, Support vector machine

收稿日期:2019-09-01 返修日期:2019-11-19 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61162406);云南省高校频谱传感与边疆无线电安全重点实验室开放课题(C6165903);云南大学研究生科研创新项目(Y2000211)

This work was supported by the National Natural Science Foundation of China (61162406), Open Project of Key Laboratory of Spectrum Sensing and Frontier Radio Security of Colleges and Universities in Yunnan Province (C6165903) and Graduate Research Innovation Project of Yunnan University(Y2000211).

通信作者:余江(yujiang@ynu.edu.cn)

1 引言

随着无线局域网(Wireless Local Network, WLAN)在室内的广泛部署,大量基于 WiFi 的应用产生。但是由于室内环境复杂多变,无线信号会受到多径效应和信道时变特性的影响,MAC 层所提取的 RSSI 也容易受到影响,从而导致 RSSI 应用的检测精度下降,因此我们通过修改商业网卡驱动或固件来提取 PHY 层的信号状态信息(Channel State Information, CSI),并将其作为一种细粒度特征。因为 CSI 能够从时域和频域的角度来详细刻画无线信号的传播模型,在拥有更好的感知效果的同时还体现了信道的多径特性,反映了大量的环境特征信息,为室内无线感知提供了丰富的物理信息,所以被应用于高精度的应用,如室内定位^[1]、无线测距^[2]、动作识别^[3]、人体跟踪^[4]等。

对当前传播信号链路中的视距路径(Line of Sight, LOS)和非视距路径(No Line of Sight, NLOS)进行识别是实现高精度应用的重要前提^[5]。LiFi^[6]基于信道统计特征的方法,利用 LOS 环境下信号呈 Rician 分布的性质,提出了包络分布特征,即 Rician-K 因子和偏度,通过二元假设检验进行分类,但是幅度特征容易受噪声影响,鲁棒性较差。PhaseU^[7]提出了基于相位的特征,因为原始相位信息是随机分布的,其通过计算两根天线之间的相位差来获得稳定的相位信息,并将其作为特征值。PhaseU 虽然可以很好地识别非视距信号,但是在动态环境中的识别率更高,不适合静态环境。AmpN^[8]在静态环境下利用 BP 神经网络对接收信号进行 LOS/NLOS 分类,动态选取二元假设检验进行划分,扩大了识别应用的场景,提高了识别精度。以上方法都是通过观察无线信号在信道中的传播状态来选取特征值,但是由于信号的突变性和噪声影响,特征值的分辨性不高,所提取的特征值也过于单一,不能涵盖复杂多变的室内传输信号的变化。Choi 等^[9]提出不利用基于幅度或相位的特征值,通过采集大量不同环境的 CSI 数据,使用 LSTM 块组成的循环神经网络结构训练数据,来得到识别 LOS/NLOS 的模型。该方法缩短了识别信道环境所需的时间,但是由于训练过程所需的数据量大,过程复杂,容易产生过度拟合。

利用小波包变换对复杂信号进行分析是近年来的研究重点,小波包变换是一种时频分析方法,用来揭示信号中包含的频率分量及其演化特性,常被应用于非平稳机械振动信号^[10]、遥感图像^[11]、地震信号^[12]和生物医学信号^[13]等包含大量细节信息的信号分析。小波包变换可以对非平稳信号提供更精细的分解,而且这种分解方法既无冗余,也无疏漏,因此对于非平稳信号可以很好地表示出信号的频率随时间的变化规律。小波包变换在信号去噪、信号滤波、信号压缩、非平稳信号的分析与特征提取^[14]及多载波调制技术^[15]等方面具有重要应用。

本文提出了一种新的 NLOS 识别方法——基于 CSI 的小波包变换的 NLOS 识别方法(NLOS recognition based on Wavelet Packet Transform Identification, NWD)。该方法利用

小波包分解 CSI 多个子载波的幅度,提取每个子载波在分解后各个频带的系数、能量谱、熵,并将其作为特征向量,采用支持向量机进行分类,进而达到识别 NLOS 的效果。该方法提取的特征向量较好地识别了 CSI 在传播过程中的 NLOS 路径。

2 系统模型

2.1 CSI 数据模型

在新一代的移动通信协议中,利用正交频分复用技术(Orthogonal Frequency Division Multiplexing, OFDM)可以将无线信道划分为多个子载波,CSI 是子载波频率响应采样值,第 n 个子载波在 t 时刻的 CSI 值 $H_n(t)$ 为:

$$H_n(t) = \sum_{k=1}^L \gamma_{k,n} + e_n(t) \quad (1)$$

其中, $n \in N$, N 表示子载波集, L 是室内环境的总路径数, $e_n(t)$ 是第 n 个子载波在 t 时刻的白噪声。 $\gamma_{k,n}$ 为第 n 个子载波从发射端到接收端的第 k 条路径在 t 时刻接收到的信号,可以表示为:

$$\gamma_{k,n} = \zeta_k e^{-j2\pi \frac{d_k}{\lambda} t} \quad (2)$$

其中, ζ_k 是第 k 条路径的衰减, d_k 是 t 时刻第 k 条路径的长度。在 OFDM 的作用下,每个数据包中的 CSI 信息中包含 30 个子载波 CSI 复数矩阵,表达式为^[16]:

$$\mathbf{H} = [\mathbf{H}(f_1), \mathbf{H}(f_2), \dots, \mathbf{H}(f_i)]^T, i \in [1, 30] \quad (3)$$

2.2 小波包分解

小波包分解(Wavelet Packet Decomposition, WPD)基于小波分解,对全频带上的信号频带做多层次的划分。其分别通过高通滤波器和低通滤波器获得原始信号的高频分量与低频分量,然后用得到的分量重复这个过程,直到满足合适的频率精度范围^[17]。它可以将原始信号分解成 2^n 个不同层次的频段。小波包分解公式的定义如下:

$$\begin{cases} p_0' = f(t) \\ p_j^{2i-1} = \sum_k \mathbf{H}(k-2t) p_{j-1}^i \\ p_j^{2i}(t) = \sum_k \mathbf{G}(k-2t) p_{j-1}^i(t) \end{cases} \quad (4)$$

其中, $f(t)$ 表示原始信号, \mathbf{G} 和 \mathbf{H} 分别是高通滤波器和低通滤波器, $p_j^i(t)$ 表示第 j 层第 i 小波包分解。分解后的频带能够根据分析信号的特征,自适应地选择相应的频带,使之与信号频谱相匹配,并且对应于各个信号的频谱节点。由式(4)可知,随着小波包分解层数的增加,会导致信号信息丢失,运算量增大。根据室内传播信号的频率分布,本文选择 3 层小波包分解,如图 1 所示。




图 1 小波包 3 层分解

Fig. 1 Wavelet packet three-layer decomposition

图 1 中, S 为原始信号, A 表示低频, D 表示高频,末尾的序号数表示小波分解的层数(即尺度数)。

2.3 特征提取

WiFi 信号受到室内复杂环境的影响,信号波形是非平稳且多变的。本文根据小波包可将原始信号按任意时频分辨率分解的特点,将信号分解到相应的频段内,根据先验知识保留分解序列中任意或几个频段序列进行重构^[18],并将各个分解频段的节点系数、能量谱和信息熵作为信号特征。具体算法如下:

(1)将原始信号进行3层小波包分解,得到8个不同层次的频段,该分解结构如图2所示。图2中,(0,0)为原始信号 X_{00} ;第1层第1个节点(1,0)的系数为 X_{10} ;第1层第2个节点(1,1)的系数为 X_{11} ,依次类推。




图2 小波包树

Fig. 2 Wavelet packet tree

(2)对步骤(1)中得到的各个节点的系数进行重构,获得各个频率范围内的信号。对于室内环境下的信号传输,采样频率取10 Hz。进行3层分解时,共分为8个频段,每个频段的带宽为0.625 Hz。

(3)提取小波包能量谱

小波包分解能够将信号分解到相互独立的各频段中在传播过程中在各个频段内信号能量的分布是不同的。由于分解后各个频段的宽度相同,且接收信号的总能量是固定值,因此将各个频段的能量与总能量相比,以得出每个频段的能量占比,如图3所示。LOS环境中存在着直射路径并且包含着大量能量,因此在频段1中能量的占比很高;而NLOS由于多径衰落,不存在直射路径,因此频段1的能量谱比直射路径低,故可以将其作为分类特征进行提取^[19]。




图3 LOS/NLOS环境下8个节点的占比

Fig. 3 Energy ratio of 8 frequency bands in LOS/NLOS

信号 $x^{k,m}(i)$ 的长度为 N ,能量为:

$$E_n[x^{k,m}] = \frac{1}{N} \sum_{i=1}^N E_n[x^{k,m}(i)]^2 \quad (5)$$

其中, k 为分解层数, m 为信号子频带分解频段的位置序号($m=1, \dots, 2^k$)。由能量守恒原理可知:

$$\begin{aligned} E_n[x(t)] &= \sum_{m=0}^{2^k-1} E_n(U_{j-k}^k + m) \\ &= \sum_{m=0}^{2^k-1} E_n(x_{2^k} + m) \end{aligned}$$

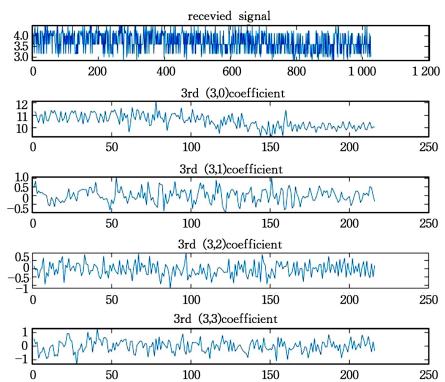
$$= \sum_{m=0}^{2^k-1} E_n(x^{k,m}(i)) \quad (6)$$

第 m 子频带内的信号能量占比,即归一化处理后的子频带能量可以表示为:


$$E_n(m) = \frac{E_n[x^{k,m}(i)]}{E_n[x(t)]} \quad (7)$$

(4)提取小波包系数均值与方差

CSI离散序列经过小波包分解后,任意的小波包基的分解系数长度等于原序列的长度,将序列投影到小波域,其各分量按照步骤(2)中的频率重新组合排序,新的序列可以集中系数,便于本质特征的提取^[20]。由图4可知,在LOS/NLOS环境下,随机选取第3层4个频段的小波包系数,小波包系数的波形都不相同。



(a) LOS



(b) NLOS

图4 LOS/NLOS环境下4个节点的小波包系数

Fig. 4 Wavelet packet coefficients of 4 nodes in LOS/NLOS

原始的CSI采样频率为10 Hz,采样信号可以不失真地复原CSI,在一定时间内采样数据的长度为 N ,将CSI进行3层小波包分解,选取第3级8个频段的系数均值 AVE_n 、系数方差 VAR_n 作为特征, AVE_n 和 VAR_n 表示为:

$$AVE_n = \frac{1}{N} \sum_{k=1}^N d(k) \quad (8)$$

$$VAR_n = \frac{1}{N} \sum_{k=1}^N [d(k) - \bar{d}(k)]^2 \quad (9)$$

其中, $n=1, 2, \dots, 30$, $d(k)$ 为对应的小波包分解系数。对CSI按照式(2)进行计算,形成特征矢量 $\mathbf{M} = [AVE_1, AVE_2, AVE_3, \dots, AVE_{30}]$ 和 $\mathbf{N} = [VAR_1, VAR_2, VAR_3, \dots, VAR_{30}]$ 。

(5)提取特征熵

熵是衡量信号随机程度的特征值,与LOS相比,NLOS

的随机程度越高,熵的值就越大。本文选取了两个特征熵、信息熵和对数能量熵^[21]。 x 代表信号,用 x_i 代表信号 x 在一个正交小波包基上的投影系数。熵 E 取决于传播信号 x 的不确定性,因此存在 $E(0)=0, E(x)=\sum_i E(x_i)$ 。信号 x 的信息熵表示为:

$$E_s(x) = -\sum_n x_i^2 \log(x_i^2) \quad (10)$$

信号 x 的对数能量熵表示为:

$$E_l(x) = \sum_n \log(x_i^2) \quad (11)$$

2.4 分类算法

由于NLOS识别是一个二元分类问题,因此本文选取支持向量机(Support Vector Machine, SVM)作为分类器。它的基本模式是在定义范围中使特征空间内间隔最大的线性分类器。

首先对训练集样本进行标注,类标记为 $y_i \in \{+1, -1\}$, $y_i = +1$ 是正类(即NLOS), $y_i = -1$ 是负类(即LOS)。在样本集构成的输入空间不是线性可分的,因此采用核函数将原始线性不可分的输入空间映射到特征空间以得到特征向量之间的内积,将线性分类器转化为非线性分类器。之后在特征空间中找到一个支持向量,即最优超平面,将正负样本分开。

通过求解拉格朗日对偶问题可以得到最优分离超平面。根据拉格朗日对偶性,得到规划函数如下^[22]:

$$\begin{aligned} \max \quad & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \kappa(x_i, x_j) \\ \text{s. t.} \quad & \sum_{i=1}^l y_i \alpha_i = 0, 0 \leq \alpha_i \leq c, i = 1, 2, \dots, l \end{aligned} \quad (12)$$

其中, c 为惩罚因子, α_i 为拉格朗日乘子, κ 为核函数。核函数的选择会影响分类器的准确率,目前最常用的核函数为径向基核函数(Radial Based Function, RBF)。所谓RBF就是某种沿径向对称的标量函数,能够把原始特征映射到无穷维。由于CSI特征空间是非线性的,采用RBF-SVM使其线性可分。超参数的数量会影响模型选择的复杂性,RBF的超参数较少,模型相对简单,具体函数如下:

$$\kappa(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|_2^2) \quad (13)$$

其中, $\|x_i - x_j\|_2^2$ 为两个特征向量之间的平方欧几里得距离, γ 为自由参数。得到分离超平面之后,根据如下的决策函数可以得到分类结果:

$$y = \text{sgn}[\sum_{i=1}^N \alpha_i y_i \kappa(x_i, x_j) + b] \quad (14)$$

2.5 信号处理流程

根据以上分析,信号的处理流程如图5所示。




图5 信号处理流程

Fig. 5 Signal processing

3 实验结果与分析

3.1 实验环境

本文采用的主要实验设备、接收机为经过改装的台式机(装有Linux,改装网卡为Intel5300),同时携带有一根天线来接收发射机的ping数据包。发射端为单个天线的TP-LINK无线路由器,发射频带为2.4GHz。

为了验证基于CSI的NLOS识别方法的有效性,在实验场景中设计了实测实验。本文的实验场景为半封闭空间结构(见图6),大小为 $3\text{m} \times 8\text{m}$ 。在LOS场景中,接收端与发射端的距离为5m,每个LOS样本包含1000个数据包;在NLOS场景中,利用木板、铁板、人体作为遮挡物分别采集数据,每个NLOS样本包含1000个数据包。



图6 走廊环境

Fig. 6 Corridor environment

3.2 评估因子

为了在实验中客观地展示实验结果,本文提出了准确率(Accuracy)和差错率(False)两个评估因子,其公式分别为:

$$\text{Accuracy} = (TP + TN) / \text{total}$$

$$\text{False} = (FP + FN) / \text{total}$$

其中, TP 代表将NLOS信号判断为NLOS信号; TN 代表将LOS信号判断为LOS信号; FP 代表将NLOS信号判断为LOS信号; FN 代表将LOS信号判断为NLOS信号; total 代表全体样本。

3.3 实验结果

为了证明所提取的特征具有区分性,并且能适应动态和静态的环境,分别设置了动态环境下和静态环境下的训练集和测试集。根据实际情况,保持接收端和发射端的静止状态,由移动的行人作为环境扰动的因素,将有行人扰动的环境作为动态环境,如图7所示。静态环境为接收端和发射端之间没有动态物体出现,障碍物均为静止状态。




图7 动态环境

Fig. 7 Dynamic environment

3.3.1 动态环境下的LOS/NLOS识别效果

动态环境为在接收端和发射端之间,一名同学以匀速移动,遮挡视距路径,如图7所示。实验以小波包系数、能量谱以及熵作为特征, P_d 为96.23%。

为了评估系统的性能,本文选取了两个常见的系统进行对比,即 LiFi 和 AmpN。为了验证 NWI 方法的性能,对比实验中选取了多个幅度和相位特征组成特征集,利用 SVM 进行分类。由于不同实验场景下,数据集的不同可能对精度产生影响,LiFi^[6] 和 AmpN^[8] 的精度来自各自的文献,NWI 和特征集的实验数据来自上述方法采集的数据集。识别效果如图 8 所示。




图 8 动态环境下不同系统的准确率和差错率直方图

Fig. 8 Histogram of accuracy and false of different systems in dynamic environment

通过比较可知,NWI 的性能优于其他系统。LiFi 是目前使用得最广泛的方法,其将 Rician-K 因子、偏度作为特征值,使用线性修正来减轻随机相位噪声引起的时域误差,利用经典的二元假设检验来区分视距和非视距。实验通过移动接收端来模拟动态环境,增加了 NLOS 的随机性,NLOS 识别的准确率为 90.7%。AmpN 将动态环境和静态环境拆分开来,静态环境采用多个幅度特征组成特征簇,利用 BP 神经网络区分;动态环境使用 K-mean 特征,利用二元假设检验机进行分类。由于在实际情况下发射与接收机是不会移动的,因此本文采用行人移动来创造动态环境,实验环境更加真实。与其他方法相比,NWI 在提取特征之前并不需要对原始信号进行预处理,因为随着小波包分解,噪声造成的影响很小,可以直接忽略。

3.3.2 静态环境下的 LOS/NLOS 识别效果

静态环境下,链路更容易受到环境变化的干扰,如在非涅尔区内有行人移动,则传播信号会产生剧烈波动^[23],非视距信号的识别难度也会增加。由于 LiFi 只适用于动态环境,这里采用 AmpN 和特征集作为对比,识别效果如图 9 所示。在静态环境下,NWI 的识别率可以达到 94.75%,相比 AmpN 的识别率稍低。但 NWI 同时适用于动态和静态环境,且精确度较高,AmpN 需要在不同的环境下选取不同的特征值以及分类算法,相比而言 NWI 具有普适性。




图 9 静态环境下不同系统的准确率和差错率直方图

Fig. 9 Histogram of accuracy and false of different systems in static environment

基于特征集方法识别 NLOS 的方法中,特征集包含了目前大部分 CSI 信号的时域、频域特征,有幅度相关矩阵的特征值与特征向量、幅度协方差矩阵的特征值与特征向量、相位相关矩阵的特征值与特征向量、三阶中心距(偏度)、四阶中心距(峰度)、信息熵熵。该方法将上述信号特征作为输入特征矩阵,利用 SVM 进行分类。由于特征选取过多,产生过拟合现象,从而导致精度下降。

结束语 针对目前大量在单一环境下基于幅度特征值的 NLOS 识别方法,本文提出了一种新的基于小波包变换的识别方法,其提取小波包系数、能量谱和熵作为特征值,利用 SVM 作为分类算法识别 NLOS,具有良好的效果。实验结果表明,NWI 的静态识别准确率约为 94.75%,动态识别准确率约为 96.23%。与其他方法相比,NWI 具有鲁棒性和普适性。NLOS 识别是实现高精度应用的基础,在此之上可以对基于 CSI 的感知应用进行更多的探索。

参 考 文 献

- [1] STUDER C, MEDJKOUH S, GONULTAS E, et al. Channel Charting: Locating Users Within the Radio Environment Using Channel State Information [J]. IEEE Access, 2018, 6: 47682-47698.
- [2] NAKATANI T, MAEKAWA T, SHIRAKAWA M, et al. Estimating the Physical Distance between Two Locations with Wi-Fi Received Signal Strength Information Using Obstacle-aware Approach [J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2018, 2(3): 1-26.
- [3] MA J, WANG H, ZHANG D, et al. A Survey on Wi-Fi Based Contactless Activity Recognition [C] // Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People, & Smart World Congress. IEEE, 2017.
- [4] QIAN K, WU C, YANG Z, et al. Widar: Decimeter-Level Passive Tracking via Velocity Monitoring with Commodity Wi-Fi [C] // Acm International Symposium. ACM, 2017.
- [5] YANG Z, LIU Y H. WiFi radar: from RSSI to CSI [J]. China Computer Society Newsletter, 2014, 10(11): 55-60.
- [6] ZHOU Z, ZHENG Y, WU C, et al. LiFi: Line-Of-Sight identification with WiFi [C] // IEEE Conference on Computer Communications, 2014.
- [7] WU C, ZHENG Y, ZHOU Z, et al. PhaseU: Real-time LOS identification with WiFi [C] // Computer Communications, 2015.
- [8] XIAO F, GUO Z, ZHU H, et al. AmpN: Real-time LOS/NLOS identification with WiFi [C] // 2017 IEEE International Conference on Communications (ICC). IEEE, 2017.
- [9] CHOI J S, LEE W H, LEE J H, et al. Deep Learning Based NLOS Identification With Commodity WLAN Devices [J]. IEEE Transactions on Vehicular Technology, 2018, 67(4): 3295-3303.
- [10] GADANAYAK D A, MALLICK R K. Interharmonics based high impedance fault detection in distribution systems using maximum overlap wavelet packet transform and a modified empirical mode decomposition [J]. International Journal of Electric-

- cal Power and Energy Systems, 2019, 112:282-293.
- [11] CHEN G, LI Q Y, LI D Q, et al. Main frequency band of blast vibration signal based on wavelet packet transform[J]. Applied Mathematical Modelling, 2019, 74:569-585.
- [12] QUAN B, ZHU F, KANG Y, et al. Power Spectral Density Estimation of Seismic Wave Based on Wavelet Transform[C]// Control & Decision Conference. 2008.
- [13] DODIA S, EDLA D R, BABLANI A, et al. An efficient EEG based deceit identification test using wavelet packet transform and linear discriminant analysis[J]. Journal of Neuroscience Methods, 2019, 314:31-40.
- [14] LI M A, SUN M, SUN Y J. EEG feature extraction method based on wavelet packet and deep belief network[J]. Journal of Electronic Measurement and Instrument, 2018, 32(1):111-118.
- [15] SANJEEV K, AMARPAL S, MANOJ K. Covert communication integrates into wavelet packet transform OFDM system over Rayleigh fading channel[J]. Wireless Networks, 2020, 26: 81-89.
- [16] MA Y, ZHOU G, WANG S. WiFi Sensing with Channel State Information: A Survey [J]. ACM Computing Surveys, 2019, 52(3):1-36.
- [17] WANG S H, ZHANG Y D, DONG Z, et al. Wavelet Families and Variants[M]// Pathological Brain Detection. 2018.
- [18] SUI X, WAN K, ZHANG Y. Pattern recognition of SEMG based on wavelet packet transform and improved SVM[J]. Optik-International Journal for Light and Electron Optics, 2019, 176:228-235.
- [19] WANG Y, GONG D, PANG L, et al. RVFL-Based Optical Fiber Intrusion Signal Recognition With Multi-Level Wavelet Decomposition as Feature[J]. Photonic Sensors, 2018, 8(3):234-241.
- [20] DIBAL P Y, ONWUKA E N, AGAJO J, et al. Application of wavelet transform in spectrum sensing for cognitive radio: A survey[J]. Physical Communication, 2018, 28:45-57.
- [21] MASOUD A, HASHIM H, MOHAMMAD L O, et al. An Anti-Islanding Protection Technique Using a Wavelet Packet Transform and a Probabilistic Neural Network[J]. Energies, 2018, 11(10):2701.
- [22] ZHOU R, LU X, ZHAO P, et al. Device-Free Presence Detection and Localization With SVM and CSI Fingerprinting[J]. IEEE Sensors Journal, 2017, 17(23):7990-7999.
- [23] NIU K, ZHANG F, XIONG J, et al. Boosting fine grained activity sensing by embracing wireless multipath effects[C]// Proceedings of the 14th International Conference on emerging Networking EXperiments and Technologies. ACM, 2018:139-151.



TIAN Chun-yuan, born in 1995, Ph.D. Her main research interests include advanced wireless communication and Internet of things.



YU Jiang, born in 1961, professor. His main research interests include network communication theory, wireless communication systems, radio monitoring and positioning, and image processing.