

基于并行空时深度学习网络的无设备身份识别方法

唐智灵 杨爱文

(桂林电子科技大学信息与通信学院 广西 桂林 541004)

摘要 针对现有人员身份识别方法存在灵活性差、特征提取不足的问题,分析人体步态对信道状态信息(CSI)幅值产生的影响,提出一种基于Wi-Fi信道状态信息的无设备人员身份识别方法。将CSI幅值矩阵的每一列子载波作为样本,利用小波变换获取样本中代表人员活动的低频信息。通过并行深度学习模型WiD(Wi-Fi identification)提取样本中人体步态的大小和发生的先后顺序,合并两种步态特征作为人员的身份特征。通过Softmax函数进行分类,实现身份识别。与当前先进方法相比,在未明显增加时间代价和空间代价的条件下,该方法获得了更高的身份识别精度和更好的模型鲁棒性。

关键词 信道状态信息 并行深度学习模型 人员身份识别 双向长短期记忆网络 卷积神经网络

中图分类号 TP391.413 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2022.03.027

DEVICE-FREE IDENTIFICATION METHOD BASED ON PARALLEL SPACE-TIME DEEP LEARNING NETWORK

Tang Zhiling Yang Aiwen

(School of Information and Communication, Guilin University of Electronic Technology, Guilin 541004, Guangxi, China)

Abstract Aiming at the problems of poor flexibility and inadequate feature extraction in the existing methods of personal identification, the influence of human gait on the amplitude of channel state information(CSI) is analyzed, and a device-free person identification based on Wi-Fi channel state information is proposed. It took each column of subcarriers of the CSI amplitude matrix as a sample, and used wavelet transform to obtain low-frequency information representing the activities of people in the sample. We used parallel deep learning models WiD(Wi-Fi identification) to extract the size and sequence of human gait in the sample, and merged the two gait characteristics as the identity characteristics of the person. We classified them through the Softmax function to achieve identity recognition. Compared with current advanced methods, this method achieves higher identification accuracy and better model robustness without significantly increasing time and space costs.

Keywords Channel state information Parallel deep learning model Personnel identification Bidirectional long-short-term memory network Convolutional neural network

0 引言

针对人员的身份识别问题,如何以更便携的方式获取更准确的识别精度成为当前研究的热点。现有的研究利用可穿戴传感器^[1]、摄像头^[2]、人体巩膜特

征^[3]等实现身份识别,这些方法存在设备昂贵、不易携带、灵活性差等问题。随着无线产业的发展,利用无线信号以无设备的方式实现身份感知正发展为一种新兴技术。当一个人在无线网络附近时,将会对周围的无线信号产生影响,对信号产生的影响进行深入分析可以获取有用的信息,例如人的活动信息^[4]、

跌倒检测^[5],甚至生理特征。已有研究利用 Wi-Fi 信道状态信息以无设备的方式实现用户身份识别。文献[6]利用带低滤波器和峰谷检测算法获取 CSI 中人员每一步的波形特性,通过决策树分类器实现身份分类识别。文献[7]利用主成分分析法 PCA (Principal Components Analysis) 和离散小波变换 DWT (Discrete Wavelet Transform) 压缩 CSI 波形特征,通过 K 近邻算法实现身份分类识别。文献[8]利用 PCA 和隐形马尔可夫模型对 CSI 特征进行初步分类,通过支持向量机实现身份分类识别。文献[9]利用 PCA 和低通滤波器获取 CSI 特征,通过支持向量机实现身份分类识别。但上述使用机器学习分类器的身份识别方法在数据预处理阶段需要手动提取 CSI 的波形特征,操作复杂并且无法细腻地提取射频信号中隐含的生物特征代表性模式,这些方法只能在 2~10 人中实现最高 93% 的身份识别率。随着深度神经网络的快速发展,神经网络不但可以处理更加庞大的样本数量,其强大的特征提取能力在模式识别方面也表现良好。先进的研究利用 PCA 算法获取 CSI 波形前 354 个特征向量作为人员身份特征,通过 23 层卷积神经网络 CNN (Convolutional Neural Network) 实现人员身份特征提取和识别^[10],可在大样本 24 个人中实现 89.9% 的身份识别精度。该方法使用卷积神经网络虽然可以自动提取样本的空间特征,但卷积神经网络具有平移不变性,会将 CSI 时间序列中不同位置的相同特征视为同种步态特征,其并未考虑不同步态特征发生的先后顺序。CSI 数据记录的是某段时间内人体活动对无线信号的扰动,其样本特征与时间有关,所以单单使用卷积神经网络无法充分提取 CSI 中隐藏的生物表示特征。

为了有效解决现有研究存在的特征提取操作复杂和特征提取不足的问题,本文提出一种基于并行时空深度网络的身份识别方法。首先使用邻式均值插补对采集到 CSI 样本进行校准,然后使用小波变换提取 CSI 样本中由于人员步态诱发的射频特征,最后设计了一个称为 WiD 的并行深度学习模型。该模型将卷积神经网络与双向长短期记忆网络相结合,自动从预处理后的 CSI 样本中提取人员步态特征大小及发生的先后顺序,融合两种步态特征细腻地表示人员身份特征。实验结果表明,在未明显增加时间代价和空间代价的前提下,该方法可以在 30 个人中达到最高 98.7% 的身份识别精度。

1 信道状态信息

信道状态信息 (CSI) 是在正交频分复用 (Orthogonal Frequency Division Multiplexing, OFDM) 技术中作为对信道状态的估计。随着 Wi-Fi 采用 OFDM 技术,几乎在所有的 Wi-Fi 设备上都有获取到 CSI 信息的潜力。对于每一条天线链路的每一个子载波具有相应的 CSI 值对应。假设发送端天线数目为 N_t ,接收端天线数目为 N_r ,子载波个数为 m ,那么每一次接收都能获得一个大小为 $N_r \times N_t \times m$ 的 CSI 矩阵。该 CSI 矩阵描述了无线信号如何从发送设备到达接收设备,CSI 中的子载波包含了不同天线对在传输时的幅值和相位信息,其记录了无线信号在空间传输的散射、衰落、功率衰减与距离、阴影等信息,可由如下模型表示:

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

式中: \mathbf{y} 为接收端信号; \mathbf{x} 为发送端信号; \mathbf{H} 为信道矩阵; \mathbf{n} 为噪声向量。噪声可以表示为 $\mathbf{n} \in N(0, S)$,所以可以估计出:

$$\hat{\mathbf{H}} = \frac{\mathbf{y}}{\mathbf{x}} \quad (2)$$

信道状态信息就是对 \mathbf{H} 的估计,对于第 K 个子载波,CSI 可以表示为:

$$\mathbf{H}(K) = \|\mathbf{H}(K)\| e^{j\angle \mathbf{H}(K)} \quad (3)$$

式中: $\|\mathbf{H}(K)\|$ 表示第 K 个子载波的幅度; $e^{j\angle \mathbf{H}(K)}$ 为第 K 个子载波的相位。人员入侵会对 Wi-Fi 无线信道产生扰动,这些扰动被记录在 CSI 数据中,表示为一系列随时间变化的相位和幅度,所以 CSI 数据中的幅值信息和相位信息可被视为射频生物识别的特征表示。

2 基于并行特征提取的 WiD 模型

WiD 模型包括空间特征提取分支和时间特征提取分支,它的结构如图 1 所示。WiD 模型的空间特征提取分支先使用像素转置卷积网络 Pconv1D (pixel transposed convolutional network)^[11]对 CSI 时间序列样本进行像素级特征学习,同时建立输出映射与相邻元素的依赖关系,最后使用卷积神经网络对像素转置卷积的输出进行空间特征提取。WiD 模型的时间特征提取分支使用 BiLSTM 来对 CSI 时间序列进行双向特征学习,这将充分挖掘 CSI 数据中人员动作的前后信息来描述身份特征。通过提取 CSI 数据中包含的空间特征表示和时间特征表示,将其结合到一起可以更细腻地描述

人员的生物特征表示。

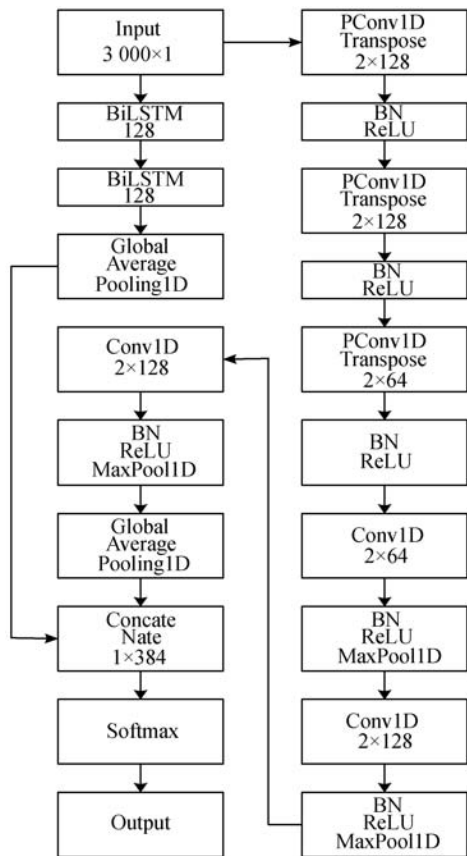


图 1 WiD 模型构架

2.1 数据预处理

数据预处理包括邻式均值插补、小波去噪、数据标准化三部分。通过数据预处理对测量的 CSI 数据进行缺失值插补并去除环境噪声,最后将 CSI 数据规范成深度学习网络方便处理的类型。

2.1.1 邻式均值插补

由于信号的空间传输或硬件设备等问题,接收到的 CSI 矩阵含有少量缺失元素。相邻子载波幅值与相位波形的变化趋势很相近,对数据进行邻式均值插补,这种方法在数据还原能力上要优于行式插补,它不但不会引起太大偏差,还可以尽量细腻地还原原始波形。设第 i 列缺失的数据为 x_i ,用其左右两列的数据求均值进行插补,即 $x_i = \frac{x_{i+1} + x_{i-1}}{2}$,如果左边或右边只有一列数据则进行数据替换,即 $x_i = x_{i-1}$ 或 $x_i = x_{i+1}$ 。

2.1.2 小波去噪

在复杂的室内环境中,原始 CSI 数据中存在许多噪声。其他射频设备的干扰、多径效应和传输功率的变化等会在 CSI 数据中引入高频噪声和突发噪声。考虑到身体各部分运动速度不一样,传统的低通滤波器提取则会损失很多细节^[12]。由于 CSI 信号是非平稳信号,它是时间上的离散采样信号,所以本文使用

DWT 来分解 CSI 中不同尺度的信号,提取人员活动的低频信息。小波变换将数据信息集中在较大的小波系数中,将噪声信息集中在较小的小波系数中。本文采用离散小波变换对在 Donoho 等^[13]的通用阈值和级别为 3 的水平相关阈值下对每个 CSI 样本进行去噪。没有人员入侵时的 CSI 波形如图 2 所示,有人员入侵时的 CSI 幅值和频谱图如图 3 所示,小波变换后的 CSI 幅值和频谱图如图 4 所示。






图 2 没有人员入侵时的 CSI 子载波幅值




(a) 小波变换前的波形图




(b) 小波变换前的频谱图

图 3 有人员入侵时的 CSI 子载波幅值和频谱图



(a) 小波变换后的波形图



(b) 小波变换后的频谱图

图 4 小波去噪后的 CSI 子载波幅值和频谱图

由图 3 和图 4 可知小波去噪前的波形频率最高达到 3 000 ~ 4 000 Hz,存在大量的环境噪声,小波变换后的波形频率在 500 Hz 以内,表示人员行走的正常频率^[12]。

2.1.3 数据标准化

因为同一个特征在不同样本中的取值可能相差大,所以一些异常小或异常大的数据会误导模型的正确训练,如果数据的分布很分散也会影响训练结果。这都会造成较大的方差,本文使用机器学习的 StandardScaler 函数对样本进行基于特征值的均值和标准差的数据标准化,即转换为均值为 0、标准差为 1 的正态分布。它的计算公式为:

$$X_{ST} = \frac{(X_i - \mu)}{\sigma} \quad (4)$$

式中: X_{ST} 表示标准化后的数据; X_i 表示第 i 个样本数据; μ 表示样本的均值; σ 表示样本的标准差。将数据转换为正态分布不仅可以消除 CSI 环境中的静态信息,还可以减少培训时间、提高模型性能。

2.2 空间特征提取分支

空间特征提取分支包含像素转置卷积网络和卷积神经网络。像素转置卷积层可以对数据进行像素级别的特征表示同时建立与相邻元素的依赖关系^[11],这将充分挖掘预处理后 CSI 数据间存在的隐藏时间关系。像素转置卷积层顺序生成中间特征图,即后续生成的中间特征映射需要依赖于先前生成的映射,这使它能够加强中间特征图之间的依赖关系,从而在最终输出特征图中添加相邻像素之间的依赖关系。最终输出特征图时中间特征图的组合形式,其公式表达为:

$$\begin{aligned} F_1 &= F_{in} * k_1 \\ F_2 &= [F_{in}, F_1] * k_2 \\ F_i &= [F_{in}, F_1, F_2, \dots, F_{i-1}] * k_i \\ F_n &= [F_{in}, F_1, F_2, \dots, F_{n-1}] * k_n \\ F_{out} &= F_1 \oplus F_2 \dots \oplus F_i \dots \oplus F_n \end{aligned} \quad (5)$$

式中: F_{in} 代表输入数据; F_{out} 代表输出特征映射,*表示卷积运算; $[\cdot, \cdot]$ 表示像素的并置; $k_i (i=1, 2, \dots, n)$ 表示一组卷积内核; \oplus 表示对每个像素的特征映射进行周期性的打乱和组合运算; $F_i (i=1, 2, \dots, n)$ 是由对应的卷积核 k_i 生成的中间特征图。

通过 CNN 对像素转置卷积输出的特征映射进行学习,每层 CNN 中间都使用最大池化层(Maxpool)和损失层(Dropout),并在 ReLU 非线性激活函数前使用批量正则化层 BN(Batch Normalization)对样本进行批量正则化操作,最后通过全局平均池化(Global_Average_Pooling)输出一维数据。BN 层让深度学习模型在训练过程中使得每一层神经网络的输出保持相同分布,这样可以避免梯度消失并且加快训练速度。样本经过该分支学习后得到的 CSI 特征表示如下:

$$F = [F_1, F_2, \dots, F_i, \dots, F_{128}] \quad (6)$$

式中: F 代表卷积网络层的输出; F_i 代表空间特征。

2.3 时间特征提取分支

由于 LSTM 模型只能正向处理 CSI 数据,而 CSI 数据中未来的信息对于确定步态的先后顺序也至关重要。例如左腿和右腿迈出的步伐都会被识别为特征,但两种特征的最终位置是不同的,因此本方法利用双向长短期记忆网络 BiLSTM (Bidirectional Long-Short-Term Memory Network) 从 CSI 中学习有效步态特征。BiLSTM 由两层 LSTM 组成,它包含前向传播层和后向传播层如图 5 所示。




图 5 双向 LSTM 网络结构

前向传播层和后向传播层的隐藏状态可以分别表示为 \vec{h}_t 和 \overleftarrow{h}_t , 其中 \rightarrow 和 \leftarrow 分别表示前向传播和后向传播过程。BiLSTM 在 t 时刻的隐藏状态 h_t 是前向传播层和后向传播层隐藏状态的串联,可表示为:

$$h_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (7)$$

BiLSTM 网络可以在前向和后向上处理 CSI 序列,从而产生更丰富的动作特征,这将给更重要的特征和时间步长分配更大的权重,并为人类活动识别提供更优异的性能。利用 BiLSTM 网络,CSI 序列的过去和未来依赖的信息都被认为是用于识别人类活动序列的信息。样本经过该分支学习后得到的 CSI 特征表示如下:

$$B = [B_1, B_2, \dots, B_i, \dots, B_{256}] \quad (8)$$

式中: B 代表 BiLSTM 网络的输出; B_i 代表时间特征信息。

2.4 模型输出

空间特征提取分支对 CSI 数据提取的特征表示为 $F = [F_1, F_2, \dots, F_{128}]$, 时间特征提取分支对 CSI 数据学习后得到的特征表示为 $B = [B_1, B_2, \dots, B_{256}]$ 。Concat 层将特征表示 F 和特征表示 B 联合起来表示为:

$$E = [F_1, F_2, \dots, F_{128}, B_1, B_2, \dots, B_{256}] \quad (9)$$

具体网络结构如图 6 所示。

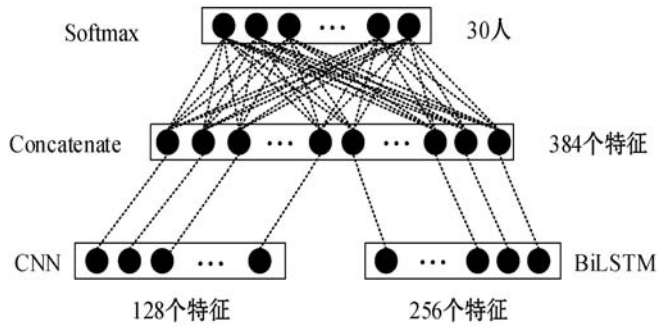


图6 模型输出网络

输出层通过学习 Concat 层的特征映射生成得分向量函数 \vec{Z} , \vec{Z} 中每个元素是特定类的得分。模型使用 Softmax 激活函数,它使用取幂和归一化将得分向量 \mathbf{Z} 转换为概率向量 $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{id}, \dots, y_{iD}]$, 其中 D 表示类的数量; y_{id} 是第 i 个 CSI 样本被预测为 d 类的概率。 y_{id} 表示为:

$$y_{id} = P(d | i) = \frac{\exp^{Z(d)}}{\sum_{j=1}^D \exp^{Z(j)}} \quad (10)$$

式中: \mathbf{Z} 表示输入向量的元素; D 表示输入向量元素的总数。

具有最大概率值的 d_{\max} 就是第 i 个 CSI 样本的预测类,其表示为:

$$d_{\max} = \arg \max_{d \in D} P(d | i) \quad (11)$$

上述分类器称为 Softmax 分类器。WiD 模型训练数据后通过最小化交叉熵损失函数 (categorical_crossentropy) 来最大化其分类精度,表示为:

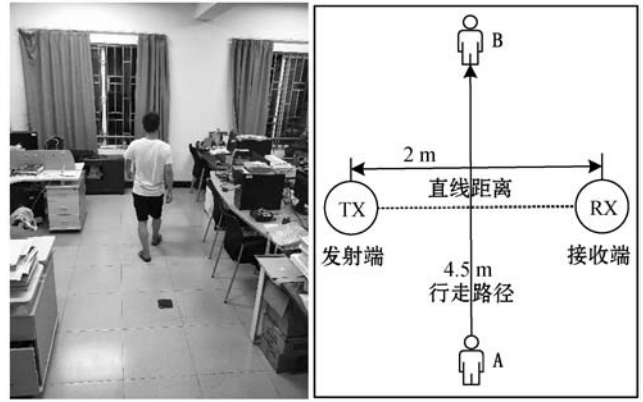
$$L(t, y) = - \sum_{i=1}^N \sum_{d \in D} t_{id} \log(y_{id}) \quad (12)$$

式中: 当且仅当第 i 个样本属于 d 类时 t_{id} 为 1; N 为每批次训练的样本个数。

3 实验

3.1 实验环境

本文采用 Intel 5300 无线网卡作为工控板的数据接收器, TP-Link 路由器作为数据发送器, 其中发射天线 (N_t) 和接收天线 (N_r) 的个数都为 1。实验所用的 Intel 5300 无线网卡有三个通道宽度, 我们获得 30 个子载波信息, 所以实验获得 CSI 矩阵大小为 $1 \times 1 \times 30$ 。实验环境为典型的室内实验环境, N_t 和 N_r 在视距条件下相距 2 m, 采样频率为 1 000 Hz, 采样时间为 3 s, 每次获得的子载波序列长度为 3 000。实验人员从 A 走到 B, 记录下 CSI 数据后开始下一次实验, 实验场景如图 7 所示。



(a) CSI 数据采集环境

(b) 数据采集环境细节

图7 实验场景

3.2 数据收集和训练细节

数据集包括 30 个人, 每个人采集 45 个实验样本, 每个实验样本的 CSI 矩阵大小为 $(3\ 000, 30)$ 。本实验将 CSI 矩阵的每列子载波作为一个样本, 所以每人 45 个样本扩展成为 1 350 个样本, 30 个人一共获得 40 500 组样本实例, 每个样本大小为 $(3\ 000, 1)$ 。

样本数据中 70% 划分为训练数据集, 30% 为验证数据集。由于数据样本较多, Dropout 层参数设置为 0.6, 即每个 Dropout 层要丢弃 60% 的神经元。实验在模型编译时使用 amsgrad 优化算法^[14], 因为 amsgrad 可以优化 Adam 后期不收敛问题, 而且可以快速接近 SGD 的收敛值。模型每个训练批次样本数为 128, 训练了 100 个批次, 采用 5 折交叉验证。

3.3 仿真结果与讨论

为了展示本文方法在处理 CSI 样本上的优越性, 实验对比了文献[10]中使用的 CNN 特征提取方法与本文方法在处理相同数据上的识别精度与模型复杂度。

3.3.1 识别精度

训练准确度和测试准确度是衡量模型优越性的两个基本评估指标, 训练准确度是训练集中样本的正确预测百分比。测试准确度来自样本测试集的正确识别率, 但测试集不能用于更新模型的权重, 这使测试准确度能够衡量模型在处理未知数据的性能。

$$\text{训练准确度} = \frac{\text{正确预测样本数}}{\text{训练集样本数}} \quad (13)$$

$$\text{测试准确度} = \frac{\text{正确预测样本数}}{\text{测试集样本数}} \quad (14)$$

由图 8 可知, 两种模型在测试集上都达到了 100% 的识别精度, 但 CNN 模型在训练集上只达到了 93.2% 的识别精度, WiD 模型在训练集上达到了 98.7% 的识别精度。因为 CNN 模型只能提取 CSI 样本中人员步态的空间特征信息, 不同位置相同大小的步态特征会

被 CNN 认为是同种特征。WiD 模型可利用 CNN 分支提取人员的步态大小,利用 BiLSTM 分支提取不同大小的步态发生的先后顺序,从而获取更细腻的步态特征表示。




图 8 模型识别精度对比

3.3.2 损失函数

损失函数是用来估量模型的预测值与真实值的不一致程度,是衡量模型鲁棒性的指标,损失函数越小表明模型的鲁棒性越好。

由图 9 可知,CNN 模型在训练 40 批次左右时基本收敛,WiD 模型在训练 30 批次左右时基本收敛,说明 WiD 模型有更好的鲁棒性。




图 9 模型损失函数对比

3.3.3 时间和空间代价

实验在 Linux 18.04 系统上使用 Python 框架下的 memory_profiler 方法对比了两种方法在处理相同数据集上的时间代价和空间代价,其中系统显卡配置为 1060-6 GB,4 GB 运行内存,具体对比如图 10 所示。




图 10 空间时间代价对比

可以看出,基于 CNN 的特征提取方法的最大时间复杂度约为 1 426 s,最大空间复杂度约为 2 061 MB;基于 WiD 的特征提取方法的最大时间复杂度约为 1 646 s,最大空间复杂度约为 2 210 MB。本文方法相比于 CNN 特征提取方法,空间复杂度增加 7.2%,时间复杂度增加 15.4%。因为 WiD 模型使用并行网络进行特征提取,样本需要同时两个分支进行训练,再融合不同分支的特征表示人员步态特征,而 CNN 模型使用串行网络训练样本,时间与空间代价相对较低。

3.3.4 混淆矩阵

混淆矩阵用于更好地了解模型在对特定类别的数据进行分类时的优异程度。混淆矩阵包含四个度量真阳性 (TP)、真阴性 (TN)、假阳性 (FP) 和假阴性 (FN)。其中,TP 是预测为正例的正样本数量;TN 是预测为反例的负样本数量;FP 是预测为正例的负样本数量;FN 是预测为反例的正样本数量。混淆矩阵的对角线表示正确识别率,上三角区域和下三角区域表示错误识别率。

图 11 展示了 WiD 模型生成的混淆矩阵,右侧条状柱从下到上颜色逐渐加深,颜色越深表示预测标签的准确度越大。在混淆矩阵中,30 个人的步态样本表示为 P_i ,其中 $i \in 1, 2, \dots, 30$ 。主对角线大部分趋向于 1,上三角区域和下三角区域只出现少数识别误差,表明模型具有良好的识别精度。




图 11 混淆矩阵

4 结 语

本文改进现有身份识别方法存在的不足,提出基于并行时空深度网络的无设备身份识别方法。该方法采用一系列数据预处理方案,对嘈杂和错误的 CSI 数

据样本进行校准和去噪,提取人员步态诱发的射频特征。然后利用空时深度神经网络 WiD 充分感知人员动作出现的时间和大小,并将两者结合作为人员身份的细腻特征表示。与现有的身份识别方法相比,在未明显提升模型时间和空间代价的条件下,本文方法获取了更高的识别精度和模型鲁棒性。但本实验只考虑了单个实验环境的身份识别,在后续的工作中将探究不同环境下的不同生物特征(如身高、体脂率、含骨率等)对 Wi-Fi 身份识别的影响,进一步提高该模型的鲁棒性及实用性。

参 考 文 献

- [1] 杨雄. 基于指静脉识别技术的云计算安全身份认证[J]. 计算机应用与软件, 2017, 34(10): 325-329.
- [2] 胡佩, 陈冠豪. 二进制特征与联合层叠结构的人脸识别研究[J]. 计算机应用与软件, 2019, 36(2): 228-234.
- [3] Delna K V, Sneha K A, Aneesh R P. Sclera vein identification in real time using single board computer[C]//2016 International Conference on Next Generation Intelligent Systems (ICNGIS), 2016: 1-5.
- [4] 刘立双, 魏忠诚, 张春华, 等. 基于 WiFi 信道状态信息的人员活动持续时间估计[J]. 计算机应用, 2019, 39(7): 2056-2060.
- [5] 崔然, 冯秀芳. 基于 CSI 的跌倒行为识别方法[J]. 计算机工程与设计, 2019(8): 2331-2336.
- [6] Zeng Y, Pathak P H, Mohapatra P. WiWho: WiFi-based person identification in smart spaces[C]//2016 15th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN), 2016: 1-12.
- [7] Xin T, Guo B, Wang Z, et al. FreeSense: Indoor human identification with Wi-Fi signals[C]//2016 IEEE Global Communications Conference (GLOBECOM), 2016: 1-7.
- [8] Zheng R, Zhao Y, Chen B. Device-free and robust user identification in smart environment using WiFi signal[C]//2017 IEEE International Symposium on Parallel and Distributed Processing with Applications and 2017 IEEE International Conference on Ubiquitous Computing and Communications (ISPA/IUCC), 2017: 1039-1046.
- [9] Lü J, Yang W, Man D, et al. Wii: Device-free passive identity identification via WiFi signals[C]//GLOBECOM 2017-2017 IEEE Global Communications Conference, 2017: 1-6.
- [10] Pokkunuru A, Jakkala K, Bhuyan A, et al. NeuralWave: Gait-based user identification through commodity WiFi and deep learning[C]//IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society, 2018: 758-765.
- [11] Gao H, Yuan H, Wang Z, et al. Pixel transposed convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(5): 1218-1227.
- [12] Wang W, Liu A X, Shahzad M. Gait recognition using wifi signals[C]//2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing, 2016: 363-373.
- [13] Donoho D, Johnstone I. Ideal spatial adaptation by wavelet shrinkage[J]. Biometrika, 1994, 81(3): 425-455.
- [14] Reddi S J, Kale S, Kuma S. On the convergence of adam and beyond[EB]. arXiv:1904.09237, 2019.
- ~~~~~
- (上接第 164 页)
- [6] Al-Mohair H K, Mohamad-Saleh J, Suandi S A. Color space selection for human skin detection using color-texture features and neural networks[C]//2014 International Conference on Computer and Information Sciences, 2014: 1-6.
- [7] Tara R, Santosa P, Adji T. Hand segmentation from depth image using anthropometric approach in natural interface development[J]. International Journal of Scientific & Engineering Research, 2012, 3(5): 1-4.
- [8] 吴鹏, 牛斌, 马利, 等. 融合皮肤检测的卷积姿势机手势分割方法[J]. 计算机工程与设计, 2019, 40(11): 3205-3211.
- [9] 师乐, 汤汶, 万韬阮, 等. 复杂背景下的人体轮廓提取算法[J]. 科学技术与工程, 2019, 19(9): 138-142.
- [10] 陆焱焱. 肤色和运动信息相结合的手势分割法[J]. 福建电脑, 2019, 35(12): 89-90.
- [11] 董旭德, 许源平, 舒红平, 等. 基于质心分水岭算法的静态手势分割算法模型[J]. 智能系统学报, 2019, 14(2): 346-354.
- [12] 赵艳妮, 郭华磊. 基于多色彩空间的肤色检测研究[J]. 计算机技术与发展, 2013, 23(10): 250-252, 257.
- [13] 崔鹏, 燕天天. 融合 YCbCr 肤色模型与改进的 Adaboost 算法的人脸检测[J]. 哈尔滨理工大学学报, 2018, 23(2): 91-96.
- [14] 李继纲. 基于 FPGA 的手势识别遥控器[D]. 西安: 西北大学, 2015.
- [15] Shaneh M, Mahyari A G. Impulse noise reduction based on improved median epsilon-filter[J]. International Journal of Electronics, 2012, 99(11): 1489-1496.
- [16] 李理, 杨晓翔, 刘键涛, 等. 基于 Canny 算子和 FFT 的非接触图像振动测量研究[J]. 机电工程, 2019, 36(11): 1183-1187.
- [17] 王安, 王芳荣, 郭柏苍, 等. 基于边缘检测的视差图效果优化[J]. 计算机应用与软件, 2019, 36(7): 236-241.
- [18] Du H, Chen X, Xi J. An improved background segmentation algorithm for fringe projection profilometry based on Otsu method[J]. Optics Communications, 2019, 453: 124206.
- [19] Budzan S, Buchczik D, Pawelczyk M, et al. Combining segmentation and edge detection for efficient ore grain detection in an electromagnetic mill classification system[J]. Sensors, 2019, 19(8): 1805.