

基于 CRNN 的 CSI 动作识别

丁文超, 张俊宝, 阴庚雷

(中原工学院 计算机学院, 河南 郑州 450007)

摘要:随着 Wi-Fi 感知技术的发展,出现了大量使用 Wi-Fi 信道状态信息(channel state information, CSI)进行动作识别的应用。然而大多数的方法在数据预处理和训练阶段都依赖于人工构建特征,构建过程耗时耗力并且需要专家的领域知识。针对上述问题,提出一种基于 CRNN(convolutional recurrent neural network)的 CSI 动作识别方法。将不同手势的 CSI 数据做低通滤波处理后,通过自组织映射(self organizing maps, SOM)聚类的结果选择最佳子载波,并对该子载波上的 CSI 数据进行扩增。然后,使用格拉姆角求和场(Gramian angular summation fields, GASF)方法将一维 CSI 数据转换成二维 GASF 图像,作为 CNN、LSTM 构成的 CRNN 网络的输入数据,训练过程中使用链接时序分类(connectionist temporal classification, CTC)作为损失函数。实验结果表明,该方法能在训练数据较少的情况下达到较高的识别精度,且无需手动构建特征。

关键词:信道状态信息; CRNN; 动作识别; 自组织映射; 格拉姆角场; 链接时序分类

中图分类号: TP391.41

文献标识码: A

文章编号: 1673-629X(2021)06-0007-06

doi: 10.3969/j.issn.1673-629X.2021.06.002

CSI Action Recognition Based on CRNN

DING Wen-chao, ZHANG Jun-bao, YIN Geng-lei

(School of Computer Science, Zhongyuan University of Technology, Zhengzhou 450007, China)

Abstract: With the development of Wi-Fi sensing technology, a large number of applications have emerged for motion recognition using channel state information (CSI) from Wi-Fi. However, most methods rely on manual construction of features during the data pre-processing and training stages, the construction process is often time-consuming and labor-intensive and requires expert domain knowledge. Aiming at these problems, we propose a CSI action recognition method based on convolutional recurrent neural network (CRNN). After the CSI data of different gestures are processed by low-pass filter, the best subcarrier is selected by the result of self-organizing maps (SOM) clustering, and the CSI data on the subcarrier is amplified. Then, one-dimensional CSI data is transformed into two-dimensional GASF images by using the method of gamma angular summation fields (GASF), which is used as the input data of CRNN composed of CNN and LSTM. In the training process, the connectionist temporal classification (CTC) is used as the loss function. The experiment indicates that the proposed method can achieve high recognition accuracy with less training data, and there is no need to manually construct features.

Key words: CSI; CRNN; action recognition; SOM; GASF; CTC

0 引言

随着 Wi-Fi 技术的发展以及相关硬件价格的下降,生活中各种场所几乎均有 Wi-Fi 信号的存在。Wi-Fi 信号不仅能传输数据,利用其信道状态信息还能进行人体动作识别^[1]。

传统的动作识别需要借助如加速度计、陀螺仪等接触式传感设备^[2]对用户进行监测来识别用户的动作,又或者是借助摄像头等非接触设备的基于视觉^[3]

的动作识别。相较于传统的识别方式,基于 CSI 的动作识别利用的是环境中广泛存在的 Wi-Fi 信号,具有不依赖特殊传感器、成本低、易扩展、不存在隐私泄露等优点。

但是当前应用大部分都依赖于手工选择子载波,构建分类特征。因此,该文提出一种基于学习的识别方法,无需专业知识构建 Wi-Fi 传播模型,即可进行训练识别。

收稿日期: 2020-08-01

修回日期: 2020-12-03

基金项目: 国家自然科学基金(U1504614); 河南省教育厅科学技术研究重点项目(14B520055)

作者简介: 丁文超(1995-),男,硕士研究生,CCF 会员(C5152G),研究方向为机器学习、无线传感网络;张俊宝,讲师,博士,研究方向为无线网络、移动计算。

1 相关工作

由于采集数据时网卡报告了多组子载波的 CSI, 且不同的子载波对于环境变化的敏感度不同, 所以要选取合适的子载波来提取 CSI 数据。WiFall^[4] 将 30 组子载波上的 CSI 取平均值作为训练数据来检测摔倒动作的发生。LBR^[5] 选取 CSI 方差第二大的子载波作为有效子载波来提取 CSI。上述方法均根据某个统计值来选择子载波, 需要大量的时间研究数据从而选择合适的统计特征。该文提出一种基于 SOM^[6] 聚类的子载波选择方法。相同的动作, 某个子载波上的 CSI 数据聚类生成多个簇, 则说明 CSI 存在多种变化模式数据间差异较大, 数据采集过程中该子载波易受环境干扰。因此对于每个动作, 该文选取所有子载波聚类后生成簇较少的子载波作为有效子载波。

在训练特征的选择上, CARM^[7] 使用离散小波变换从不同时间尺度的不同活动中提取频率分量作为特征。WiSee^[8] 从手势动作中提取对应的多普勒频移特征来识别手势。两种方法均需手动设计特征。该文提出使用 GASF^[9] 方法将 CSI 转换成图像从而利用 CNN 强大的特征提取能力自动提取特征。

由于实验对象的运动速度以及采样频率的差异, 相同动作所收集到的 CSI 数据长度可能不同, 但神经网络输入数据的长度需要保持一致。所以对收集到的 CSI 数据进行截取, 以保证数据长度相同, 并且截取到的部分需要包含动作发生的整个过程。WiFinger^[10] 根据统计特征来检测手势动作的起始点和结束点。文献[11]直接采用了人工截取的方式。上述方法需要大量的人力与计算资源来截取数据。文中的 CRNN 网络使用 CTC^[12] 作为损失函数, 能够使网络自动对齐输入数据中发生动作的部分, 无需对数据进行截取。

深度学习网络需要大量的数据来进行训练从而防止模型过拟合, 但是人工采集大量的数据往往是不容易的。因此, 该文通过添加噪音、缩放、滑动平均等方法增加数据量, 从而提高模型的鲁棒性。

2 信道状态信息

CSI 代表了信号在传输过程中所产生的时延、幅度衰减以及相位偏移等变化。换句话说, CSI 表征了附近环境的无线特性。假设发送端信号为 $X(f, t)$, 接收端信号为 $Y(f, t)$, 那么有^[1]:

$$Y(f, t) = H(f, t) \cdot X(f, t) + n \quad (1)$$

其中, $H(f, t)$ 为信道频率响应矩阵, CSI 就是对 $H(f, t)$ 的估计。 n 为高斯白噪声。对于单个子载波, CSI 的形式如下:

$$H_i = |H_i| e^{j \cdot \sin \theta} \quad (2)$$

其中, $|H_i|$ 和 θ 分别表示 CSI 的幅度和相位。由于商

用网卡接收到的两个连续的 CSI 间相位差可能很大, 因此该文只使用 CSI 的振幅进行动作识别。

3 方法设计

图 1 所示为方法流程, 由信号采集、数据处理、训练预测三个阶段组成。其中信号采集阶段将在第 3 章详细阐述。

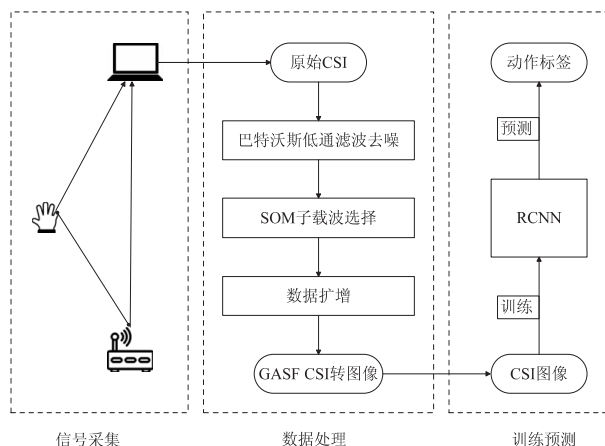


图 1 方法流程

3.1 数据预处理

3.1.1 滤波去噪

由于人体动作的频率较低以及环境中高频噪音存在, 所以原始 CSI 需要滤除高频分量, 这里使用常用的巴特沃斯低通滤波器进行滤波^[1]。巴特沃斯低通滤波器的增益 $G^2(\omega)$ 为:

$$G^2(\omega) = |H(j\omega)|^2 = \frac{G_0^2}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} \quad (3)$$

其中, n 表示滤波器的阶数, ω_c 表示截止频率即功率下降为 -3 分贝时的频率, G_0 是直流增益。频率低于 ω_c 的部分会以 G_0 的增益通过, 而频率高于 ω_c 的就会被抑制。由于手部动作频率范围在 0.3 Hz 到 4.5 Hz 之间^[13], 因此设置截止频率为 5 Hz, 考虑到滤波效果与计算成本滤波器阶数设置为 5。图 2 所示为滤波前后对比, 可以看出滤波后曲线变得平滑高频噪声被抑制。




图 2 低通滤波前后 CSI 幅值对比

3.1.2 子载波选择

SOM^[6] 是一种无监督聚类的神经网络, 通过学习自动对输入进行聚类, 且能保持数据的拓扑结构不变。SOM 由输入和输出 (竞争两层) 构成, 采用竞争学习


的方式进行训练。首先将网络权重初始化,接着每个输入的样本遍历竞争层中的每个节点,计算两者之间的距离(通常为欧式距离),选取距离最小的节点作为获胜节点。

接着用随机梯度下降法更新获胜节点及其邻近节点的权重向量使它们向输入向量移动。输出节点 v 的权值更新公式为:

$$W_v(s+1) = W_v(s) + \theta(u, v, s) \cdot \alpha(s) \cdot (D(t) - W_v(s)) \quad (4)$$

其中, W_v 为权重向量, s 为迭代次数, $D(t)$ 为当前输入向量, u 为获胜节点, $\theta(u, v, s)$ 为 s 下给出 u 和 v 之间距离的邻近函数,用来确定获胜节点对其近邻节点的影响强弱。 $\alpha(s)$ 是一个单调递减的学习率。对每个输入向量这个过程会重复进行直到达到提前设置的循环次数 λ 。

该文设置输出层 SOM 神经元的数量为 3 进行聚类,图 3 所示为上下挥手时不同的四个子载波上的 CSI 聚类后的结果。样本数量为 50,可以看到子载波 3 聚类后只有一个簇,说明数据内在的分布较一致,受环境干扰较小。子载波 1、2、4 聚类后均生成多个簇,说明同一个子载波上的 CSI 间差异较大。因此对于上下挥手动作,选择提取子载波 3 上的 CSI 作为训练数据。



(a)子载波1聚类结果 (b)子载波2聚类结果 (c)子载波3聚类结果 (d)子载波4聚类结果

图3 上下挥手的四个子载波聚类结果

3.1.3 数据扩增

相较传统模型,深度学习的参数非常多,故有很强的拟合能力,从而也就需要更多的数据来避免过拟合的发生。但收集和标记大量的数据是耗时耗力的。通过现有的样本进行数据扩增创建新的样本,能够利用有限的样本有效地提高分类性能^[14]。该文采取了多种数据扩增方法包括:

(a)添加噪声,CSI序列加上高斯随机噪声序列 n 。

(b)缩放,CSI序列乘以缩放系数 s 。

(c)降采样,设置降采样因子 m ,保留 CSI 序列中间隔为 m 的采样点,其余采样点舍弃。

(d)滑动平均,采样点 i 的值由滑动窗口 w 内 CSI 数据的平均值代替。

(e)截取,使用长度为 l 的窗口在 CSI 序列上截取数据。

图 4 所示为使用不同方法所产生的新样本。可以看到一个样本能生成多个虚拟样本。且所生成的样本保留了 CSI 的变化模式。




图4 应用不同数据扩增方法得到的新样本

3.1.4 CSI 转换为图像

CNN 能够自动高效地从图像中提取特征。因此该文没有手工设计特征,而是使用 GASF^[9]方法将接收到的 CSI 编码为图像,使用 CNN 提取特征。设 $X = \{x_1, x_2, \dots, x_n\}$ 为滤波后的 CSI 序列,先通过

$$\tilde{x}_i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (5)$$

将 X 归一化,此时有 $\tilde{x}_i \in [0, 1]$, $\forall 1 \leq i \leq n$ 。

令 $\varphi_i = \arccos(\tilde{x}_i)$ 将重缩放后的时间序列转换成极坐标系,定义矩阵 GASF 为:

$$\text{GASF} = [\cos(\varphi_i + \varphi_j)]_{1 \leq i, j \leq n} \quad (6)$$

于是有:

$$\text{GASF} = [\cos(\varphi_i) \cdot \cos(\varphi_j) - \sin(\varphi_i) \cdot \sin(\varphi_j)]_{n \times n} \quad (7)$$

令 $\tilde{X} = (\cos(\varphi_1), \dots, \cos(\varphi_n))^T$, 可以得到:

$$\text{GASF} = \tilde{X} \cdot \tilde{X}^T - \sqrt{I - \tilde{X}^2} \cdot \sqrt{I - (\tilde{X}^T)^2} \quad (8)$$

图 5 所示为 6 种手势动作的 CSI,通过转换得到的 GASF 图像,可以看到不同的动作生成的图像有不同的纹理特征。




图5 不同手势的 CSI 转化得到的图像

3.2 训练

文中的 CRNN 由 CNN、RNN 构成,训练时使用 CTC 作为损失函数。网络结构如图 6 所示。

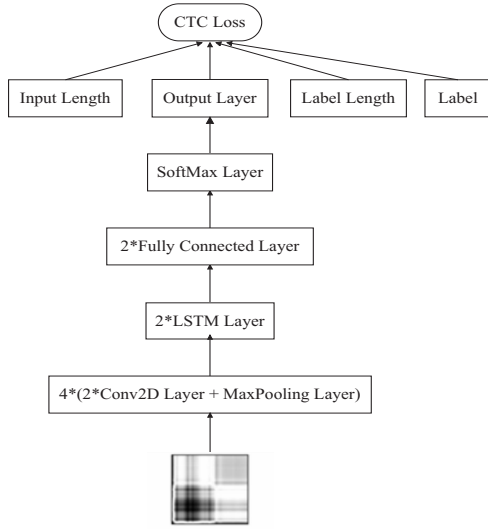


图 6 网络结构

3.2.1 卷积神经网络

首先使用卷积神经网络^[15]来对图像提取特征,卷积网络部分由四个卷积模块组成,每个卷积模块由两个二维卷积层加上一个池化层构成。卷积层 l 的卷积计算公式为:

$$z_{i,j}^l = \sum_{m=0}^H \sum_{n=0}^W f_{m,n} x_{i+m,j+n}^l \quad (9)$$

其中, $x_{i+m,j+n}^l$ 是输入张量, $f_{m,n}$ 是维度为 $H \times W$ 的卷积核, $z_{i,j}^l$ 为该卷积层的输出张量, i, j 是张量的坐标值, m, n 是卷积核的坐标值。该文所使用卷积核大小为 3×3 , 并进行了零填充以保持卷积后的输出特征图与输入的分辨率相同。

池卷积层的池化操作能够减少模型的计算量和参数个数,防止过拟合。该文使用了最大池化,其公式为:

$$f_{\text{pool}} = \text{Max}(s_{i,j}, s_{i+l,j}, s_{i,j+1}, s_{i+l,j+1}) \quad (10)$$

其中, f_{pool} 是池化后的结果, $s_{i,j}$ 是特征图张量上位置 (i, j) 上的元素。该文使用的池化核大小为 2×2 。

3.2.2 长短期记忆网络

由于 CSI 是时间序列数据,所以接下来使用两个长短期记忆(long short-term memory, LSTM)层对 CSI 序列时间上的变化进行建模。LSTM^[16]是一种拥有三个“门”的特殊网络结构,包括遗忘门、输入门、输出门。输入门选择保留的信息,遗忘门选择被遗忘的信息,输出门决定哪些状态信息需要输出,如公式(11)所示。

$$\begin{pmatrix} i \\ f \\ o \\ g \end{pmatrix} = \begin{pmatrix} \sigma \\ \sigma \\ \sigma \\ \varphi \end{pmatrix} W \begin{pmatrix} h_{t-1} \\ x_t \end{pmatrix} \quad (11)$$

其中, i, f, o, g 分别表示输入门、遗忘门、输出门的输出以及输入的单元状态。 σ, φ 分别为 sigmoid、tanh 激活函数, h_{t-1}, x_t 分别为上一时刻的输出和当前时刻的输入。当前时刻的单元状态 c_t 为:

$$c_t = f \odot c_{t-1} + i \odot g \quad (12)$$

其中, c_{t-1} 为上一时刻的单元状态, \odot 表示元素乘。由当前时刻的输出门输出 o_t 和单元状态可得当前时刻的输出 h_t 为:

$$h_t = o_t \odot \tanh(c_t) \quad (13)$$

3.2.3 CTC 损失函数

由于 CSI 序列长度不一致,那么训练前每个样本都需要标记出发生动作的片段在整个 CSI 序列中的位置,从而截取得到长度一致的输入数据,该文使用 CTC^[12]损失函数不需要对数据进行截取。LSTM 提取完特征后由两个全连接层和 Softmax 层进行分类,分类结果作为 CTC 损失函数的输入,此外还需要提供输入长度、标签、标签长度。

CTC 算法的不同之处在于引入了一个空白($_$)标签表示无动作发生。设给定长度为 T 的输入序列 $X = (x_1, x_2, \dots, x_T)$, 神经网络对应的输出序列为 $Y = (y_1, y_2, \dots, y_{T'})$, 其中 T' 为神经网络提取到的特征图的长度, $y_i = (y_i^1, y_i^2, \dots, y_i^K)$ 为第 i 帧的条件概率分布, K 为动作标签和空白标签的个数。CTC 算法的输出序列路径为 π 的概率为:

$$P(\pi | X) = \prod_{t=1}^{T'} P(\pi_t | t, X) \quad (14)$$

用 B 表示映射函数,消除重复的标签和空白标签,例如:

$$B(_, a, a, b, b, c, c, _) = (a, b, c) \quad (15)$$

因此输出序列路径为 μ 的概率可以表示为经过映射后为 μ 的所有 π 的概率之和,即:

$$P(\mu | X) = \sum_{\pi \in B^{-1}} P(\pi | X) \quad (16)$$

CTC 损失函数定义如下:

$$\text{CTC}(X) = -\log P(\mu | X) \quad (17)$$

CTC 算法通过最大路径解码所解得的概率最大的输出序列路径为:

$$\mu \approx B(\pi^*), \pi^* = \underset{\pi}{\text{argmax}} P(\pi | X) \quad (18)$$

其中, π^* 为 T 帧输入序列的后验概率最大的 CTC 输出序列路径。

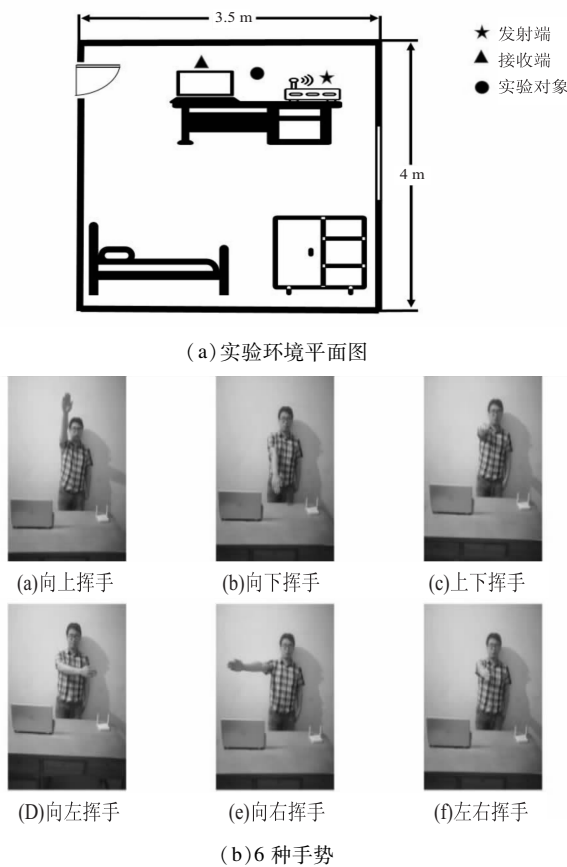
4 实验设计

4.1 数据采集

将一台装有英特尔 5300 网卡,系统内核版本为 4.1.10 的 HP Pavilion15 笔记本电脑作为接收端接收信号。一个支持 802.11n 协议的 MERCURY

MW305R 路由器为发射端发送信号。使用 Halperin^[17]发布的 CSI 工具包来修改网卡驱动。设置路由器的工作频率为 2.4 G, 发包频率为 20 Hz。由于发射端有两根天线, 接收端有三根天线, 每个天线对上有 30 个子载波。因此接收到的 CSI 数据为 $2 * 3 * 30$ 的复数矩阵。

图 7(a)所示为实验环境。实验对象站在笔记本和路由器之间的桌子前做如图 7(b)所示的 6 种手势动作, 每个手势采集 50 组数据, 共计 300 组数据。使用 240 组数据训练模型, 剩余 60 组数据对训练好的模型进行测试。



(a) 实验环境平面图

(a) 向上挥手

(b) 向下挥手

(c) 上下挥手

(d) 向左挥手

(e) 向右挥手

(f) 左右挥手

(b) 6 种手势

图 7 数据采集

4.2 对比分析

该文做了一系列对照实验来对比分析提出的方法的有效性。

4.2.1 不同的子载波选择方法

为了验证提出的基于 SOM 聚类的子载波选择方法的有效性, 对照实验使用了 WiFall^[4]的所有子载波求平均、LBR^[5]的选择 CSI 方差第二大的子载波进行对比。仅改变子载波选择方法, 其他步骤相同, 实验结果如表 1 所示。

结果表明直接对所有子载波上的 CSI 求平均, 结果准确率较低, 原因可能是不同的子载波对动作和环境的敏感度不同, 直接求平均值将各种环境因素的影

响叠加到一起, 使得 CSI 中的有效信息被掩盖。选取方差第二大的子载波, 准确率虽然有所提高, 但是由于 CSI 易受环境噪音影响, 较大的方差可能是由于环境噪音变化引起的, 而且不能保证相同动作的 CSI 变化模式的一致性。通过聚类选择子载波能够保证相同动作的 CSI 数据内部的一致性, 不会出现异常数据, 准确率较高。

表 1 不同的子载波选择方法结果对比

方法	准确率/%
30 组子载波上的 CSI 求平均	75
选取方差第二大的子载波	78.3
基于 SOM 聚类的子载波选择	93.3

4.2.2 不同的网络结构

将 SignFi^[18]使用的 CNN 及文献[19]所使用的 LSTM 作为对照, 并把使用交叉熵损失函数的 CRNN 也作为一种不同的网络进行对比, 结果如表 2 所示。

表 2 不同的网络结构结果对比

方法	准确率/%
CNN	86.7
LSTM	50
使用交叉熵损失函数的 CRNN	64.9
使用 CTC 损失函数的 CRNN	93.3

可以看到仅使用 LSTM 由于模型参数数量较少因此拟合能力较弱。使用 CNN 能够达到相对较高的准确率。相较于仅使用 CNN 或 LSTM, 同时使用 CNN、LSTM 能综合利用两种网络结构的优势, 准确率较高。使用 CTC 损失函数不仅不需要对 CSI 进行截取, 而且能够有效地识别发生动作的 CSI 序列片段, 从而提高模型的分类准确率。

4.2.3 不同数量的训练数据

基于学习的识别方法要求有大量的数据训练模型, 本小节通过对比实验探究不同数量的训练数据对于识别准确率的影响。分别使用 120 组数据, 240 组数据, 与文中使用的 240 组数据并对数据扩增的方法作对比, 结果如表 3 所示。

表 3 不同数量的训练数据结果对比

方法	准确率/%
120 组训练数据	63.3
240 组训练数据	81.6
240 组训练数据并进行数据扩增	93.3

可以看到随着训练数据的增加模型的分类准确率也随之增加, 模型对训练数据的数量有较高的要求。虽然大规模采集数据是不容易的, 但是通过数据扩增的方法, 能够在原有数据的基础上增加数据的多样性, 有效提升模型的准确率。使得基于学习的方法也能够

以较低的数据成本达到较高的识别效果。

5 结束语

提出了一种基于 SOM 聚类的子载波选择方法,并将 CSI 数据序列转换为图像,通过 CNN、LSTM 构成的网络使用 CTC 损失函数进行训练分类。在数据预处理和模型训练中,采用聚类 and 深度学习的方法代替传统的基于手工设计特征的方法,并利用现有样本进行了数据扩增。实验结果表明,该方法能够在数据量较小的情况下达到较高的识别准确率,且无需手工设计特征。下一步将会致力于研究提高模型的泛化能力。

参考文献:

- [1] 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.
- [2] MANTYJARVI J, HIMBERG J, SEPPANEN T. Recognizing human motion with multiple acceleration sensors[C]//2001 IEEE international conference on systems, man and cybernetics. e-Systems and e-Man for cybernetics in cyberspace (Cat. No. 01CH37236). Tucson, AZ, USA; IEEE, 2001:747-752.
- [3] 胡 琼,秦 磊,黄庆明. 基于视觉的人体动作识别综述[J]. 计算机学报,2013,36(12):2512-2524.
- [4] WANG Yuxi, WU Kaishun, NI L. WiFall: device-free fall detection by wireless networks[J]. IEEE Transactions on Mobile Computing, 2017, 16(2):581-594.
- [5] 姚青桦,崔 然. 一种基于 CSI 的轻量级行为识别方法[J]. 计算机应用研究,2018,35(11):3397-3399.
- [6] TERMINI S. T. Kohonen, self-organizing maps[J]. Rendiconti del Circolo Matematico di Palermo, 1995, 44(3):506.
- [7] WANG Wei, LIU A X, SHAHZAD M, et al. Understanding and modeling of wifi signal based human activity recognition[C]//Proceedings of the 21st annual international conference on mobile computing and networking. Paris, France; ACM, 2015:65-76.
- [8] PU Qifan, JIANG Siyu, GOLLAKOTA S. Whole-home gesture recognition using wireless signals[J]. ACM SIGCOMM Computer Communication Review, 2013, 43(4):485-486.
- [9] WANG Zhiguang, OATES T. Imaging time-series to improve classification and imputation[C]//Proc of the 24th international conference on artificial intelligence. Palo Alto, CA; AAAI Press, 2015:3939-3945.
- [10] LI Hong, YANG Wei, WANG Jianxin, et al. WiFinger: talk to your smart devices with finger-grained gesture[C]//Proc of the 2016 ACM international joint conference on pervasive and ubiquitous computing. Heidelberg, Germany; ACM, 2016:250-261.
- [11] WANG Fei, FENG Jianwei, ZHAO Yinliang, et al. Joint activity recognition and indoor localization with WiFi fingerprints[J]. IEEE Access, 2019, 7:80058-80068.
- [12] GRAVES A, FERNÁNDEZ S, GOMEZ F. Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks[C]//Proc of the 23rd international conference on machine learning. Pittsburgh, Pennsylvania, USA; ACM, 2006:369-376.
- [13] XIONG Yingen, QUEK F. Hand motion gesture frequency properties and multimodal discourse analysis[J]. International Journal of Computer Vision, 2006, 69(3):353-371.
- [14] UM T, PFISTER F, PICHLER D C, et al. Data augmentation of wearable sensor data for parkinson's disease monitoring using convolutional neural networks[C]//Proc of the 19th ACM international conference on multimodal interaction. Glasgow, UK; ACM, 2017:216-220.
- [15] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proc of the IEEE, 1998, 86(11):2278-2324.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [17] HALPERIN D, HU W, SHETH A, et al. Tool release: gathering 802.11n traces with channel state information[J]. Computer Communication Review, 2011, 41(1):53.
- [18] MA Yongsun, ZHOU Gang, WANG Shuangquan, et al. Sign-fi: sign language recognition using wifi[J]. Proc of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2018, 2(1):1-21.
- [19] 刘佳慧,王昱洁,雷 艺. 基于 LSTM 的 CSI 手势识别方法[J]. 计算机科学, 2019, 46(11A):283-288.