

基于 WiFi 信号的老年人家居行为识别算法

刘苗苗 樊春玲

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 针对老年人家居行为识别中的隐私保护、跌倒检测和识别率低的问题,本文提出了一种新的基于 WiFi 信号的人体行为识别算法。首先,在模拟家居环境中自主采集了 10 种老年人日常行为(喝水、跌倒、坐-躺下等);然后对提取到的 WiFi 信道状态信息用巴特沃斯滤波器降噪,并使用主成分分析方法数据降维;最后将处理后有清晰特征的 CSI 信号输入到基于注意力的双向长短时记忆模型用于行为分类,高效的双向结构和注意力机制不仅产生了信息更丰富的特征,还提高了行为识别的泛化性能。实验结果表明,与一些基准方法相比,本文算法在公共数据集和自主采集的数据集上都能实现对所有行为的最佳识别性能,准确率分别为 98% 和 96%。

关键词: 信道状态信息;人体行为识别;双向长短时记忆;注意力机制

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.60

Human activity recognition algorithm for elderly home based on WiFi signal

Liu Miaomiao Fan Chunling

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Aiming at the problems of privacy protection, fall detection and low recognition rate in home behavior recognition of the elderly, a new human behavior recognition algorithm based on WiFi signal is proposed in this paper. Firstly, 10 kinds of daily life behaviors of the elderly (drinking water, falling, sitting down, etc.) were collected in the simulated home environment; Then, the extracted WiFi channel state information is denoised by Butterworth filter, and the dimension is reduced by principal component analysis; Finally, the processed CSI signals with clear features are input into the attention based bidirectional long short-term memory model for behavior classification. The efficient bidirectional structure and attention mechanism not only produce more informative features, but also improve the generalization performance of behavior recognition; Experimental results show that, compared with some benchmark methods, the proposed algorithm can achieve the best recognition performance for all activities on both public data sets and self-collected data sets, and the accuracy rates are 98% and 96% respectively.

Keywords: channel state information; human activity recognition; bidirectional long short-term memory; attention mechanism

0 引言

近年来随着人口老龄化的加快,独居老年人的人身安全问题亟待解决,特别是老年人在如厕、洗澡时稍有不慎摔倒便可能导致骨折、瘫痪等事故发生,因此,老年人日常行为的检测需求日益迫切^[1]。目前常用的人体行为识别技术有计算机视觉^[2]、红外技术^[3]、专用传感器技术^[4]、WiFi 感知技术^[5]等。相比其他技术而言,基于 WiFi 信号的识别技术具有独特优势。首先,它不需要额外设备,仅通过人体反射的信号就能检测活动。另一方面,相比摄像头来说,它拥

有更好的视野和隐私保护。此外,基于 WiFi 的人体行为识别系统不仅造价便宜、计算量更少,而且还不受墙壁、家具和门的限制^[6]。因此,本文主要研究利用 WiFi 信号进行人体活动识别。

目前主要的人体行为识别算法有两大类:机器学习算法和深度学习算法。传统的机器学习算法通常是手动提取鉴别特征,比如支持向量机^[7](support vector machine, SVM)、K-最近邻^[8](K-nearest neighbor, K-NN)、隐马尔可夫模型^[9]、决策树^[10]等。但是这些手工提取的浅层次特征只能用于识别站立、行走这样的低级活动,很难识别出跌倒、喝水

等更为复杂和高级的人体行为^[11]。而且由于特征提取和识别部分没有联合优化,不能保证泛化能力。深度学习算法可以从原始传感器数据中学习特征,实现特征的自动提取,比如卷积神经网络^[12]、稀疏自动编码器(sparse autoencoder, SAE)^[13]、长短时记忆(long short time memory, LSTM)等。其中,LSTM可以在特征学习过程中自动学习代表性特征并对时间信息进行编码,在动作视频识别^[14]、基于可穿戴传感器的行为分类上有较高的准确率^[15]。传统的 LSTM 只能在一个方向(即正向)上处理连续的信道状态信息(channel state information,CSI)信号,忽略了未来的上下文信息。研究人员提出了先进的双向长短时记忆(bidirectional-LSTM, BiLSTM)方法,可以在前向和后向两个方向上处理连续的 CSI 信号,从而产生信息更为丰富的特征^[16]。注意力机制能够对输入的特征重新分配权重,在识别过程中聚焦感兴趣的区域,同时模糊其他区域,使模型做出更加准确的判断,提高人体行为识别的泛化性能^[17]。

因此,为了进一步提高人体行为识别分类性能,同时又

不依赖手工特征提取,本文提出了一个新的基于 WiFi 信号的人体行为识别算法框架。实验结果表明,基于注意力的双向长短时记忆(attention based bi-directional long short-term memory, At-BiLSTM)算法在公共数据集和自制数据集中都表现出了极好的鲁棒性和较高的识别率。

1 人体行为识别算法

1.1 算法框架结构

本文构建了基于 WiFi 信号的人体行为识别算法,总体架构如图 1 所示,主要包括 WiFi 感知和信号传播、数据采集、数据预处理、特征提取和分类等 4 个部分。首先在模拟家居场景中收集 CSI 原始数据,然后对数据进行预处理,使用主成分分析 PCA 方法^[18]降维和巴特沃斯滤波器降噪,得到包含少量噪声和标记了行为的 CSI 数据样本,再构建了引入注意力机制的双向长短时记忆 At-BiLSTM 模型,完成特征提取和行为分类。最后,在训练集上进行模型训练和调参,并使用测试集进行结果分析。

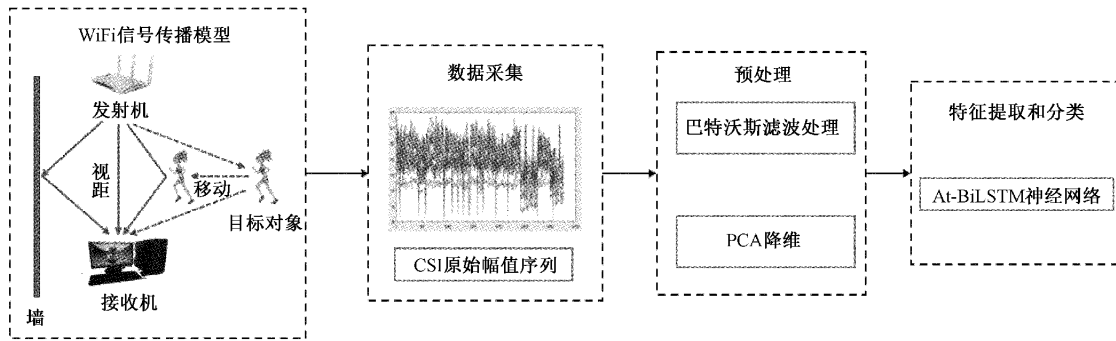


图 1 算法流程

1.2 WiFi 感知和信号传播

当信号在传播过程中遇到人体活动,会发生反射、折射、吸收等现象,对信号的正常传播产生扰动,因此通过监测 WiFi 信号的变化来识别人类活动是可行的。WiFi 感知和信号传播(如图 1)可以将其建模为具有正交频分复用技术的多输入多输出,其主要反映了 CSI 信号子载波的幅度和相位信息。在频域中, \mathbf{T} 和 \mathbf{R} 分别表示发射信号向量和接收信号向量; H 代表信道的频率响应; \mathbf{N} 为高斯白噪声向量,WiFi CSI 信号模型可表示为:

$$\mathbf{T} = \mathbf{H}\mathbf{R} + \mathbf{N} \quad (1)$$

其信道频率响应 H 还可以表示为:

$$H = h_{mnk} \quad (2)$$

其中, $m \in [1, N_T]$, N_T 为发射天线的数目; $n \in [1, N_R]$; N_R 为接收天线的数目; k 为子载波, $k \in [1, 30]$; $h_{N_T N_R k}$ 表示第 k 个子载波的值。解析出信号的幅值 $h_{N_T N_R k}$ 和相位 $\angle h_{N_T N_R k}$, 公式为:

$$h_{N_T N_R k} = |h_{N_T N_R k}| e^{j \sin \angle h_{N_T N_R k}} \quad (3)$$

1.3 数据预处理

从设备获取的原始 CSI 信号含有噪声且不平稳,因此

首先要对采集的数据进行预处理,降维除噪,得到清晰稳定的信号。在数据预处理的过程中,采用低通巴特沃斯滤波器和 PCA 方法对采集的 WiFi CSI 信号进行降噪和降维处理。

1) 巴特沃斯低通滤波器降噪

人体行为的频率一般位于低频区间,但是受各种噪声影响,采集的信号包含很多高频分量和直流分量。本文采用巴特沃斯低通滤波器抑制低频或直流分量,滤波器可用振幅的平方对频率的公式表示。

$$|H(\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^{2\gamma}} \quad (4)$$

其中, γ 为滤波器的阶数; ω_c 为截止频率。

2) PCA 方法降维

PCA 在该阶段用于去除 30 个子载波之间的相关信息并降低特征维数。具体的实现如下:设 CSI 矩阵为: $\mathbf{H} = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_1]^T$, 其中 \mathbf{H}_i 为任一子载波的列向量。首先消除静态分量,对所有数据样本点求均值得到均值列向量 $\bar{\mathbf{H}}$, 从 \mathbf{H} 的每一列减去 $\bar{\mathbf{H}}$, 得到一个居中的矩阵 \mathbf{H}_s 。然

后,计算协方差矩阵 \mathbf{H}_c , 采用奇异值分解法求得特征值和特征向量。选取前 l 个最大的特征值对应的特征向量构成新矩阵 \mathbf{H}_w 。最后利用 \mathbf{H} 与 \mathbf{H}_w 相乘,只保留包含绝大部分方差的维度特征,忽略方差几乎为 0 的特征维度,实现对数据的降维处理。具体公式如下:

$$\overline{\mathbf{H}}_i = \frac{1}{n} \sum_{i=1}^n \mathbf{H}_i \quad (5)$$

$$\mathbf{H}_s = \sum_{i=1}^n \mathbf{H}_i - \overline{\mathbf{H}} \quad (6)$$

$$\mathbf{H}_c = \frac{1}{n} \mathbf{H}_s \mathbf{H}_s^T \quad (7)$$

1.4 特征提取和分类

本文提出了一个基于 WiFi 信号的 At-BiLSTM 人体识别算法框架用于特征提取和分类,具体过程如图 2 所示。

1) BiLSTM

首先,将预处理后的 CSI 信号(30×10 的二维矩阵)送入到 BiLSTM 用于两个方向的自动特征学习。BiLSTM 由前向层和后向层组成,如图 3 所示。令前向层和后向层的隐藏状态分别为 h_{Rt} 和 h_{Lt} ,其中 R 表示向前处理信息, L 表示向后处理信息^[19]。则 BiLSTM 在时间步长 t 处的完全隐藏状态 h_t 为两者隐藏状态的串联,公式为:




图 2 At-BiLSTM 算法框架

$$h_t = h_{Rt} \oplus h_{Lt} \quad (8)$$

与传统的 LSTM 算法相比,BiLSTM 算法能够同时考虑过去和未来的信息,从而产生信息更丰富的特征。

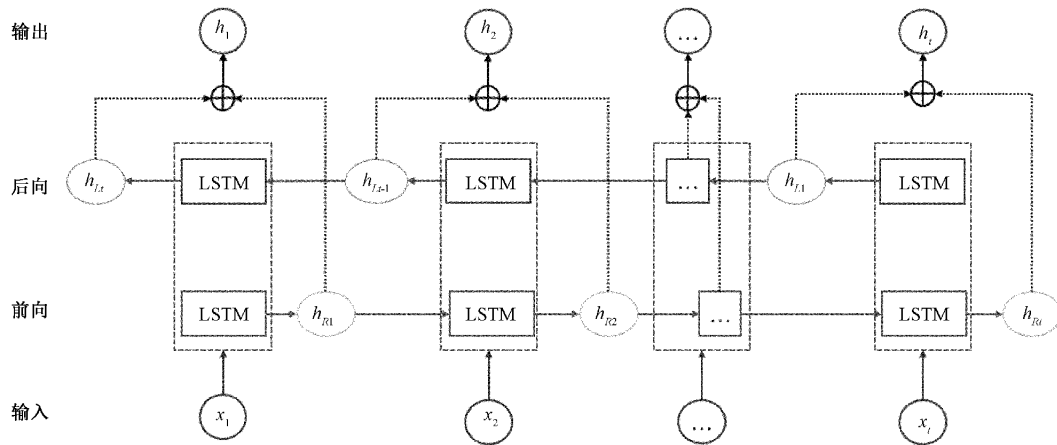


图 3 BiLSTM 网络结构

图 3 中 LSTM 网络是通过控制遗忘门、输入门、输出门 3 个门结构来实现信息的输入输出以及遗忘和保留哪些信息,如图 4 所示。

图 4 中: W_f, W_i, W_o, W_c 和 b^f, b^i, b^o, b^c 分别为控制门之间的权重和偏差量; f_t 和 O_t 分别是遗忘门和输出门; \tanh 是双曲正切激活函数; σ 是 sigmoid 型函数; x_t 代表输入的特征向量; h_t 和 h_{t-1} 分别为当前特征向量的输出和上一特征向量的输出; i_t 作为输入门的状态更新率,表示需要更新的信息; \tilde{C}_t 为状态更新向量,指新输入带来的信息; C_t 为更新后的单元。具体运算过程为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = s(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (11)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (12)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (13)$$

$$h_t = o_t * \tanh(C_t) \quad (14)$$

2) 注意力机制

注意力模型没有可用的先验信息,只能使用从 BiLSTM 中学习的特征作为输入。由于 BiLSTM 网络可以学习时间相关性的特征,不同的特征和时间步长可能对最终的活动识别有不同的贡献和影响。因此,本文利用注意力模型自动学习特征和时间步长的能力,为更重要的

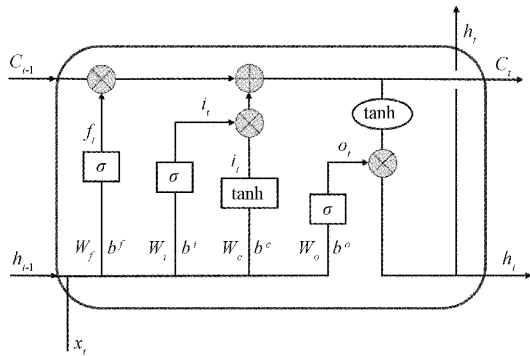


图 4 LSTM 的网络结构

特征和时间步长分配更大的权重,以提高系统的识别性能。注意力模型被设计为一个 softmax 回归层,其输出是




图 5 注意力模型

3)合并矩阵

从注意力模型输出的矩阵会遗失一些权重为 0 的信息,但是这些信息仍然是有用的。因此,引入了残差网络,该网络使用旁路 shortcut(捷径),作用是特征重用,使特征矩阵隔层相加,其中从 BiLSTM 中输出的矩阵要和从注意力模块得到的矩阵形状相同。将从 BiLSTM 中学习到的特征矩阵与注意力矩阵拼接,得到带有注意力的修改特征矩阵(30×512 的二维矩阵)。此时,完成特征提取部分。

4)展平层

展平层用来将多维的输入一维化,常用于卷积层到全连接层的过渡。本文利用展平层将特征矩阵压平为最终分类的特征向量。

5)全连接层和 Softmax 层

将经过多次卷积后高度抽象化的特征进行整合,然后输出到 Softmax 层中进行归一化。Softmax 层在多分类过程中,能将多个输入映射到 0~1 区间内,并利用最终的特征向量实现行为识别。

2 实验过程及结果

2.1 实验环境

本文模拟了家居测试环境进行算法的性能分析,结构如图 6 所示。测试环境面积大小为 13 m×8 m,该房间摆放了沙发、电视、桌子和柜子等家具,环境比较复杂。实验中发射机与接收机之间相距 3 m,离地高度为 1 m。发射设备为有 4 根天线的 WiFi 路由器,型号是 TP-LINK-WiFi6-AX3000。接收设备为配有 Intel 5300 网卡的台式电脑,电

每个特征和时间步长的标准化权重^[20]。注意力模型如图 5 所示。从 BiLSTM 网络中输出的特征向量传送到注意力机制模型中,经过注意力模型中的隐藏层得到初始状态向量 h_i ,然后用 r_i 来评估每个特征向量的重要性。在获得每个特征向量的分数后,使用 softmax 函数对其进行归一化。最后将特征向量及其归一化分数相乘得到注意力模型的输出特征 Y 。具体计算公式如下:

$$r_i = \tanh(W_T h_i + b) \tag{15}$$

$$\alpha_i = \text{softmax}(r_i) = \frac{\exp(r_i)}{\sum_i \exp(r_i)} \tag{16}$$

$$Y = \sum_{i=1}^n \alpha_i \times h_i \tag{17}$$

式中: W_T 和 b 分别表示权重向量和偏差,权重系数 α_i 表示初始输入状态向量在最终输出的状态向量中所占的比重。

脑版本是 Ubuntu 14.04.1。还安装了 Halperin 等开发的 CSI-Tool 工具,以收集无线卡报告的 CSI 数据包。

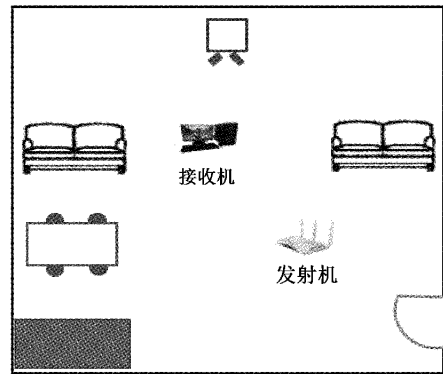


图 6 模拟家居环境结构图

2.2 实验数据集

1)自制数据集

本文自主采集了老年人居室生活中常见的 10 种行为:站立、行走、慢跑、喝水、打扫、跌倒、站-坐、站-蹲、站-弯腰、坐-躺下。测试数据邀请 10 位志愿者(5 男 5 女)测试这 10 种行为,每种行为 30 组,每次采集一个 5 s 左右的 WiFi 信号序列作为活动的一个样本,测试行为前后均有一段静止时间。具体操作如下,基于手动的方式收集活动数据需要一名操作员和一名志愿者在一个房间内。发射器每秒发送 60 个数据包,开始采集前先观察实时 WiFi 信号变化,检测采集的设备是否存在问题,然后再采集活动数据。志愿者位于发射器和接收器的中间,操作员靠近接收器运

行收集的代码。志愿者每完成 30 次活动后,开始做下一次活动。一旦志愿者感到疲劳,测试会暂停并让他/她放松,以确保收集活动数据的质量。

2) 公共数据集 WIAR

实验还在公共数据集 WIAR 上进行了测试,WIAR 数据集采集了 10 名志愿者(5 男 5 女),在 3 个环境(空房间、会议室、办公室)做 16 种动作的数据,每项活动 30 次,数据采样频率为 30 Hz。在此次实验中,考虑到会议室与家居环境相似的复杂性,因此选择会议室环境下 6 名志愿者的 6 种行为(行走、弯腰、蹲下、坐下、打电话、喝水)。

2.3 实验参数

实验数据集采集完成后,预处理选择频率为 50 Hz 的八阶低通巴特沃斯滤波器和 PCA 将 CSI 信号矩阵维数从 30×120 降到 30×10 。然后将处理后的数据输入到 At-BiLSTM 模型中用于分类识别。实验参数设置如表 1 所示,仿真实验时所有模型的初始化参数都使用相同配置。

表 1 实验参数设置

| 参数 | 设置 |
|----------------|-----------------|
| BiLSTM 层权系数初始化 | 正交法 |
| 卷积层权系数初始化 | Kaiming 法 |
| 全连接层权系数初始化 | Kaiming 法 |
| 损失函数 | 交叉熵 |
| 初始学习率 | 0.000 5 |
| 样本序列大小 | 120×30 |
| 训练集样本数 | 7 024 |
| 测试集样本数 | 1 756 |
| 训练轮数 | 100 |
| 优化器 | Adam 优化器 |
| 批次大小 | 64 |

卷积层和全连接层权系数初始化都采用 Kaiming 法,有利于加快模型的收敛速度。使用 Adam 优化器优化模型参数^[21],它可以有效地计算优化过程中每个参数的自适应学习率,收敛速度快,对内存需求小,并且在模型训练过程中可以不使用验证集。

2.4 实验结果与分析

实验用五折交叉验证法进行评估,具体步骤是先将所有数据随机分成 5 份,然后选择一组数据进行测试剩下的用于训练,得到 5 次结果,最终的识别率是 5 次的平均值^[22]。本文算法在公共数据集和自制数据集分类情况的混淆矩阵分别如图 7、8 所示。2 个混淆矩阵分别为 6 行 6 列和 10 行 10 列。横轴为预测标签,纵轴为真实标签。对角线的格子里的数字代表模型对某一行为正确分类的准确率。每个动作对应的那行格子(对角线格子除外)代表模型识别成其它行为的错误率。

由图 7 可以看出,本文算法在公共数据集 6 种行为的识别率较高,均在 96% 以上,而且“行走”、“弯腰”、“打电话”这 3 种行为的识别率达到 98% 以上。图 8 中,“慢跑”、“喝水”、“打扫”这 3 种行为的识别率都不低于 97%。尤其是对于老年人群体来说,本文所提出的算法在“跌倒”这种危险行为达到了 99% 的高识别率。从这两个混淆矩阵可以看出这些身体运动幅度较大的行为具有较好的识别性能,主要是因为 CSI 对大幅度的行为比较敏感,这些行为会对 CSI 信号的特征产生较大的影响。




图 7 本文算法在公共数据集上分类的混淆矩阵

其中“站-坐”、“坐-躺”的识别率较低 92%,分析其原因是“坐下”这种行为与“躺下”和“站起来”对 CSI 特性有类似的影响,特别在行为转换的过程中,采集信号很大概率受到干扰影响,从而容易混淆导致识别率下降。

综上,本文所提的 At-BiLSTM 算法在两个数据集上都表现出优秀的识别性能,因此,认为本文提出的基于 WiFi 的人体行为识别算法在老年人家居行为识别中是有效且稳健的。

为了验证本文所提算法的优越性,将其与一些常用的基于 CSI 的人类活动识别算法进行了比较。本文模型训练的环境配置为 Ubuntu16.04 64 位操作系统, GPU 为 NVIDIA GeForce RTX 2080Ti, 11 GB 显存;模型测试的环境配置为 Windows10 64 位操作系统, GPU 为 NVIDIA GeForce RTX 1050, 4 GB 显存。所有实验均使用 Pytorch 深度学习框架,使用 Python3.7.2 语言编写程序。实验中选择 SVM、K-NN、SAE、LSTM、BiLSTM 算法进行对比,不同算法在公共数据集和自制数据集的识别率分别如表 2、3 所示。从表中可以看出使用手工制作特征的浅层学习算法,即 SVM 和 K-NN 在两个数据集上的表现最差,“跌倒”行为的识别率甚至低于 70%。与 SVM 和 K-NN 相比,基于深度学习的 SAE 方法具有较为优越的性能,识别率提高了 5%~10%,这验证了 SAE 方法自动特征学习的有效性。考虑了特征学习序列数据时间依赖性的 LSTM




图 8 本文算法在自制数据集上分类的混淆矩阵

表 2 不同算法在公共数据集上的识别率对比

| | 行走 | 弯腰 | 蹲下 | 坐下 | 打电话 | 喝水 | 所有行为 |
|--------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| SVM | 0.88 | 0.76 | 0.80 | 0.85 | 0.70 | 0.84 | 0.81 |
| K-NN | 0.93 | 0.82 | 0.79 | 0.87 | 0.80 | 0.88 | 0.85 |
| SAE | 0.95 | 0.89 | 0.88 | 0.93 | 0.88 | 0.90 | 0.91 |
| LSTM | 0.97 | 0.89 | 0.94 | 0.94 | 0.92 | 0.91 | 0.93 |
| BiLSTM | 0.99 | 0.94 | 0.95 | 0.96 | 0.94 | 0.93 | 0.95 |
| 本文算法 | 1.00 | 0.98 | 0.97 | 0.97 | 0.99 | 0.96 | 0.98 |

表 3 不同算法在自制数据集上的识别率对比

| | 站立 | 行走 | 慢跑 | 喝水 | 打扫 | 跌倒 | 站-坐 | 站-蹲 | 站-弯腰 | 坐-躺 | 所有行为 |
|--------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| SVM | 0.86 | 0.80 | 0.85 | 0.78 | 0.80 | 0.65 | 0.75 | 0.81 | 0.83 | 0.75 | 0.79 |
| K-NN | 0.83 | 0.82 | 0.87 | 0.83 | 0.76 | 0.68 | 0.73 | 0.79 | 0.84 | 0.78 | 0.80 |
| SAE | 0.88 | 0.86 | 0.90 | 0.84 | 0.83 | 0.80 | 0.82 | 0.84 | 0.85 | 0.79 | 0.84 |
| LSTM | 0.92 | 0.88 | 0.93 | 0.89 | 0.89 | 0.93 | 0.88 | 0.90 | 0.91 | 0.87 | 0.90 |
| BiLSTM | 0.95 | 0.90 | 0.93 | 0.93 | 0.94 | 0.95 | 0.90 | 0.92 | 0.93 | 0.89 | 0.92 |
| 本文算法 | 0.99 | 0.96 | 0.98 | 0.98 | 0.97 | 0.99 | 0.92 | 0.94 | 0.95 | 0.92 | 0.96 |

算法实现了比 SAE 方法更好的性能,其中“跌倒”、“坐-躺”的识别率相比 SAE 提高了约 10%。相比单独的 LSTM 算法,学习两个方向代表性特征的 BiLSTM 算法的识别率在两个数据集上都提高了 2%。本文所提 At-BiLSTM 算法在两个数据集上能够实现对所有行为的最佳识别性能,在公共数据集和自制数据集上所有行为的平均识别率分别为 98%和 96%。与实验中其它方法相比,所有行为识别率提高了 5%~15%,尤其是“打电话”、“跌倒”等行为甚至达到了 99%的识别率。这充分说明由于本文算法在

BiLSTM 算法双向结构的基础上引入了注意力机制,为更重要的特征和时间步长分配了更重要的权重,抽取出来更加关键及重要的信息,使模型做出更加准确的判断,从而识别效果更好。

由表 4 不同算法在自制数据集上的识别时间可以发现,基于深度学习的方法训练时间远大于传统的机器学习算法。在所有基于深度学习的方法中,本文算法 At-BiLSTM 的训练时间最长。虽然这种方法的训练时间很长,但这种耗时的训练过程是离线的,只需要做一次。并

且所有方法的测试时间都很短,所有测试样本(1 756个)的拟定 At-BiLSTM 识别时间为 14.29 s,每个样本的识别

时间为 0.008 s,这一识别时间可以忽略不计。因此,本文算法可以用于基于 WiFi 的实时人体行为识别。

表 4 不同算法在自制数据集上的识别时间对比

| | SVM | K-NN | SAE | LSTM | BiLSTM | 本文算法 |
|---------|-------|-------|----------|----------|----------|----------|
| 训练时间(秒) | 12.31 | 13.62 | 1 887.05 | 3 538.27 | 4 728.93 | 5 438.24 |
| 测试时间(秒) | 0.48 | 0.59 | 0.98 | 7.32 | 10.21 | 14.29 |

考虑到发射机和接收机的位置、房屋布局和家居摆放,以及外界干扰(如扫地机器人的移动)等因素可能会对行为识别的准确率产生影响,因此针对这些因素做了相应的对比试验,本文算法考虑不同因素下的识别率如图 9 所示。当人体位于发射机与接收机中间位置时识别情况最好,而人体距离发射机 2.5 m 时识别率较差为 93%。在空房间采集的数据质量好于模拟家居环境下的,因此本文算法在空房间的识别率为 98%,比模拟环境下的识别率高了 2%。当有扫地机器人移动等外界干扰的时候会对人体行为识别产生一定影响,识别率降到 94%。从图 9 可以发现一些特定因素会对人体行为识别造成一定影响,但是本文算法的识别率仍然都在 93%以上,因此可以认为 At-BiLSTM 具有抗外界干扰的能力和鲁棒性。




图 9 本文算法考虑不同因素下的识别率

3 结 论

本文提出了一种针对老年人家居生活的 WiFi 行为识别算法,在公共数据集和自制数据集上进行评估,均取得了较好的识别效果。由于引入高效的双向结构和注意力机制,本文所提出的 At-BiLSTM 算法性能明显优于其他常用算法。尤其对于老年人群体来说,该算法在“跌倒”行为上达到了 99% 的识别率,这将有利于算法的实际应用。由于本文只关注了单用户活动的识别,未来的研究中将考虑多用户人类活动识别的更现实场景,并且试图提高像“站-坐”、“坐-躺”等这类容易混淆的行为的识别率。

参考文献

- [1] TAN T, BADARCH L, ZENG W, et al. Binary sensors-based privacy-preserved activity recognition of elderly living alone using an RNN[J]. *Sensors*, 2021, 21(16): 2-18.
- [2] 岳彬,余大兵,常心悦,等. 基于智能视觉物联网的油库人员行为识别与监测系统[J]. *电子测量技术*, 2020, 43(3): 128-131.
- [3] WANG Z, LIU P, NI S, et al. Low-frequency infrared electromagnetic wave promotes partial nitrification by affecting the community signal system [J]. *Chemical Engineering Journal*, 2021, 425(3): 1-9.
- [4] DONG Y, LI X, DEZERT J, et al. Multi-criteria analysis of sensor reliability for wearable human activity recognition[J]. *IEEE Sensors Journal*, 2021, 21(17): 19144-19156.
- [5] CHEN J, HUANG X, JIANG H, et al. Low-cost and device-free human activity recognition based on hierarchical learning model [J]. *Sensors*, 2021, 21(7): 2-19.
- [6] 胡叶,张爱军. 基于 K-means 的室内行人导航步态识别方法[J]. *国外电子测量技术*, 2021, 40(3): 32-36.
- [7] SHAH S, KANHERE S. Smart user identification using cardiopulmonary activity [J]. *Pervasive and Mobile Computing*, 2019, 58: 1-20, DOI: 10.1016/j.pmcj.2019.05.005.
- [8] SIDOR K, WYSOCKI M. Recognition of human activities using depth maps and the viewpoint feature histogram descriptor [J]. *Sensors*, 2020, 20(10): 2-21.
- [9] CHENG X, HUANG B, ZONG J. Device-free human activity recognition based on GMM-HMM using channel state information[J]. *IEEE Access*, 2021, 9: 76592-76601, DOI: 10.1109/ACCESS.2021.3082627.
- [10] QI W, SU H, ALIVERTI A. A smartphone-based adaptive recognition and real-time monitoring system for human activities [J]. *IEEE Transactions on Human-Machine Systems*, 2020, 50(5): 414-423.
- [11] DANG X, SI X, HAO Z, et al. A novel passive indoor localization method by fusion CSI amplitude and

- phase information[J]. *Sensors*, 2019, 19(4): 2-20.
- [12] 谭峰, 李成南, 萧红, 等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. *仪器仪表学报*, 2020(9): 79-87.
- [13] WANG Z, WANG Z, FAN L, et al. A hybrid WiFi fingerprint-based localization scheme achieved by combining fisher score and stacked sparse autoencoder algorithms[J]. *Mobile Information Systems*, 2020, 2020: 1-14, DOI: 10.1155/2020/5710450.
- [14] FRIDRIKSDOTTIR E, BONOMI A. Accelerometer-based human activity recognition for patient monitoring using a deep neural network[J]. *Sensors*, 2020, 20(22): 2-13.
- [15] ZHANG J, WU F, WEI B, et al. Data augmentation and dense-LSTM for human activity recognition using WiFi signal[J]. *IEEE Internet of Things Journal*, 2020, 8(6): 4628-4641.
- [16] YANG X, CAO R, Zhou M, et al. Temporal-frequency attention based human activity recognition using commercial WiFi devices [J]. *IEEE Access*, 2020, 8: 137758-137769, DOI: 10.1109/ACCESS.2020.3012021.
- [17] ASLAN M, NLEREN M, SABANCI K, et al. CNN-based transfer learning-BiLSTM network: A novel approach for COVID-19 infection detection [J]. *Applied Soft Computing*, 2020, 98: 1-12, DOI: 10.1016/j.asoc.2020.106912.
- [18] DING J, WANG Y. WiFi CSI based human activity recognition using deep recurrent neural network[J]. *IEEE Access*, 2019, 7: 174257-174269.
- [19] HAPSARI Y, SYAMSURYADI. Weather classification based on hybrid cloud image using principal component analysis (PCA) and linear discriminant analysis (LDA) [J]. *Journal of Physics Conference*, 2019, 1167: 1-10, DOI: 10.1088/1742-6596/1167/1/012064.
- [20] GAO W, ZHANG L, TENG Q, et al. DanHAR: Dual attention network for multimodal human activity recognition using wearable sensors[J]. *Applied Soft Computing*, 2020, 111: 1-12, DOI: 10.1016/j.asoc.2021.107728.
- [21] CHEN Z, ZHANG L, JIANG C, et al. WiFi CSI based passive human activity recognition using attention based BLSTM [J]. *IEEE Transactions on Mobile Computing*, 2019, 18(11): 2714-2724.
- [22] 王震宇, 张雷. 基于深度卷积和门控循环神经网络的传感器运动识别[J]. *电子测量与仪器学报*, 2020, 32(1): 1-9.

作者简介

刘苗苗, 硕士研究生, 主要研究方向为信息检测与处理。

E-mail: 2802653444@qq.com

樊春玲, 博士, 教授, 硕士生导师, 主要研究方向为多相流传感与流体流动, 机器视觉和信息处理。

E-mail: chunlingfan@qust.edu.cn