

WiCare:一种非接触式的老人如厕跌倒监测模型

段鹏松, 刁宪广, 张大龙, 曹仰杰, 刘广怡, 孔金生

引用本文

段鹏松, 刁宪广, 张大龙, 曹仰杰, 刘广怡, 孔金生. [WiCare:一种非接触式的老人如厕跌倒监测模型](#)[J]. 计算机科学, 2024, 51(6A): 230700044-8.

DUAN Pengsong, DIAO Xianguang, ZHANG Dalong, CAO Yangjie, LIU Guangyi, KONG Jinsheng.

[WiCare:Non-contact Fall Monitoring Model for Elderly in Toilet](#)[J]. Computer Science, 2024, 51(6A): 230700044-8.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

[基于BERT和CNN的药物不良反应个例报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

[深度学习驱动下IaaS云运维异常检测算法的研究进展](#)

Research Progress of Anomaly Detection in IaaS Cloud Operation Driven by Deep Learning

计算机科学, 2024, 51(6A): 230400016-8. <https://doi.org/10.11896/jsjcx.230400016>

[基于注意力的多尺度蒸馏异常检测](#)

Attention-based Multi-scale Distillation Anomaly Detection

计算机科学, 2024, 51(6A): 230300223-11. <https://doi.org/10.11896/jsjcx.230300223>

WiCare:一种非接触式的老人如厕跌倒监测模型

段鹏松¹ 刁宪广¹ 张大龙¹ 曹仰杰¹ 刘广怡² 孔金生¹

¹ 郑州大学网络空间安全学院 郑州 450002

² 解放军战略支援部队信息大学 郑州 450001

(duanps@zzu.edu.cn)

摘要 老人在卫生间内的跌倒行为存在因救助及时性差而导致严重危害的风险,因此高效快捷的如厕跌倒监测研究具有重要意义。针对当前基于 Wi-Fi 感知的跌倒监测方法中存在的受噪声影响大而特征提取不充分、监测精度有限的问题,提出了一种基于多级离散小波变换和软阈值处理的信号降噪算法,及一种融合卷积神经网络、双向长短期记忆网络及自注意力机制的非接触式如厕跌倒监测模型 WiCare。首先,从原始 CSI 数据中提取振幅作为基础数据;其次,使用多级离散小波变换和软阈值处理进行感知数据降噪;然后,将感知数据进行多维重构,以更准确地表征跌倒行为特征;最后,利用 WiCare 提取感知数据中的有效特征,进而实现卫生间如厕跌倒行为监测功能。实验结果表明,WiCare 在居家卫生间环境下对跌倒行为监测的准确率为 99.41%,与其他同类模型相比,WiCare 的识别准确率高,模型复杂度低,且泛化能力更强。

关键词: Wi-Fi 感知;如厕跌倒监测;离散小波变换;软阈值处理;深度学习

中图分类号 TP391

WiCare: Non-contact Fall Monitoring Model for Elderly in Toilet

DUAN Pengsong¹, DIAO Xianguang¹, ZHANG Dalong¹, CAO Yangjie¹, LIU Guangyi² and KONG Jinsheng¹

¹ School of Cyber Science and Engineering, Zhengzhou University, Zhengzhou 450002, China

² People's Liberation Army Strategic Support Force Information Engineering University, Zhengzhou 450001, China

Abstract The fall down behavior of elderly people in the bathroom poses a risk of serious harm due to poor timely rescue. Therefore, efficient and rapid monitoring of fall down in toilet is of great significance. A non-contact fall down in toilet monitoring model WiCare, which integrates convolutional neural network(CNN), Bi-directional long short-term memory(BiLSTM), and self-attention mechanism, is proposed to address the issues of insufficient feature extraction and limited monitoring accuracy in current fall monitoring methods based on Wi-Fi perception, which are greatly affected by noise. Firstly, the amplitude is extracted from the original CSI data as the basic data. Secondly, multi-level discrete wavelet transform and soft threshold processing are used to reduce perceived data noise. Then, the perceptual data is reconstructed in multiple dimensions to more accurately characterize the characteristics of fall behavior. Finally, WiCare is used to extract effective features in the perception data, and then realize the function of monitoring toilet fall behavior in the toilet. Experimental results show that the accuracy of WiCare in monitoring fall behavior in the home bathroom environment is 99.41%. Compared with other similar models, WiCare has high recognition accuracy, low model complexity, and stronger generalization ability.

Keywords Wi-Fi sensing, Fall down in toilet detection, Multilevel discrete wavelet transform, Soft threshold processing, Deep learning

1 引言

当前,我国老龄化趋势日趋严重,老龄人群的康养安全需求愈发强烈^[1]。跌倒行为作为一种常见的安全事件,其对人体尤其是老龄人群的身体健康可能会造成较大伤害^[2]。尤其在卫生间等密闭空间发生的跌倒行为,可能存在因救助不及时而对老人身体健康造成严重伤害的隐患。据统计,密闭空

间下的老人发生意外跌倒后,其中约 20%的老人会持续处于跌倒状态约 1h 后才能被救助,而高达 47%的未受伤跌倒者无法自主站起^[3]。此外,跌倒不仅会造成身体上的伤害,还会产生严重的心理阴影,尤其是对于老人日常生活中必备的卫生间来说,其高隐私特性可能会造成老人跌倒后的救助及时性更差,进而对老人身体健康造成不可逆转的严重伤害。因此,研究一种低成本、非接触式、高隐私保护性的老人如厕跌

基金项目:郑州市协同创新重大专项(20XTZX06013);中国工程科技发展战略河南研究院战略咨询研究项目(2022HENYB03);河南省科技攻关项目(232102210050)

This work was supported by the Collaborative Innovation Major Project of Zhengzhou(20XTZX06013), China Engineering Science and Technology Development Strategy Henan Research Institute Strategic Consulting Research Project(2022HENYB03) and Key Science and Technology Project of Henan Province(232102210050).

通信作者:张大龙(ttengzhang@163.com)

倒行为监测方法具有重要的现实意义。

常见的老人跌倒监测方法主要依赖计算机视觉^[4-6]和专用传感器^[7-9]等。计算机视觉是对人体跌倒行为的影像序列进行分析和匹配,进而实现跌倒监测功能,但是其受光照影响较大,且存在隐私泄露风险,不适合在卫生间此类密闭场景中使用。专用传感器方法用于跌倒监测时存在携带不便、部署及运维成本昂贵等不足,在卫生间场景下使用也存在诸多限制。对于卫生间场景来说,利用无线信号的衰减变化进行非接触式跌倒行为监测不失为一种好的方式。目前,基于无线信号的非接触行为监测方法包含超宽带技术(Ultra-Wide Band, UWB)^[10]、自组网无线通信技术 ZigBee^[11]等。其中, UWB 带宽范围较大,会对其他无线电系统正常使用造成较大干扰,且设备昂贵,限制其大规模部署。ZigBee 设备在居家场所使用较少,进行感知应用的基础较弱。目前,随着 Wi-Fi 信号在家庭、办公等场所的广泛覆盖,基于该类信号的跌倒监测技术为非接触式行为感知提供了一种新型感知方式,受到了研究者的广泛关注。

与同类方法相比,基于 Wi-Fi 信号的跌倒监测方法具有多种优势,如非接触式、低成本、全天候、隐私保护性较好等。基于 Wi-Fi 信号的感知研究中,常用的感知信号包含信号接收强度(Received Signal Strength Indication, RSSI)和信道状态信息(Channel State Information, CSI)。RSSI 抗干扰能力较低,且传播过程中衰减严重,仅适用于粗粒度行为感知。2010年, Halperin 等^[12]发布了 CSI Tool 工具,使得 CSI 信息能够从商用 Wi-Fi 设备中直接提取。CSI 的粒度更细,信道分辨率更高,且包含丰富的振幅和相位信息,适用于细粒度感知场景,如手势识别^[13-15]、步态识别^[16-18]、跌倒监测^[19-21]、室内定位^[22-24]等。

目前,已有一些利用 Wi-Fi 感知技术进行跌倒监测的研究成果。WiFall^[25]系统利用振幅信息来区分人体活动,分别使用支持向量机算法(SVM)和随机森林算法(RF)实现了准确率达 90% 和 94% 的单人跌倒监测。Anti-fall^[26]首次把 CSI 振幅和相位信息同时用于人体跌倒监测,并使用 SVM 进行分类,准确率为 89%。RT-Fall^[27]则使用相位差作为特征用于跌倒监测,取得了比 WiFall 更好的跌倒识别性能。文献^[28]把 CSI 中的振幅和相位信息同时用于人体跌倒监测,并使用人工鱼群算法修正的 SVM 进行分类,准确率为 94.64%。

当前,基于 Wi-Fi 感知的跌倒监测研究大多采用传统机器学习算法,存在特征提取不足而导致模型识别准确率有限的问题。此外,现有研究主要关注室内开放场景,缺乏针对封闭卫生间场景的研究。为此,本文的在现有 Wi-Fi 感知研究基础之上,提出了一种适用于卫生间场景的跌倒监测模型,旨在为老龄人群的如厕安全提供保障。本文主要创新如下:

1) 针对 Wi-Fi 感知跌倒监测中存在的噪声干扰问题,提出了一种基于多级离散小波变换(DWT)和软阈值处理的信号降噪算法。该算法通过对原始 CSI 数据进行分解、降噪和重构处理,去除干扰信号的高频分量,实现感知数据的有效降噪。实验结果表明,使用 DWT 和软阈值处理后的感知数据后,识别模型分类准确率提高了 1.58%,能有效改进跌倒监测模型的准确率。

2) 基于 Wi-Fi 感知技术,提出了一种适用于卫生间场景的跌倒行为监测模型 WiCare。该模型融合 CNN^[29]和 BiLSTM 并添加自注意力机制进行跌倒行为特征的精准提取。实验结果表明, WiCare 在 DWT 和软阈值降噪后的数据集上取得了 99.41% 的准确率,相比其他同类模型有明显优势。

本文第 1 章主要介绍了卫生间跌倒监测的必要性及 Wi-Fi 感知技术的优势;第 2 章介绍了利用 Wi-Fi 信号进行跌倒监测的基本原理;第 3 章介绍了本文提出的卫生间跌倒监测模型 WiCare,包括数据处理流程和模型设计两部分;第 4 章是实验部分,主要介绍了 DWT、软阈值算法及 WiCare 的评估结果及实验分析;最后总结全文并展望未来。

2 模型原理

2.1 信道状态信息

在 Wi-Fi 信号充分覆盖的卫生间环境中,人体跌倒行为会对 Wi-Fi 信号造成扰动,导致信道状态发生变化。通过分析接收到 CSI 数据中的扰动变化,即可检测是否发生了跌倒行为。CSI 是正交频分复用(Orthogonal Frequency Division Multiplexing, OFDM)技术中用于估计信道状态的信息^[30]。CSI 描述了从发射端到接收端的信号传播过程,并反映了信号在传播过程中所受到的散射、衰落和功率衰减等综合影响。由于 Wi-Fi 信号传输中使用了多载波技术,因此 CSI 数据是针对子载波来说的,其通常定义为:

$$H(f_k) = \| H(f_k) \| e^{j\angle H(f_k)}, k \in [1, K] \quad (1)$$

其中, $H(f_k)$ 是第 k 子载波的信道频域响应, $\| H(f_k) \|$ 和 $\angle H(f_k)$ 分别为该子载波的振幅和相位, e 和 j 分别为自然对数的底数和虚数单位, K 为子载波数量。

2.2 问题定义

CSI 数据包含子载波的振幅和相位两种感知信息,本文选取振幅信息用于跌倒监测。因此,跌倒监测可看作是振幅值映射到相应标签的过程。

通常来说,可将 CSI Tool 工具采集到的数据表示为一个 $N_s \times N_r \times m$ 的复数矩阵,其中 N_s 为发射端天线数量, N_r 为接收端天线数量, m 为 OFDM 信道中的子载波数量,矩阵中的每个元素表示接收信号在对应子载波上的振幅。每个 CSI 数据包中有 $N_s \times N_r$ 个数据流,每个数据流包含 m 个子载波。此时, T 时间段内采集到的单个子载波的 CSI 序列可表示为:

$$\mathbf{X} = [H_{1,k}, H_{2,k}, \dots, H_{i,k}, \dots, H_{j,k}]^T \quad (2)$$

其中, $H_{j,k}$ 表示 j 时刻第 k 个子载波的 CSI 振幅数值。每个子载波间跌倒特征存在差异,为了更好地利用不同频率子载波之间的特征差异,本文将每条无线信道间所有子载波的 CSI 序列重构为二维矩阵形式,如式(3)所示:

$$\mathbf{X} = \begin{bmatrix} H_{1,1} & \dots & H_{1,k} & \dots & H_{1,K} \\ H_{2,1} & \dots & H_{2,k} & \dots & H_{2,K} \\ \vdots & & \vdots & & \vdots \\ H_{j,1} & \dots & H_{j,k} & \dots & H_{j,K} \\ \vdots & & \vdots & & \vdots \\ H_{J,1} & \dots & H_{J,k} & \dots & H_{J,K} \end{bmatrix} \quad (3)$$

在实际的数据采集中,发射端和接收端多天线的场景较为常见。在每个采集周期内,可得到 $N_s \times N_r$ 个振幅矩阵 \mathbf{X} 。由于不同收发天线获取的信号有差异,为保留信号差异,本文将

对应的 $N_s \times N_r$ 个矩阵合并,以增强跌倒动作的特征表征能力。

至此,将带标签的数据集表示为 $D = \{(X_i, Y_i)\}_{i=1}^I$, 其中数据集 D 包含 I 个重构数据,每个重构数据 X_i 有对应的标签 Y_i ,则跌倒监测问题可归纳为:构建一个映射模型,根据输入的重构数据 X 预测对应的跌倒标签 Y 。

本文采用 1 发 3 收的天线配置,每个发射天线经调制发射出 30 个子载波,当采样频率为 1000 数据包每秒,采样时长

为 3 s 时,可生成 3 个大小为 30×3000 的数值矩阵。将其合并可得到形状为 $3 \times 30 \times 3000$ 的三维振幅矩阵。

3 模型设计

本文利用 Wi-Fi 感知技术,设计了适用于卫生间场景内跌倒行为监测模型 WiCare,其包括数据处理模块和跌倒监测模块,如图 1 所示。

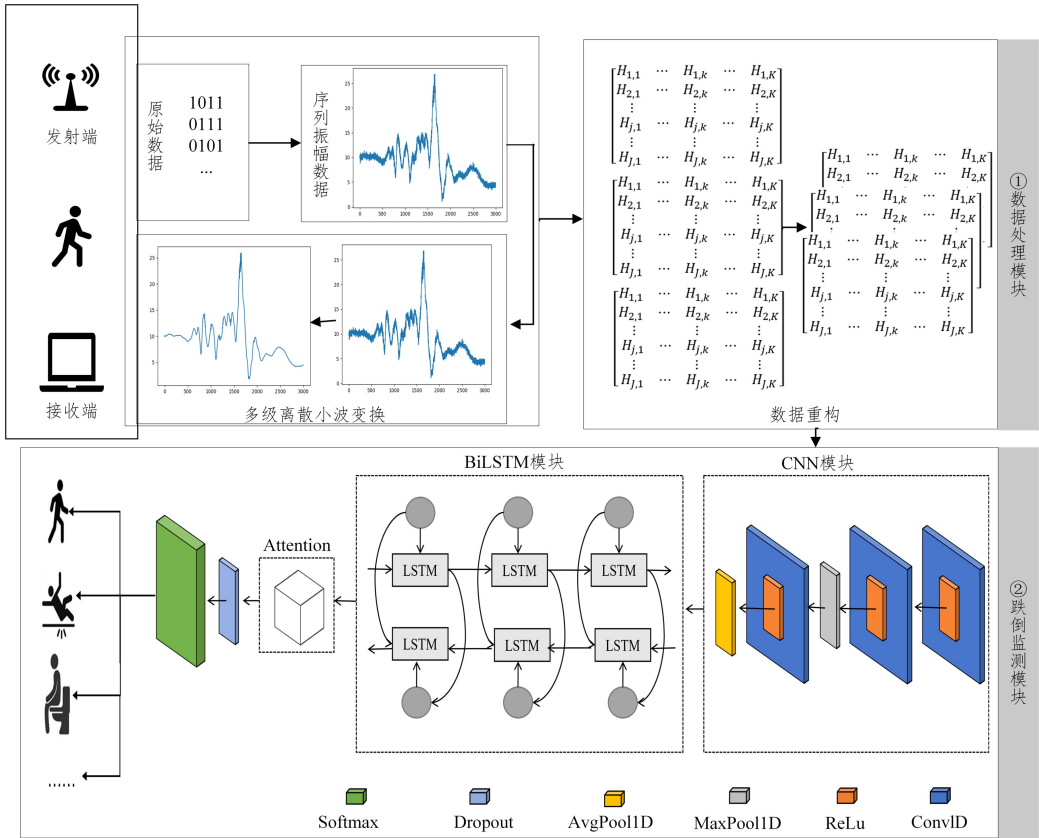


图 1 WiCare 的整体流程图
Fig. 1 Overall flow chart of WiCare

图 1 中,首先,使用 Wi-Fi 信号收发设备获取包含不同跌倒行为特征的 CSI 数据;其次,将采集到的 CSI 数据通过 DWT 和软阈值处理进行降噪;然后,将感知数据重构为多维振幅矩阵;最后,将多维振幅矩阵放入 WiCare 中提取行为特征以分类行为,进而实现跌倒监测功能。

3.1 数据处理

接收端获取的原始 CSI 数据,是经室内不同物品折射、反射、衍射等作用后的综合结果,这种现象被称为多径效应^[31]。此外,原始 CSI 数据中也不可避免会包含周围环境噪声,进而影响跌倒监测的准确性和鲁棒性。因此,数据的预处理是非常必要的。由于 DWT 计算效率高且能保留信号细节,因此本文选取 DWT 和软阈值处理进行 CSI 数据降噪。

本文中,DWT 处理流程由信号分解、软阈值处理和信号重构 3 部分组成,如图 2 所示。DWT 可将原始 CSI 数据分解为近似系数(低频分量)和细节系数(高频分量)。其中,近似系数用于描述 CSI 数据的形状,而细节系数用于捕捉随机噪声和细节信息。为获得更精细的细节信息,DWT 递归分解近似系数,并通过软阈值处理各层细节系数,以实现 CSI 数据降噪的目的。下文将对这 3 部分进行详细介绍。

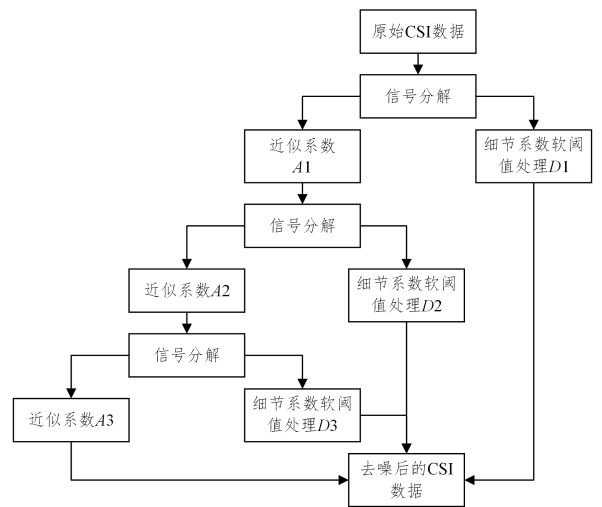


图 2 DWT 和软阈值算法降噪流程图
Fig. 2 Flowchart of DWT and soft threshold algorithm denoising

1)信号分解。对原始 CSI 数据进行多级离散小波分解,得到近似系数和细节系数,处理方法分别如式(4)、式(5)所示。此部分的目的是将原始 CSI 数据分解成不同的频率分量,以便更好地进行降噪。

$$\omega_{j,k} = \sum_{n=0}^{N-1} x_n h_{n-2^j k} \quad (4)$$

$$v_{j,k} = \sum_{n=0}^{N-1} x_n g_{n-2^j k} \quad (5)$$

其中, x_n 为原始 CSI 数据, $h_{n-2^j k}$ 和 $g_{n-2^j k}$ 分别表示两组离散正交函数, 也称为小波函数, $\omega_{j,k}$ 和 $v_{j,k}$ 分别表示第 j 级小波分解后的近似系数和细节系数, k 为小波分解的位置参数, j 为小波变换的层数。

2) 软阈值处理。采用软阈值处理分解后的细节系数, 达到对原始 CSI 数据进行降噪, 同时保留原始 CSI 数据中的重要信息, 处理方法如式(6)所示。此部分的目的是对原始 CSI 数据中高频分量部分进行降噪。

$$S = \begin{cases} v_{j,k} - T, & v_{j,k} > T \\ 0, & |v_{j,k}| \leq -T \\ v_{j,k} + T, & v_{j,k} < -T \end{cases} \quad (6)$$

其中, T 为软阈值参数, 绝对值小于阈值的小波系数置 0,

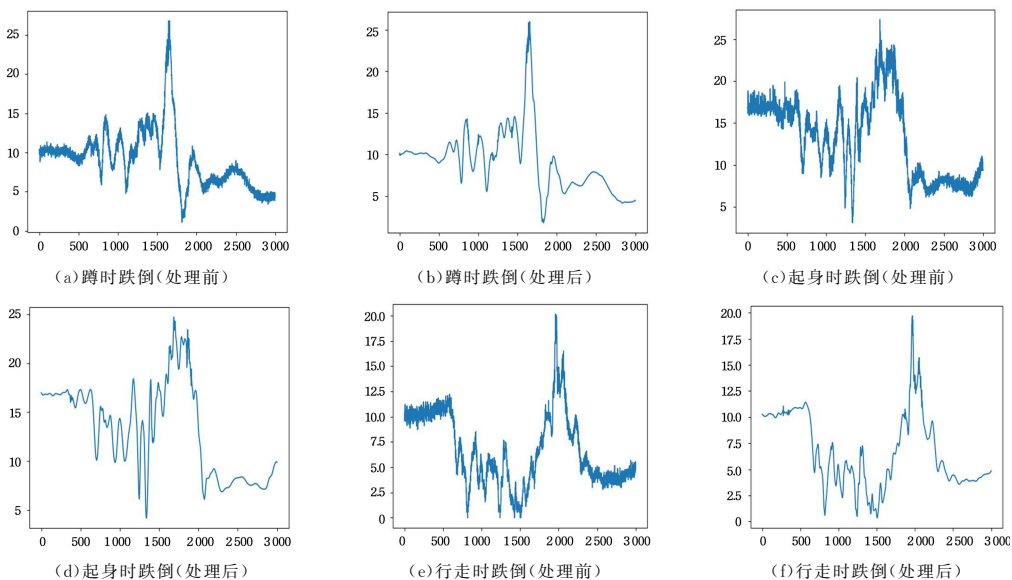


图 3 3 种跌倒动作经 DWT 处理前后的对比

Fig. 3 Comparison before and after DWT treatment

从图 3 中可以看出, 经 DWT 和软阈值处理后的 CSI 数据更加平滑且噪声更少。此外, 第 4.2.1 节的实验也证明了经 DWT 和软阈值处理后的数据提升了跌倒监测模型的准确率。

3.2 跌倒监测

在跌倒监测模块, WiCare 采用的主要技术包含 CNN、BiLSTM 及自注意力机制等。本节将介绍这些技术及模型的构建细节。

CSI 为时间序列结构的数据, 一维卷积神经网络(1D-CNN)在处理时间序列的数据时具有效率高和高泛化能力, 因此本文使用 1D-CNN。一维卷积计算过程如式(8)所示:

$$y_i = \sum_{j=1}^m \alpha_j x_{i+j-1} \quad (8)$$

其中, y_i 是输出的第 i 个元素, m 是卷积核的大小, α_j 是卷积核的权重, x_{i+j-1} 是输入的第 $i+j-1$ 个元素。

LSTM^[32] 在处理时序数据时有效地缓解了梯度消失问题, 但 LSTM 仅考虑当前时刻之前的历史信息, 而 BiLSTM 则由前向 LSTM 和后向 LSTM 组成, 全面考虑了之前的历史信息 and 之后的未来信息, 跌倒监测需要考虑一段时间内的

大于阈值的则进行减小。

3) 信号重构。将经过软阈值处理后的小波系数进行重构, 处理方法如式(7)所示。此部分的目的是对降噪后的 CSI 数据进行重构。

$$\bar{x}_n = \sum_k \omega_{j,k} \cdot \prod_{j=0}^{J-1} 2^{-\frac{j}{2}} h_{n-2^j k} + \sum_k v_{j,k} \cdot \prod_{j=0}^{J-1} 2^{-\frac{j}{2}} g_{n-2^j k} \quad (7)$$

其中, \bar{x}_n 为降噪后的 CSI 数据; J 表示小波变换的层数; $\omega_{j,k}$ 和 $v_{j,k}$ 分别表示第 j 级小波分解后的近似系数和细节系数; $h_{n-2^j k}$ 和 $g_{n-2^j k}$ 分别表示两组离散正交函数; $2^{-\frac{j}{2}}$ 表示一个权重项, 用于对不同层进行加权处理, 从而完成小波重构过程。

本文所使用的小波函数为多贝西(Daubechies, dB)小波函数, 图 3 为经过 DWT 和软阈值处理前和处理后的 3 种跌倒动作(蹲时跌倒、起身时跌倒、行走时跌倒)的振幅波形图。其中, 横轴表示采样时间, 单位为毫秒(ms), 竖轴表示振幅大小(dB)。

人体动作对 CSI 数据的影响, 这些信息具有时序特征, 故 WiCare 中采用 BiLSTM 进行特征提取, 其结构如图 4 所示。




图 4 双向长短期记忆网络结构

Fig. 4 Network structure of BiLSTM

具体跌倒监测模型如图 5 所示, 先使用 3 层 Cnov1D 提取 CSI 数据中与跌倒相关的局部特征, 对于 3 层 Cnov1D, 前两层卷积核大小均为 4, 步长为 2, 并在每层 Cnov1D 中使用 ReLU 函数作为激活函数, 随后加入一个尺寸为 2 的最大池化层减小输出数据的尺寸, 保留最显著特征, 第三层卷积核大小为 7, 步长为 2, 且后面跟一个 ReLU 激活函数, 最后加入一个尺寸为 32 的平均池化层, 保留更加平滑的特征信息。

CNN 模块将提取到的特征输入到 BiLSTM 层,以进一步提取其时间序列特征,对于 BiLSTM 层,隐藏状态大小为 64。自注意力机制模块包含一个线性层和一个 Softmax 函数,首先,线性层将 BiLSTM 层输出的特征向量转换为一个标量;其次,通过 Softmax 函数将该标量转换为一个概率分布;最后,使用该概率分布对输入序列中的特征向量进行加权求和,得到自注意力机制的输出特征向量。提取完有效特征后,加入参数为 0.1 的 Dropout^[33]层来防止过拟合,最后将有效特征输入到 Softmax 层将其映射到 6 种行为(正常行走、行走时跌倒、静止蹲、蹲时跌倒、正常起身、起身时跌倒)。

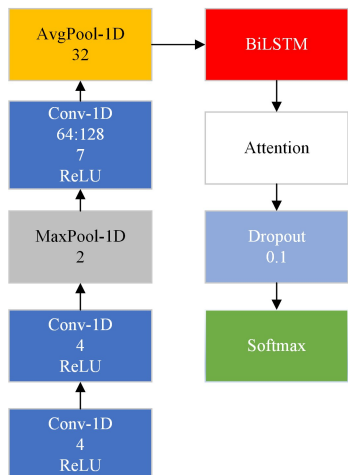


图 5 跌倒监测模型

Fig. 5 Fall detection model

4 实验与分析

4.1 实验设置

目前,国内外还没有公开的卫生间内目标跌倒 Wi-Fi 感知数据集。因此,本文进行了相关数据的自采,并用于本文设计模型的评估。在数据集采集时,本文选择了不同居家卫生间环境(环境-1、环境-2)进行人体跌倒数据采集,环境-1 实景如图 6 所示。



图 6 采集环境-1 实景图

Fig. 6 Collection environment

在感知数据收发装置上,发射端和接收端分别为 TP-LINK AC1750 无线路由器(发射端)和 Intel5300 802.11n NIC 网卡并安装开源 CSI Tool 工具的台式计算机(接收端)。发射端和接收端分别配置 1 个和 3 个天线,因此构成了 3 个(1×3)天线对,其中每个天线对包含 30 个子载波。因此,每个接收端采集到的数据文件共包含 90(1×3×30)个子载波的 CSI 数据。详细实验参数设置如表 1 所列。

表 1 实验设备参数设置

Table 1 Experimental equipment parameter settings

参数名称	参数值
发射端与接收端距离/cm	360
发射端天线数、接收端天线数	1,3
信号频率/GHz	5
接收端采样率	1000 个数据包每秒
采集时长/ms	3000
采样工具	CSI Tool

居家卫生间环境-1 中,实验共采集了 5 名受测者的跌倒行为 CSI 数据。采集过程中,每个实验者在视距路径下的活动时间为 3s。最终,形成的自采数据集(DataSet-1)包括 5 名受测者的 6 个动作数据,其中每种动作采集 60 条。整个数据集采集时间持续一周,处理后得到 1800 条数据(3.3 GB),并以 4:1 的比例划分训练集和测试集。环境-2 采集数据方式与环境-1 相同,形成的数据集为 DataSet-2,用于 WiCare 泛化实验部分。

在模型实现中,本文选取 PyTorch 深度学习框架构建跌倒监测模型 WiCare。WiCare 的学习率设置为 0.001,优化器使用 Adam,dropout^[21]层参数设置为 0.1,以防止过拟合,Batch-size 设置为 8。WiCare 的训练和测试在一个配备 NVIDIA 2060Ti 显卡的服务器上完成。

4.2 实验结果

为评估 WiCare 的性能,本文设计不同的实验。首先,本文验证了所提出的 DWT 和软阈值处理方法的有效性;然后,通过消融实验和泛化实验,验证了模型结构的合理性;最后,通过 WiCare 与现有模型的性能进行对比,验证了 WiCare 的先进性。

4.2.1 多级离散小波变换的有效性验证

为验证所提出的 DWT 和软阈值处理方法的有效性,本文设计了 WiCare 使用 DWT 和软阈值处理以及不使用 DWT 和软阈值处理进行实验,在 DataSet-1 上的结果如图 7 所示。




图 7 WiCare 是否使用 DWT 的评估结果

Fig. 7 Evaluation of whether WiCare uses DWT

DWT 可通过对原始 CSI 数据进行多次分解和重构来降噪声,而不会过度平滑信号或损失重要信息。同时,软阈值处理可以使 CSI 数据更加平稳,从而降低分类误差。从图 7 可以看出,使用 DWT 和软阈值处理后的分类准确率达到 99.41%,高于不使用 DWT 和软阈值处理的准确率,其他 3 个指标的表现也一样。实验结果表明,DWT 和软阈值处理能有效地减少噪声对模型的影响,提高了模型的鲁棒性和稳定性。

4.2.2 WiCare 消融实验

消融实验指通过对深度学习模型中的某些模块进行去除或修改,来评估这些模块对模型性能的一种实验。为验证 WiCare 的模型结构合理性,本文进行了相应的消融实验。实验中,共设计了如下 5 种消融模型。

- 1) WiCare-1: 不添加注意力机制;
- 2) WiCare-2: CNN 模块和 LSTM 模块组合;
- 3) WiCare-3: 仅使用 CNN 模块;
- 4) WiCare-4: 仅使用 BiLSTM 模块;
- 5) WiCare-5: 仅使用 LSTM 模块。

本文对比了 WiCare 和以上 5 种消融模型在 DataSet-1 上的识别性能对比, 结果如图 8 所示。




图 8 消融实验结果的对比

Fig. 8 Comparison of ablation study results

从图 8 可以看出, 对于 WiCare, 使用和不使用自注意力机制的模型识别准确率分别为 99.41% 和 98.23% (WiCare-1), 有 1.18% 的性能差距。这表明自注意力机制能促使模型选择 CSI 数据中的关键信息, 提高模型准确率。WiCare-1 的准确率为 98.23%, 相比 WiCare-2 准确率高出 1.01%。同时, WiCare-4 的准确率为 95.88%, 相比 WiCare-5 准确率高出 1.02%。这表明在处理 CSI 数据时, BiLSTM 比 LSTM 能更充分地提取时序数据的全局特征, 提高模型的准确率。WiCare-3 虽然局部特征提取能力强, 但无法捕捉到整个时间序列的全局特征, 准确率仅为 96.38%。WiCare 模型将 1D-CNN 和 BiLSTM 结合起来, 可以充分利用两者的优势。其中, 1D-CNN 可以提取局部特征, BiLSTM 则可以捕捉全局时序特征, 两者相互补充, 提高了模型的整体性能。此外, 加入自注意力机制, 提高了模型对关键信息的关注能力。综上所述, 融合 CNN-BiLSTM 和自注意力机制, 可以获得更好的时间序列建模性能。

4.2.3 不同模型识别性能对比

为了充分评估 WiCare 的各项识别性能, 本文选取了跌倒监测模型 WiSfall^[34] 和 VIT^[35] 作为对比模型。WiSfall 采用两个 CNN 模块进行特征提取并进行特征融合, 能实现较为准确的浴室跌倒监测。VIT 是一种基于 Transformer 和自注意力机制的跌倒监测模型。在 DataSet-1 上, 这 3 种模型的对比结果如图 9 所示。




图 9 不同模型评估指标对比

Fig. 9 Comparison of evaluation indicators of different models

从图 9 可以看出, WiCare 的准确率最高, 达到了 99.41%, 其次是 WiSfall 的 98.23% 及 VIT 的 97.64%。WiSfall 虽采用了特征融合的方法, 但其对 CSI 数据的全局

时序特征提取能力较弱, 且缺少对关键特征的选取, 导致在准确率评估项上表现稍逊。VIT 虽使用 Transformer 层和自注意力机制来捕捉 CSI 数据中的行为特征, 但同样在提取全局时序特征时较 WiCare 弱。其他 3 个评估指标的结果也说明 WiCare 在卫生间环境中的表现更好, 具有更强的监测能力。

除准确率外, 本文还从模型参数量和训练时间两方面来对比 WiCare 和其他两个模型的优劣, 实验结果如表 2 所列。

表 2 不同模型复杂度对比

Table 2 Comparison of different model complexities

模型	指标	
	Time duration / (s)	Parameters
WiCare	869.86	0.1×10^6
WiSfall	878.20	0.16×10^6
VIT	1241.56	0.93×10^6

从表 2 中可看出, WiCare 参数量为 0.1×10^6 , 相对于 WiSfall 和 VIT, 各参数量为 0.16×10^6 和 0.93×10^6 , 其计算复杂度更低。WiCare 和 WiSfall 的训练时间相近, 分别为 869.86s 和 878.20s, 但 WiCare 相对 WiSfall 参数量减少约 40%, 相比 VIT 的训练时间也大幅缩减约 30%。综上所述, WiCare 在卫生间内监测老年人跌倒任务上具有明显的优势, 能够更快且准确地识别老年人的跌倒情况, 为老年人提供更好的保障。

4.2.4 模型泛化能力对比

为了验证 WiCare 结构的鲁棒性, 以应对不同卫生间环境下的跌倒监测, 本文还进行了相应的泛化能力对比实验。实验中, 使用了两个不同的卫生间环境下采集的感知数据集, 通过对 DataSet-1 上训练好的模型结构进行微调以实现模型迁移。为了提高迁移学习的效果, 采用冻结模型方法保留浅层公共特征, 并在 DataSet-2 上训练剩余层。

为对比不同模型的泛化能力, 本文进行了 WiCare 不同消融模型之间及 WiCare 和其他同类模型的迁移效果对比实验。其中, 消融实验迁移对比模型仍为 WiCare-1, WiCare-2, WiCare-3, WiCare-4, WiCare-5, 实验结果如图 10 所示。




图 10 迁移实验结果对比

Fig. 10 Comparison of migration experiment results

从图 10 可以看出, WiCare 表现最好, 准确率为 83.07%, 其他模型的表现则相对较差。其中, WiCare-1 由于缺少对关键特征的选择, 导致模型泛化能力较差的准确率为 81.07%; WiCare-2 由于在提取 CSI 数据的全局时序特征较 WiCare 差, 且缺少对关键特征的选择, 导致模型泛化能力较差, 准确率为 78.13%; WiCare-3, WiCare-4, WiCare-5 仅使用单一的提取特征方法, 且缺少对关键特征的选择, 导致模型泛化能力均较差。相比之下, WiCare 融合 CNN-BiLSTM 和自注意力机制, 能够更有效地提取 CSI 数据中的关键行为特征, 在老人如厕跌倒监测中取得了较好的效果。

在其他同类模型迁移对比实验中,依旧选取 WiSFall 和 VIT 作为对比模型,实验结果如图 11 所示。




图 11 迁移实验结果的对比

Fig. 11 Comparison of migration experiment results

从图 11 可以看出, WiCare 的准确率最高,达到了 83.07%,其次是 WiSFall 的 76.53% 及 VIT 的 73.42%。WiSFall 使用多个 ConvBN 组合的方式进行特征融合,但缺少 BiLSTM 模块对时间序列中全局特征的提取及自注意力机制对关键特征的关注,因此冻结浅层卷积层的操作未能有效保留公共特征,导致其泛化能力有限。VIT 的核心层为 Transformer 层和自注意力层,相对 1D-CNN 缺少归纳偏置及 BiLSTM 模块对时间序列中全局特征的提取能力,不能有效保留公共特征,导致其泛化能力有限。相比之下, WiCare 的 BiLSTM 模块能使模型捕捉 CSI 数据中的时间依赖性,而自注意力机制使模型能够关注输入数据中最相关的特征,这对于如厕跌倒监测非常重要。

结束语 高效便捷的卫生间跌倒监测技术对老人如厕安全有着重要的安全意义。传统基于 Wi-Fi 感知的跌倒监测方法的数据处理过程较为复杂,且需手动提取特征,效率较低且识别结果欠佳。本文提出的 WiCare,针对卫生间场景,使用 DWT 和软阈值处理对原始 CSI 数据进行降噪,并基于 CNN-BiLSTM 和自注意力机制模型进行特征提取及行为分类,取得了较好的跌倒行为监测效果。实验结果显示, WiCare 不仅准确率高,且具有较强的鲁棒性。

由于多径效应的普遍存在,本文模型仍具有一定局限性。后期,本文将从以下两个方面进行改进:1)充分融合振幅和相位信息进行特征提取,进一步提升模型鲁棒性;2)研究多人跌倒监测方法,扩大模型的普适范围。

参考文献

- [1] YUX P, LU B Y. Active Measures for Current Situation of Population Aging in China[J]. China Economist, 2023(2): 21-22.
- [2] ZHANG T T, FENG Z Q, WANG W C, et al. A study on the status quo and influencing factors of falls among the elderly in China[J]. Chinese Journal of Disease Control and Prevention, 2022, 26(5): 502-507.
- [3] ZHANG H, QI S G, CUI L, et al. Prevalence of falls and fall-related injuries among Chinese community-dwelling older adults: a one-year retrospective follow-up data analysis[J]. Chinese Journal of Public Health, 2022, 26(5): 502-507.
- [4] LIU J, TAN R, HAN G, et al. Privacy-preserving in-home fall detection using visual shielding sensing and private information-embedding[J]. IEEE Transactions on Multimedia, 2020, 23: 3684-3699.
- [5] LOTFI A, ALBAWENDI S, POWELL H, et al. Supporting independent living for older adults: employing a visual based fall de-

tection through analysing the motion and shape of the human body[J]. IEEE Access, 2018, 6: 70272-70282.

- [6] CHONG C J, TAN W H, CHANG Y C, et al. Visual based fall detection with reduced complexity horprasert segmentation using superpixel[C]//2015 IEEE 12th International Conference on Networking, Sensing and Control. IEEE, 2015: 462-467.
- [7] ISLAM M S, SHAHRIAR H, SNEHA S, et al. Mobile sensor-based fall detection framework[C]//2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC). IEEE, 2020: 693-698.
- [8] HNOOHOM N, JITPATTANAKUL A, INLUERGRIP, et al. Multi-sensor-based fall detection and activity daily living classification by using ensemble learning[C]//2018 International ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering(ECTI-NCON). IEEE, 2018: 111-115.
- [9] XU J D, CHEN Q, XUY X, et al. Design of real time fall detection system based on MEMS sensor[J]. Transducer and Microsystem Technologies, 2022, 41(7): 77-80.
- [10] HU D M, WANG S H, SUN X Y, et al. Improved Grey Model Prediction Algorithm for Falling Down[J]. Science Technology and Engineering, 2019, 19(20): 31-36.
- [11] HE J, ZHANG Z J, WANG W D, et al. Low-Power Fall Detection Technology Based on ZigBee and CNN Algorithm[J]. Journal of Tianjin University (Science and Technology), 2019, 52(10): 1045-1054.
- [12] HALPERIRR D, HU W, SHETHA, et al. Tool release: gathering 802.11n traces with channel state information[J]. Acm Sigcomm Computer Communication Review, 2011, 41(1): 53-53.
- [13] ZHANG T, SONG T, CHEN D, et al. WiGrus: A WiFi-based gesture recognition system using software-defined radio[J]. IEEE Access, 2019, 7: 131102-131113.
- [14] ABDELNASSER H, YOUSSEF M, HARRASK A. Wigest: A ubiquitous wifi-based gesture recognition system[C]//2015 IEEE Conference on Computer Communications(INFOCOM). IEEE, 2015: 1472-1480.
- [15] LI C, LIU M, CAO Z. WiHF: Gesture and user recognition with WiFi[J]. IEEE Transactions on Mobile Computing, 2020, 21(2): 757-768.
- [16] WANG W, LIU A X, SHAHZAD M. Gait recognition using wifi signals[C]//Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing. 2016: 363-373.
- [17] 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(IPSIN). IEEE, 2016: 1-12.
- [18] DENG L, YANG J, YUAN S, et al. Gaitfi: Robust device-free human identification via wifi and vision multimodal learning[J]. IEEE Internet of Things Journal, 2022, 10(1): 625-636.
- [19] HU Y, ZHANG F, WU C, et al. DeFall: Environment-independent passive fall detection using WiFi[J]. IEEE Internet of Things Journal, 2021, 9(11): 8515-8530.
- [20] HU Y, ZHANG F, WUC, et al. A WiFi-based passive fall detection system[C]//ICASSP 2020—2020 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP).

- IEEE, 2020; 1723-1727.
- [21] LI X W, YU J, CHANG J P, et al. Non-cooperative Human Behavior Recognition Method Based on CSI[J]. Computer Science, 2019, 46(12): 266-271.
- [22] YANG C, SHAO H R. WiFi-based indoor positioning[J]. IEEE Communications Magazine, 2015, 53(3): 150-157.
- [23] LUKITO Y, CHRISMANTO A R. Recurrent neural networks model for WiFi-based indoor positioning system[C] // 2017 International Conference on Smart Cities, Automation & Intelligent Computing Systems (ICON-SONICS). IEEE, 2017: 121-125.
- [24] DANG X C, ZHANG T, HAO Z J, et al. Indoor Key Area Monitoring Method Based on WiFi[J]. Journal of Chinese Computer Systems, 2020, 41(2): 344-349.
- [25] WANG Y, WU K, NIL M. Wifall: Device-free fall detection by wireless networks[J]. IEEE Transactions on Mobile Computing, 2016, 16(2): 581-594.
- [26] ZHANG D, WANG H, WANG Y, et al. Anti-fall: A non-intrusive and real-time fall detector leveraging CSI from commodity WiFi devices [C] // 13th International Conference on Smart Homes and Health Telematics (ICOST 2015). Geneva, Switzerland, Springer International Publishing, 2015; 181-193.
- [27] WANG H, ZHANG D, WANG Y, et al. RT-Fall: A real-time and contactless fall detection system with commodity WiFi devices [J]. IEEE Transactions on Mobile Computing, 2016, 16(2): 511-526.
- [28] RAN Y X, YU J, CHANG J, et al. A CSI-based fall detection method[J]. Journal of Yunnan University(Natural Sciences Edition), 2020, 42(2): 220-227.
- [29] LECUN Y, BOTTOU L, BENGIOY, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [30] WU K, XIAO J, YI Y, et al. FILA: Fine-grained indoor localization[C] // 2012 Proceedings IEEE INFOCOM. IEEE, 2012: 2210-2218.
- [31] GU Y, ZHANG X, LIU Z, et al. BeSense: leveraging WiFi channel data and computational intelligence for behavior analysis[J]. IEEE Computational Intelligence Magazine, 2019, 14(4): 31-41.
- [32] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [33] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. The journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [34] DUAN P S, LI J X, WANG C, et al. WiSFall: a Device-free Fall Detection Model for Shower Room[J]. Journal of Chinese Computer Systems, 2023, 44(2): 232-238.
- [35] YANG J, CHEN X, ZOU H, et al. SenseFi: A library and benchmark on deep-learning-empowered WiFi human sensing[J]. Patterns, 2023, 4(3).



DUAN Pingsong, born in 1983, Ph.D, is a member of CCF (No. 43410M). His main research interests include wireless sensing Internet of things and machine learning.



ZHANG Dalong, born in 1976, professor, Ph.D supervisor, is a member of CCF (No. T98T4M). His main research interests include wireless communication network, satellite positioning and network information.