文章编号：2095-4980(2026)01-0073-07

基于WiFi的跨环境适应性的人体行为识别算法

李星星[1]，黄景涛[1]，陆许明[*1]，陈　翔[2]

(1.五邑大学 电子与信息工程学院，广东 江门 529000；2.中山大学 电子与信息工程学院，广东 广州 510000)

摘　要：针对老年人跌倒等不安全行为的隐私保护识别及跨环境识别率低的问题，提出一种基于信道状态信息(CSI)的行为识别框架——单天线跨环境稳定人体活动特征提取(SSRF)，并对现有ReWiS模型进行优化。通过从不同环境采集5类老年人行为数据(如跌倒、无动作等)，对CSI信号进行幅值归一化、奇异值分解(SVD)和皮尔逊相关系数计算，生成带标签的CSI数据样本输入ProtoNet模型进行分类。相比ReWiS，SSRF显著减少了参数量(从111 936降至37 392)，加快了训练与测试速度，所有样本训练时间从33.12 s缩短至26.8 s，每个样本测试时间从0.000 149 s减少至0.000 104 s。在公开数据集的四分类任务和自制数据集的五分类任务中，SSRF的平均跨环境准确率分别达到89%和85%，跌倒行为预测准确率为95%。实验表明，SSRF在保持高泛化性能的同时，大幅提高了效率。

关键词：信道状态信息；人体行为识别；元学习

中图分类号：TP391.4　　**文献标志码：**A　　**DOI：**10.11805/TKYDA2024543

Human behavior recognition algorithm based on WiFi cross-environment adaptability

LI Xingxing[1]，HUANG Jingtao[1]，LU Xuming[*1]，CHEN Xiang[2]

(1.Faculty of Electronic and Information Engineering，Wuyi University，Jiangmen Guangdong 529000，China；
2.Faculty of Electronic and Information Engineering，Sun Yat-sen University，Guangzhou Guangdong 510000，China)

Abstract：To address the challenges of privacy protection in recognizing unsafe behaviors such as falls and low cross-environment recognition rates，this paper proposes a behavior recognition framework，Single-antenna Cross-environment Stable Human Activity Feature Extraction and Recognition Framework (SSRF)，based on Channel State Information(CSI)，optimized from the existing ReWiS model. By collecting data on five types of elderly behaviors(such as falls，no action，etc.) from different environments，the CSI signals are normalized，followed by Singular Value Decomposition(SVD) and Pearson correlation coefficient calculation to generate labeled CSI data samples，which are then fed into the ProtoNet model for classification. Compared to ReWiS，SSRF significantly reduces the number of parameters(from 111 936 to 37 392) and accelerates both training and testing speed，with total training time reduced from 33.12 s to 26.8 s，and per-sample testing time reduced from 0.000 149 s to 0.000 104 s. In the four-category task of a public dataset and the five-category task of a custom dataset，SSRF achieves average cross-environment recognition accuracies of 89% and 85%，respectively，with 95% accuracy for fall detection. Experimental results show that SSRF maintains high generalization performance while significantly improving the efficiency.

收稿日期：2024-09-20；**修回日期：**2024-11-01

基金项目：广东普通高校重点领域专项资助项目(2022ZDZX1033)；江门市基础与理论科学研究类科技计划资助项目(2022JC01026)

[*]**通信作者：**陆许明　email:luxuming@189.cn

引用格式：李星星,黄景涛,陆许明,等. 基于WiFi的跨环境适应性的人体行为识别算法[J]. 太赫兹科学与电子信息学报, 2026,24(1):73-79. DOI:10.11805/TKYDA2024543.

Citation format：LI Xingxing,HUANG Jingtao,LU Xuming,et al. Human behavior recognition algorithm based on WiFi cross-environment adaptability[J]. Journal of Terahertz Science and Electronic Information Technology, 2026,24(1):73-79. DOI:10.11805/TKYDA2024543.

Keywords：Channel State Information(CSI)；human behavior recognition；meta-learning

国家统计局公布的数据表明，我国在2022年末60岁及以上的人口数量达到28 004万人[1]，随着人口老龄化，随之而来的就是独居老年人的安全保障问题，如老年人在如厕、洗澡时发生摔倒或因特殊病情跌倒等。因此，老年人的行动需要密切关注。目前的人体跌倒检测识别方法可分为基于雷达[2]、基于可穿戴设备[3]、基于视频分析[4-5]和基于WiFi[6-7]这4种。由于基于视频分析方法不具有隐私性，基于可穿戴设备方法的高部署成本，近年来，基于WiFi信号的跌倒检测方法得到了较大发展。相比之下，基于WiFi的室内跌倒检测方法有着保护隐私、成本低和几乎覆盖室内区域等优点。因此，本文主要研究基于WiFi信号的跌倒检测方法。20 MHz带宽是WiFi的基本标准，可确保最广泛的兼容性，支持更宽带宽的设备。某些情况下，使用20 MHz带宽可实现更长的传输距离。较宽的带宽通常在短距离通信中更为有效，而20 MHz带宽可提供更好的覆盖范围，特别是在室外环境或需要信号穿透障碍物的场合。在干扰较多的环境中，使用20 MHz带宽可提供更稳定、可靠的连接，因为较窄的信道受到干扰的影响较小。基于信道状态信息(CSI)的人体行为识别算法逐渐采用深度学习方法自动提取深层特征并分类，如递归神经网络(Recurrent Neural Network，RNN)与长短期记忆(Long Short-Term Memory，LSTM)[8]结合、双向LSTM[9]与注意力机制结合等[10]。这些方法在特定环境下表现良好，但在新环境中的准确率会显著下降。少样本学习(Few-Shot Learning，FSL)能够在数据量有限的情况下快速适应新任务，减少数据收集成本。相关研究中，MatNet-PCC(Pearson Correlation Coefficient)[11]在新环境下六分类的准确率约为80%，ML(Machine Learning)[12]算法在1-shot分类中的准确率达90%，ReWiS[13]在80 MHz带宽环境下四分类的准确率达到95%。

本文提出的SSRF框架是在ReWiS的基础上针对20 MHz带宽通道环境进行优化得到。SSRF在20 MHz带宽通道环境下，使用软件无线电设备，通过单天线单接收机模式收集CSI数据，并加大数据包窗口，显著提高了人体行为识别的分类性能。通过模型压缩技术，将ReWiS的参数量从111 936(0.428 MB)降至SSRF的37 392(0.144 MB)，这一优化不仅减少了模型的存储需求，而且提高了模型在资源受限设备上的部署效率。实验结果表明，SSRF在公开数据集和自制数据集中都展现出卓越的识别性能。特别是在20 MHz带宽环境下，五分类预测结果达到了87%的准确率。更值得一提的是，在新环境下的跌倒预测正确率高达94%，这一成果对于远程医疗保健、安全和监控等应用领域具有重要意义。SSRF的成功不仅在于其高准确率，更在于其对新环境的快速适应能力。通过这些技术创新，SSRF为20 MHz带宽的WiFi传感技术提供了一个更为高效、准确的解决方案。

1 系统框架

1.1 SSRF系统概述

SSRF的主体框架如图1所示，分为CSI收集模型、原始数据采集、数据预处理、特征提取及分类4部分。首先在模拟浴室环境下搭建稳定的WiFi通信，通过接收器捕获发射器的一系列WiFi数据包，并从中提取CSI的信息；然后对CSI信息进行原始幅值归一化，使用SVD将时域信息映射到子载波，然后计算皮尔逊相关系数后得到降维后的带标签的CSI数据样本；训练嵌入函数将CSI数据样本进行特征提取并映射到嵌入空间中再利用ProtoNet[14]思想进行分类。CSI数据将在某模拟浴室环境下进行训练和调参，并把另一环境下收集的CSI数据样本作为测试集进行测试分析。

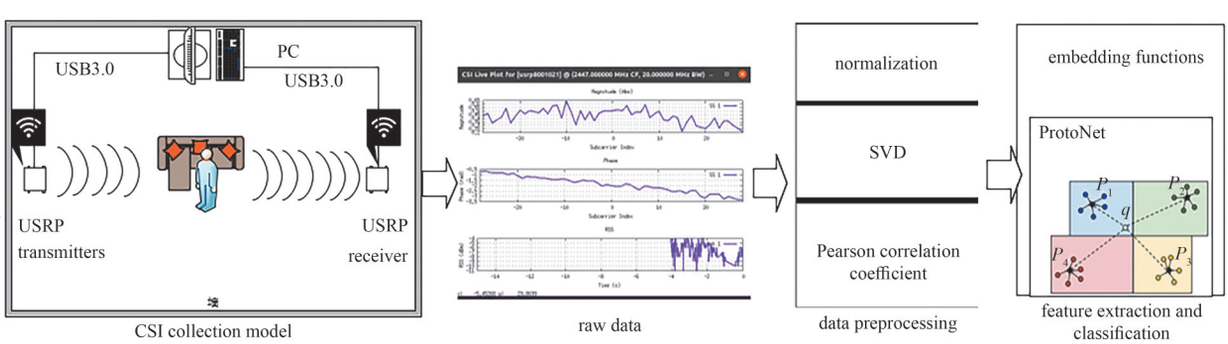

Fig.1 System process

图1 系统流程

1.2 CSI感知原理及信号收集

物体在无线信道中运动时会引起信号的衰减、相位变化、多径效应等，而CSI记录这些信息。因此，通过分

析不同动作对CSI信息的影响，结合机器学习的思想可对人类的活动进行分类识别。本文采用PicoScenes作为CSI收集工具，建立一个单天线通信模型，在20 MHz信道带宽下收集CSI。在单输入单输出正交频分复用(Single-Input Single-Output Orthogonal Frequency Division Multiplexing，SISO-OFDM)系统中，数字数据流在多个重叠的、紧密间隔的正交子载波上进行调制以并行传输数据。假设收到的数据包数为P，子载波数为S，接收器收到的CSI矩阵为：

$$\boldsymbol{H}_{\mathrm{r}}=\begin{bmatrix} h_{1,1} & \cdots & h_{1,s} & \cdots & h_{1,S} \\ & & \vdots & & \\ h_{p,1} & \cdots & h_{p,s} & \cdots & h_{p,S} \\ & & \vdots & & \\ h_{P,1} & \cdots & h_{P,s} & \cdots & h_{P,S} \end{bmatrix}, 1\leqslant s\leqslant S, 1\leqslant p\leqslant P \tag{1}$$

式中$h_{p,s}$为第p个数据包的第s个子载波的值，其中每个h都以复数的形式表示并包含幅度和相位信息。考虑到系统的实时性，SSRF的接收器以500个数据包(约3 s的接收时间)作为一个样本的CSI数据，然后在0.5 s内进行数据预处理、特征提取和分类。不同于ReWiS以300个数据包作为一个样本的数据窗口，SSRF添加至500个数据包，以获得更丰富的信息表示，提供更丰富的时空信息，使模型有更多的数据学习每个动作类别的特征，有助于提高模型对不同动作的区分度；同时模型也更容易学到动作类别的共性特征，从而提高了模型对新数据的泛化性能。

1.3 数据预处理

从硬件设备收集的CSI难免带有噪声和一些不必要的信号放大。为消除特征量纲的不一致性，确保每个特征对模型的贡献基本相同，本文取CSI的原始幅值信息$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}(500\times 57)$，然后对$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}$进行归一化处理得到$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{AN}}$。$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}$由式(2)得到：

$$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}=\left\|\boldsymbol{H}_{\mathrm{r}}\right\| \tag{2}$$

$$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{AN}}=\frac{\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}-\min(\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}})}{\max(\boldsymbol{H}_{\mathrm{r}}^{A})-\min(\boldsymbol{H}_{\mathrm{r}}^{A})}\times(10-1)+1 \tag{3}$$

式中：$\min(\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}})$为$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}$的最小值；$\max(\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}})$为$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}$的最大值。对$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{A}}$的每一个值标准归一化到[0, 1]之间，最后，将归一化后的值通过线性变换，映射到目标范围[1, 10]。

对于机器学习模型，$P\times S$(约500×57)的输入过大。为提高学习算法的性能，采用奇异值分解(SVD)进行最小化，减少时域(数据包)的特征数。即通过降低时域分辨力，保持子载波的分辨力，将500×57的样本降维至57×57。利用SVD将式(2)中的$\boldsymbol{H}_{\mathrm{r}}^{\mathrm{AN}}$的转置进行分解：

$$\left(\boldsymbol{H}_{\mathrm{r}}^{\mathrm{AN}}\right)^{\mathrm{T}}=\boldsymbol{U}\boldsymbol{\Sigma}\boldsymbol{V}^{\mathrm{T}} \tag{4}$$

式中：奇异矩阵$\boldsymbol{U}$的行提供关于子载波的信息；奇异矩阵$\boldsymbol{V}^{\mathrm{T}}$的列提供关于每个数据包的信息；奇异值矩阵$\boldsymbol{\Sigma}$的对角线上的元素则表示每个奇异值对应的重要程度。取$\boldsymbol{H}'=\boldsymbol{U}\boldsymbol{\Sigma}(:,1{:}57)$，将原始矩阵的时域信息投影到子载波方向上。在OFDM系统中，每个子载波对应于一定的频率，因此$\boldsymbol{H}'$的行可看作在频率域上的表示，反映每个子载波的时域信息。具体而言，矩阵$\boldsymbol{H}'$的列包含了每个子载波的信息，而矩阵的行反映了不同时间点上子载波的状态。通过分析$\boldsymbol{H}'$，可更好地理解在不同时间和不同频率上子载波的变化和特征。

最后对$\boldsymbol{H}'$按行计算皮尔逊相关系数(PCC)[15]，得到一个57×57的对称矩阵$\boldsymbol{\rho}$，将此对称矩阵再进行归一化处理得到模型的输入。由此，将原始的幅值数据样本从500×57降维至57×57的矩阵。

1.4 特征提取及分类

在WiFi传感等应用中，收集和标记大型数据集可能具有挑战性，SSRF采用少样本学习的方法，目的是在有限的数据集下快速适应新环境或看不到的环境。

1) ProtoNet

SSRF的特征提取和分类算法采用ProtoNet模型，不同于其他少样本学习算法，ProtoNet以类原型的形式应用了一种简单而有效的归纳偏差，从而实现了很好的Few-Shot学习性能，并降低了网络的复杂性。

ProtoNet的基本原理为：将某一环境下收集的数据集随机抽样分成多个训练任务，每次训练任务随机从各个类别抽取N个样本。假设共有K个类别，则共抽取$K\times N$个样本作为一次训练任务。将K个类别的N个样本分为

支持集和查询集，计算每个类别查询集和支持集的原型表示。原型表示是指通过神经网络将支持集数据和查询集数据映射到特征空间中，如图2所示，X_i是被原型映射的样本，通过嵌入网络(某神经网络)映射到图右侧的嵌入空间内，不同类别的样本映射的位置不同。这样既可避免由于样本的高维性造成的高方差，又可通过深度学习的方式自动提取一些深层次的特征。得到每个类别查询集的原型表示后，通过多次任务的集群，不断计算损失、梯度，更新参数，得到一个嵌入函数$f(x)$。将输入的样本，通过嵌入函数得到其原型表示，通过计算其最近的原型表示距离得到分类结果。ProtoNet的核心思想是：样本围绕每个类的一个原型表示进行集群，即每个类的嵌入式支持样本的平均值。每个类的原型P_k表示为：

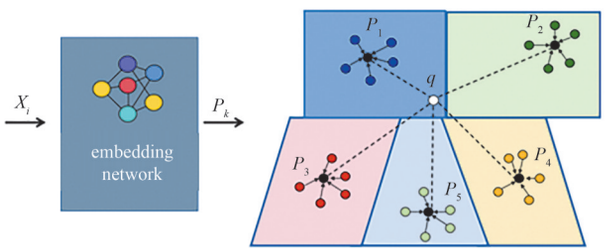

Fig.2 ProtoNet principle diagram
图2 ProtoNet原理图

$$P_k=\frac{1}{|D_k|}\sum_{(s_i,y_k)\in D_k} f(s_i) \tag{5}$$

式中：D_k为某一训练任务，$k\in K$；(s_i,y_k)为支持集的样本(s_i)及其类别(y_k)。

这些原型可用于对查询样本进行分类。对于查询点q，ProtoNet使用嵌入空间中原型表示的欧氏距离再通过Softmax操作，从而生成类别的分布：

$$L(Q_e)=\frac{-1}{|Q_e|}\sum_{(qi,yi)\in Q_e}\log\left[\frac{\exp\left(-\left\|f(q_i)-P_k\right\|^2\right)}{\sum_{k'}\exp\left(-\left\|f(q_i)-P_{k'}\right\|^2\right)}\right] \tag{6}$$

式中：Q_e为查询集；$f(\cdot)$为嵌入函数；$P_{k'}$为所有类别原型的遍历变量。在训练期间，通过随机梯度下降(Stochastic Gradient Descent，SGD)最小化损失函数训练ProtoNet。在测试时，使用从测试事件的支持集计算的邻近原型对样本进行分类。

2) 学习嵌入函数

之前的研究[11]采用了一种MatNet，并使用了两种不同的深度神经网络(Deep Neural Network，DNNs)来计算查询集和支持集。此外，基于注意力的LSTM被用作模型的外部记忆。ReWiS只使用一个深度神经网络，减少了超参数的数量，与ReWiS不同的是，SSRF针对20 MHz带宽环境下的嵌入函数进行压缩，将4个卷积块降至3个，进一步减少了超参数的数量，简化了CSI感知的学习过程，并减少了时间，降低了计算的复杂度。本文的嵌入函数使用具有3个卷积块的卷积神经网络(Convolutional Neural Network，CNN)进行训练。每个块包括一个3×3的卷积、批归一化层、一个ReLU函数，以及在每个块之后应用一个2×2的最大池化层。最后，在第3个块之后建立一个全局平均池化层生成特征嵌入向量。所有的模型都使用Adam[16]的SGD优化器进行训练。学习速率初始化为10^{-3}，每训练2 000次减小1/2。在学习了适当的嵌入模型之后，通过最小化式(5)中的损失函数进行学习。

2 实验过程及结果

2.1 实验环境

本文模拟了比较空旷的浴室环境以及比较繁杂的办公室环境进行算法的预测和性能评估。环境二为办公室环境，该环境面积大小约为10 m×18 m，摆放一张较大的办公桌、主机、显示器、多张椅子以及一些杂物，环境比较复杂，如图3所示。环境一较为空旷，只有两把椅子和一个主机，环境比较简单，用于模拟浴室，如图4所示。

实验中，发射器与接收器相距3 m，离地高度1.2 m。发射器和接收器设备都采用通用软件无线电(Universal Software Radio Peripheral，USRP)的单天线设备，型号为USRP b210。电脑版本为Ubuntu 20.04 LTS，安装了Francesco Gringoli等[17]开发的PicoScenes工具。通过USB3.0控制2个USRP设备的发送和接收，并记录CSI数据包。

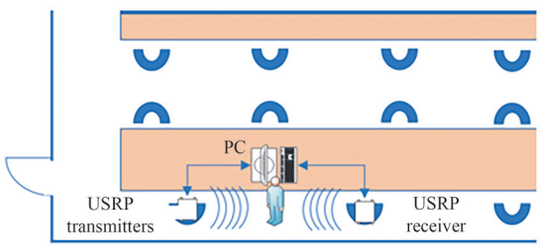

Fig.3 Environment Two
图3 环境二

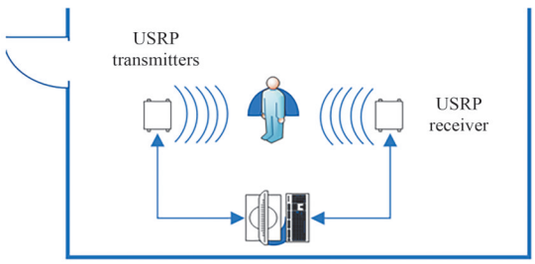

Fig.4 Environment One
图4 环境一

2.2 实验数据集

1) 自制数据集

本文自主采集了5种人类行为，分别是：站–行走、坐–站起、站–跳跃、站–摔倒、无动作。邀请2位志愿者测试这5种动作，在不同时间段，对不同人员分别收集每个环境下每个动作类别的20个样本。每个样本时长为4 s，数据包大小约500个。每个环境下每个类别动作收集40个样本，共收集400个样本。每个样本前后都有约0.5 s的静止时间，如站–行走这一动作就是前后都静止站立0.5 s。详细执行过程如下：假设收集站–行走这一类别动作，收集人员先在发射器和接收器之间区域随机站立，待观察主机显示开始发送接收数据包时，站立静止0.5 s，然后开始随机向不同的方向行走2~3 s，再站立0.5 s后结束一个样本的收集。过程中需仔细观察主机，检查USRP设备间是否正常通信、是否随人员变动而对实时的接收信号强度指示图造成影响。每收集完成一类动作休息0.5 h，再由此反复，保证CSI数据的质量。

2) 公开数据集

实验在ReWiS提供的数据集上进行测试，该数据集收集了3个不同环境(办公室A、办公室B、办公室C)下的2名测试人员的包括跳跃、行走、站立和无动作共4个类别的动作样本，每个动作样本40个。信道带宽有20 MHz及80 MHz。此次实验中，考虑到SSRF是针对20 MHz信道带宽下的CSI数据进行优化，因此只采用该数据集的20 MHz带宽收集的4个类别的CSI数据。

2.3 ProtoNet参数设置

本次实验采用5–way 4–shot和4–way 4–shot的方式，即在自制数据集上，进行五分类任务，每个类别的支持集数量为4，用于构建原型；在自制数据集和公开数据集的结合数据集上，进行四分类任务，每个类别的支持集数量也是4。每类别的查询集选择为3个，采用CNN作为嵌入网络。具体参数设置为：学习率设置为0.001，批大小选择16，距离度量方式选择欧氏距离，训练轮数选择50。

2.4 实验结果及分析

因SSRF主要针对在新环境中的泛化能力，因此本次实验在一个环境中进行模型训练，然后在另一个环境中进行评估。具体步骤是：先在环境一或环境二中训练，然后将训练好的模型在环境二或环境一中进行测试，测试部分只需计算出各个类别预测正确的个数占该类别样本总数的百分比即可。将自制数据集的环境一和环境二记为环境A、环境B，公开数据集的办公室A、办公室B、办公室C记为环境C、环境D、环境E。

表1 环境A训练在环境B的预测结果(单位:%)

Table1 Prediction accuracy of training in environment A on environment B(unit:%)

item	empty	fall	jump	stand	walk
empty	92.95	0	0.25	0	6.80
fall	0	94.80	0	4.90	0.30
jump	3.30	0	87.70	0	9.00
stand	0	8.75	7.15	70.65	13.45
walk	1.00	0	10.75	0.20	88.05

设混淆矩阵中的横轴为预测标签，纵轴为真实标签，同行非对角线上的元素表示预测错误的百分比，通过观察对角线上的数值可以看出该类预测正确的百分比。本文算法在自制数据集上的环境A中训练，在环境B中预测结果，如表1所示。由表1可知，5种行为的新环境预测能力较强，预测准确率的均值达到87%以上。其中，无动作、摔倒这2个动作的识别率达到92%以上，而跳跃和走路这2个动作的预测准确率降低至87%左右，其原因是动作幅度没有摔倒的动作幅度大。站起这一动作的预测准确率明显下降到70%，原因是这一个动作相比于

跳跃和走路都有一定的相似性，且其动作幅度较小，但CSI对大幅度的行为比较敏感，通过浅层次的深度学习模型很难提取到这些不同的细微动作引起的CSI的不同的特征。

由表2可知，算法在公开数据集的平均准确率达到90%，其中无动作和走路的预测结果平均准确率最高达到95%以上，而站起的预测准确率偏低，均值只有70%，其原因已在上文分析，SSRF在公开数据集上的4个行为预测结果的平均准确率相比ReWiS最高的80%，提高了约11个百分点。

表2 SSRF在公开数据集的性能(单位:%)

Table2 Prediction accuracy of SSRF on public datasets(unit:%)

training environment	testing environment	empty	jump	stand	walk	Avg.
A	C	99	99	65	99	91
A	D	100	96	83	94	93
A	E	100	85	75	99	89
D	E	99	99	72	99	92

综上所述，本文所提出的SSRF在2个数据集上都表现出优秀的泛化能力和识别性能，在模拟公共浴室环境的五分类预测平均准确率达到87%，特别在跌倒这一危险动作的预测平均准确率达到94%。因此，可认为SSRF在检测老年人在公共浴室的动作识别是可靠且灵活高效的。

由表3可以看出，传统的LSTM在公开数据集上的非跨域识别率和ReWiS以及本文的算法都相差不大，本文所提的SSRF在添加一个识别类别(摔倒)的前提下保持了ReWiS在20 MHz带宽下的一个接收机、一个天线收集模式下的识别率。

表3 不同算法在公开数据集和在自制数据集的非跨域识别率对比(单位:%)

Table3 Comparison of non-cross-domain recognition rates of different algorithms on public datasets and self-collected datasets(unit:%)

model	public datasets						self-collected datasets					
	empty	fall	jump	stand	walk	Avg.	empty	fall	jump	stand	walk	Avg.
LSTM	99	–	81	96	96	93	99	–	92	99	80	93
ReWiS	100	–	89	93	98	95	96	–	88	85	88	89
SSRF	100	–	93	90	96	95	96	99	87	88	86	90

在跨域识别方面，由表4可以观察到LSTM的跨域识别表现非常差，表现出高度类别偏见。SSRF相比于ReWiS在2个数据集的识别率上都有提升，平均提升9个百分点。

表4 不同算法在公开数据集和自制数据集的跨域识别率对比(单位:%)

Table4 Comparison of cross-domain recognition rates of different algorithms on public datasets and self-collected datasets(unit:%)

model	public datasets						self-collected datasets					
	empty	fall	jump	stand	walk	Avg.	empty	fall	jump	stand	walk	Avg.
LSTM	0	–	0	95	13	27	0	–	0	88	0	22
ReWiS	100	–	74	87	59	80	96	–	84	60	83	80
SSRF	100	–	96	83	94	93	93	95	88	70	88	87

本文算法在2个数据集上的跨域的平均识别率都较高，得到最佳识别性能。在公开数据集中，相比于ReWiS的平均识别率80%提升了13个百分点；在自制数据集中添加一个识别类别的前提下，平均识别率提升7个百分点。

由表5可以看出，SSRF无论是模型的参数量、训练时长和推理时长都少于ReWiS，且对每个样本从预处理到分类的总时长不足0.3 s。由此可以证明本文所提出的算法具有实时性的较强泛化能力。可用于基于CSI的老年人公共浴室场景下的人体安全识别。

表5 不同算法在自制数据集上的训练和识别时间对比

Table5 Comparison of training and recognition time for different algorithms on self-collected datasets

item	LSTM	ReWiS	SSRF
number of parameters	1 375 236	111 936	37 392
training time for all samples/s	11.76	33.12	26.80
testing time per sample/s	0.000 200	0.000 149	0.000 104

3 结论

本文所提出的一种针对老年人公共浴室场景下的CSI行为识别算法，在公开数据集以及自制数据集上都进行

了评估。实验结果证明，SSRF针对20 MHz带宽的单接收器单天线的模式下优化了ReWiS，加大了数据包窗口并减少嵌入网络的层数，使算法的跨域识别性能明显提高。尤其在对老年人群体的安全方面上，跨域的跌倒动作识别率达到95%。这在公共浴室等隐私场景的安全问题上有着实际应用。未来研究中将考虑更多的动作类别。

参考文献：

[1] 杜鹏.中国人口老龄化现状与社会保障体系发展[J]. 社会科学文摘, 2023(7):8-10. (DU Peng. The current situation of population aging and the development of social security system in China[J]. Digest of Social Sciences, 2023(7):8-10.

[2] 牟效乾,陈小龙,苏宁远,等.基于时频图深度学习的雷达动目标检测与分类[J]. 太赫兹科学与电子信息学报, 2019,17(1):105-111. (MU Xiaoqian, CHEN Xiaolong, SU Ningyuan, et al. Radar detection and classification of moving target using deep convolutional neural networks on time-frequency graphs[J]. Journal of Terahertz Science and Electronic Information Technology, 2019,17(1):105-111.) DOI:10.11805/TKYDA201901.0105.

[3] CHEN Kaixuan,YAO Lina,ZHANG Dalin,et al. A semisupervised recurrent convolutional attention model for human activity recog-nition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(5): 1747-1756. DOI: 10.1109/TNNLS.2019.2927224.

[4] HUA Minjie, NAN Yibing, LIAN Shiguo. Falls prediction based on body keypoints and seq2seq architecture[C]// 2019 IEEE/CVF International Conference on Computer Vision Workshop(ICCVW). Seoul, Korea(South): IEEE, 2019: 1251-1259. DOI: 10.1109/ICCVW.2019.00158.

[5] FENG Qi, GAO Chenqiang, WANG Lan, et al. Spatio-temporal fall event detection in complex scenes using attention guided LSTM[J]. Pattern Recognition Letters, 2020,130(1):242-249. DOI:10.1016/j.patrec.2018.08.031.

[6] 潘浩. 基于WiFi的人体动作识别方法研究[D]. 长沙:湖南大学, 2019. (PAN Hao. Research on human action recognition methods based on WiFi[D]. Changsha,China:Hunan University, 2019.)

[7] 程汉妮. 基于信道状态信息的跌倒检测算法研究[D]. 武汉:华中科技大学, 2020. (CHENG Hanni. Research on fall detection algorithms based on channel state information[D]. Wuhan,China:Huazhong University of Science and Technology, 2020.)

[8] DING Jianyang, WANG Yong. WiFi CSI-based human activity recognition using deep recurrent neural network[J]. IEEE Access, 2019(7):174257-174269. DOI:10.1109/ACCESS.2019.2956952.

[9] CHEN Zhenghua,ZHANG Le,JIANG Chaoyang,et al. WiFi CSI based passive human activity recognition using attention based BLSTM[J]. IEEE Transactions on Mobile Computing, 2019, 18(11):2714-2724. DOI:10.1109/TMC.2018.2878233.

[10] WANG Fangxin,GONG Wei. On spatial diversity in WiFi-based human activity recognition:a deep learning-based approach[J]. IEEE Internet of Things Journal, 2019,6(2):2035-2047. DOI:10.1109/JIOT.2018.2871445.

[11] SHI Z G,CHENG Q Q,ZHANG J A,et al. Environment-robust WiFi-based human activity recognition using enhanced CSI and deep learning[J]. IEEE Internet of Things Journal, 2022,9(24):24643-24654. DOI:10.1109/JIOT.2022.3192973.

[12] MA Xiaorui, ZHAO Yunong, ZHANG Liang, et al. Practical device-free gesture recognition using WiFi signals based on metalearning[J]. IEEE Transactions on Industrial Informatics, 2020,16(1):228-237. DOI:10.1109/TII.2019.2909877.

[13] BAHADORI N, ASHDOWN J, RESTUCCIA F. ReWiS:reliable Wi-Fi sensing through few-shot multi-antenna multi-receiver CSI learning[J/OL]. arXiv.2201.00869, 2022. DOI:10.48550/arXiv.2201.00869.

[14] SNELL J, SWERSKY K, ZEME R. Prototypical networks for few-shot learning[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach,CA,USA:ACM, 2017:4080-4090.

[15] HAN J,PEI J,KAMBER M. Data mining:concepts and techniques[M]. 3rd ed. San Francisco:Morgan Kaufmann, 2011.

[16] KINGMA D P,BA J. Adam:a method for stochastic optimization[J/OL]. arXiv:1412.6980, 2014. DOI:10.48550/arXiv.1412.6980.

[17] GRINGOLI F,SCHULZ M,LINK J,et al. Free Your CSI:a channel state information extraction platform for modern Wi-Fi chipsets[C]// The 13th International Workshop on Wireless Network Testbeds, Experimental Evaluation & Characterization(WiNTECH'19). New York,NY,USA:ACM, 2019:21-28. DOI:10.1145/3349623.335547.

作者简介：

李星星(1990-)，男，博士，讲师，主要研究方向为信号处理、集成电路设计与实现.email:wyuxxli@163.com.

黄景涛(2000-)，男，在读硕士研究生，主要研究方向为信号处理和机器学习算法、人工智能.

陆许明(1985-)，男，博士，高级工程师，主要研究方向为无线通信、物联网应用.

陈　翔(1980-)，男，博士，教授，主要研究方向为5G/6G移动通信与物联网、卫星通信.