

基于残差网络的FMCW雷达人体行为识别

罗金燕, 常俊, 吴彭, 许妍, 卢中奎

引用本文

罗金燕, 常俊, 吴彭, 许妍, 卢中奎. 基于残差网络的FMCW雷达人体行为识别[J]. 计算机科学, 2023, 50(11A): 220800247-6.

LUO Jinyan, CHANG Jun, WU Peng, XU Yan, LU Zhongkui. FMCW Radar Human Behavior Recognition Based on Residual Network [J]. Computer Science, 2023, 50(11A): 220800247-6.

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)

[一种融合CNN和Swin Transformer的医学显微图像分割模型](#)

Medical Microscopic Image Segmentation Model Based on CNN Structure and Swin Transformer
计算机科学, 2023, 50(11A): 230200119-8. <https://doi.org/10.11896/jsjcx.230200119>

[多流融合的轻量级图卷积行为识别算法](#)

Lightweight Graph Convolution Action Recognition Algorithm Based on Multi-streamFusion
计算机科学, 2023, 50(11A): 220800147-6. <https://doi.org/10.11896/jsjcx.220800147>

[多维特征激励网络用于视频行为识别](#)

Multi-dimensional Feature Excitation Network for Video Action Recognition
计算机科学, 2023, 50(11A): 230300115-8. <https://doi.org/10.11896/jsjcx.230300115>

[基于元学习和注意力机制的用户行为识别研究](#)

Human Activity Recognition with Meta-learning and Attention
计算机科学, 2023, 50(8): 193-201. <https://doi.org/10.11896/jsjcx.220900124>

[结合残差与自注意力机制的图卷积小样本图像分类网络](#)

Graph Neural Network Few Shot Image Classification Network Based on Residual and Self-attention Mechanism
计算机科学, 2023, 50(6A): 220500104-5. <https://doi.org/10.11896/jsjcx.220500104>

基于残差网络的 FMCW 雷达人体行为识别

罗金燕¹ 常俊^{1,2} 吴彭¹ 许妍¹ 卢中奎¹

1 云南大学信息学院 昆明 650500

2 云南省高校物联网技术及应用重点实验室 昆明 650500

(blxszejy@163.com)

摘要 现有的基于调频连续波(Frequency Modulated Continuous Wave,FMCW)雷达的人体行为识别方法大多采用深度卷积神经网络完成,但随着网络加深,会出现网络训练难度增大或特征提取不充分的问题。针对此问题,提出一种基于残差网络的 FMCW 雷达人体行为识别方法。通过对雷达回波数据分析处理得到每种行为的微多普勒时域谱图,将其作为识别模型的特征。将卷积块注意模块(Convolutional Block Attention Module,CBAM)引入残差网络的残差块中构建识别模型,CBAM 关注谱图的颜色变化情况和谱图中每种颜色的位置信息,同时引入自适应归一化和改变网络输入部分的卷积结构提高模型的特征提取能力。实验验证,该模型的平均识别准确率可达 98.17%,对于微多普勒特征相似的行为,识别准确率可达 95%,证明了该模型具有较好的识别性能。

关键词: FMCW 雷达;微多普勒谱图;行为识别;残差网络;卷积块注意模块

中图分类号 TN959

FMCW Radar Human Behavior Recognition Based on Residual Network

LUO Jinyan¹, CHANG Jun^{1,2}, WU Peng¹, XU Yan¹ and LU Zhongkui¹

1 College of Information Science & Engineering, Yunnan University, Kunming 650500, China

2 University Key Laboratory of Internet of Things Technology and Application, Kunming 650500, China

Abstract For the existing FMCW radar human behavior recognition methods are mostly done by deep convolutional neural networks, however, with the deepening of the network, there will be problems such as the difficulty of network training will increase or the feature extraction will be insufficient. A method for FMCW radar human behavior recognition based on residual network is proposed. The micro-Doppler time-domain spectrogram of each behavior is obtained by analyzing and processing the radar echo data, which is used as the classification feature of the recognition model. The convolutional block attention module(CBAM) is introduced into the residual block of the residual network to build a recognition model. CBAM pays attention to the color change of the spectrogram and the position information of each color in the spectrogram, while introducing adaptive Matching normalization and changing the convolutional structure of the input part of the network improves the feature extraction ability of the model. Through experimental verification, the average recognition accuracy of the model can reach 98.17%, and for behaviors with similar micro-Doppler features, the recognition accuracy can reach 95%, which prove that the model has good recognition performance.

Keywords FMCW radar, Micro-Doppler spectrograms, Behavior recognition, Residual networks, Convolutional block attention module

1 引言

人体行为识别一直是一个活跃的研究领域,有着广阔的应用前景,在医疗保健、智能家居和其他室内监控的应用中具有很大潜力^[1-3]。由于雷达回波可以反映人体运动时身体各个部位的多普勒频率随时间的变化,因此基于雷达的人体行为识别变得越来越受欢迎^[4]。与光学传感器不同,雷达感应不受光或其他不断变化的环境条件影响^[5],并且雷达传感器对运动目标敏感,可以捕获运动目标的距离和速度信息。相较于视觉传感器而言,雷达传感器无需发送目标的照片或视频,具有保护隐私的作用;此外,雷达传感器不是穿戴式传感器,甚至可以通过墙壁感知,因此将雷达传感器作为人体行为

识别的工具是基于现实生活场景的最佳选择^[6]。雷达传感器有很多种,如激光雷达^[7]、超宽带(Ultra-Wide Band,UWB)雷达^[8]和调频连续波(Frequency Modulated Continuous Wave,FMCW)雷达^[9]等。FMCW 雷达硬件处理相对简单,适合数据采集和进行数字信号处理。因此,本文中使用 FMCW 雷达进行人体行为识别的研究。

在 FMCW 雷达人体行为识别方面,与支持向量机(Support Vector Machine,SVM)等机器学习算法相比^[10],之前的深度学习工作在对 12 种行为进行分类时取得了更好的结果^[11]。深度学习技术的吸引力主要在于它可以自动提取特征,无需人工干预。文献[12]将深度卷积神经网络(Deep Convolutional Neural Networks,DCNN)用于雷达微多普勒特

征的人体检测和活动分类,在人体检测中获得了较高的检测精度,但在活动分类的准确率上有待提高;文献[13]利用 77 GHz 的 FMCW 雷达采集医院患者的多普勒特征,并将三层的卷积神经网络(Convolutional Neural Network, CNN)作为分类模型对每个患者的行为进行分类,获得了较好的分类准确率,但在模型训练时只收集了一名患者的数据,训练数据集不具有多样性;文献[14]基于 CNN 提出一种利用线核卷积网络(Line Kernel Convolutional Neural Network, LKCNN)直接处理 FMCW 雷达基带数据样本的室内坠落检测方法,算法获得了较高的检测精度,但存在检测动作单一的问题;文献[15]提出一种混合神经网络模型,用于探索雷达回波数据的多域融合,利用这种混合模型,通过多域特征融合来获取更丰富的特征,可以获得较好的识别准确率,但是对难以区分的动作识别准确率较低。可见,之前的大多数研究工作都采用深层结构或混合结构进行基于雷达微多普勒特征的人体行为分类和识别,但是随着网络深度的加深,会出现网络性能反而下降的问题。

针对上述问题,本文使用格拉斯哥大学公开的数据集[16]。该数据集的收集来自不同的测试场景,测试者是多名不同年龄、不同身高、不同性别的志愿者,数据集具有多样性。同时引入 He 等[17]提出的残差网络(Residual neural Network, ResNet)用于 FMCW 雷达的人体行为识别,提取雷达回波数据的微多普勒时域谱图作为分类特征。实验验证,该方法能够达到较高的分类准确率,并且对于难以区分的动作,识别准确率也较好,因此本文所提识别方法具有较好的性能。

2 雷达信号处理

2.1 FMCW 雷达信号模型

FMCW 雷达发射一种称为“Chirp”的信号,Chirp 是一种正弦信号,其频率随时间线性增加。图 1 所示为发射天线和接收天线的 Chirp 信号。




图 1 Chirp 信号(频率作为时间的函数)

Fig. 1 Chirp signal(with frequency as a function of time)

图 2 为 FMCW 雷达主射频组件的简化框图。




图 2 FMCW 雷达框图

Fig. 2 Block diagram of FMCW radar system

合成器生成 Chirp 信号,该信号由发射天线发射。发射信号[18]可以表示为:

$$x_T(t) = A_T \cos(2\pi f_c t + \pi\beta t^2) \quad (1)$$

其中, A_T 是发射功率, f_c 是 Chirp 的起始频率, β 是调频斜率。 $\beta = \frac{B}{T_c}$, B 表示调频带宽, T_c 是 Chirp 的持续时间。当雷达监测到运动目标时,发射信号被目标反射后由接收天线接收,接收到的信号[18]可以表示为:

$$x_R(t) = A_T \cos(2\pi f_c(t - t_d) + \pi\beta(t - t_d)^2) \quad (2)$$

其中, $t_d = 2R(t)/c$, 为接收天线接收到回波的时间延迟, $R(t)$ 是目标和雷达的距离。混频器将发射信号和接收信号合并到一起,生成中频信号。中频信号由雷达设备中的模数转换器(ADC)转换为数字信号,以便进一步处理。然后,通过数字信号处理(DSP)获得拍频信号。拍频信号[18]可以表示为:

$$y(t) = A_R e^{j[2\pi f_b t + \varphi_b(t)]} \quad (3)$$

其中, A_R 为接收信号功率; f_b 表示拍频,结合图 1 及信号分析, $f_b = 2BR(t)/(cT_c)$ 。假设雷达采集板一共采集了 M 个 Chirp, 每个 Chirp 上有 N 个采样点,可将拍频信号视为 $N \times M$ 的数据矩阵,其行和列分别代表慢时间变量和快时间变量,则 I/Q 采样后的拍频信号可以被表示为:

$$y[n, m] = A_R e^{j(2\pi f_b n T_f + \frac{2\pi}{T_s} R(nT_f + mT_s))} \quad (4)$$

其中, n 表示第 n 个采样点, m 表示第 m 个 Chirp, T_f 表示快时间采样间隔, T_s 表示慢时间采样间隔。

2.2 微多普勒特征提取

FMCW 雷达收集到的回波数据是以二进制的形式存储的,将数据重排为矩阵,矩阵的每一行代表一个 Chirp,一行中的每个点都是混频信号的采样点,由于一个 Chirp 中采样点的间隔远小于每个 Chirp 之间的间隔,即矩阵中左右两个点的时间间隔小于上下两个点的时间间隔,所以矩阵的行也叫作快时间维,列也叫作慢时间维。首先对数据矩阵沿着快时间维做快速傅里叶变换(Fast Fourier Transform, FFT),将矩阵换成距离单元。受试环境中存在的静态物体或与人体行为无关的目标,都会产生雷达回波信号,将这些无关的回波定义为杂波。MTI 滤波器可通过对多组脉冲回波的同一个距离单元加权求和,得到一个输出,抑制静态目标和慢速杂波。应用 MTI 滤波器抑制静态杂波信息可得到雷达回波数据的距离像信息,根据距离像信息可知运动目标主要集中在距离单元为 $0 \sim 30$ 的范围内,因此可根据受试者和雷达之间的距离选择距离单元范围在 $10 \sim 30$ 的样本值,应用短时傅里叶变换(Short Time Fourier Transform, STFT)得到微多普勒时域谱图。STFT 的计算过程为:

$$STFT(f, k) = \sum_{n=-\infty}^{+\infty} x(n) \omega(n-k) e^{-j2\pi f n} \quad (5)$$

其中, $\omega(n)$ 为 STFT 使用的窗函数,这里采用汉明窗。以行走为例,微多普勒特征获取流程如图 3 所示。

图 4 分别给出了喝水、跌倒、捡起物品、坐下、站起来和行走 6 种行为的微多普勒谱图。微多普勒谱图可以观察身体不同部位较重和较轻的运动,光谱图中较亮的黄色和红色表示较强烈的运动,浅蓝色表示较轻的运动。与自然图像相比,雷达谱图本质上是雷达信号在时域上的图像表示,图像中的振荡表明了这些运动,当人体运动时,雷达将检测人体的径向速度,反射频率发生变化,从而使多普勒频移。多普勒频移信息包含人体各个部位的速度信息。当人们做不同的动作时,每个身体部位的速度都是不同的,从而表明通过利用这些微多普勒谱图来识别人体行为的可行性。但主要的挑战是不同活动模式之间的相似性会导致有些行为难以区分,从而导致识

别准确率不理想。例如,从6种行为的微多普勒谱图来看,喝水和捡起物品具有相似的特征。针对具有相似特征的行为会

出现难以区分的问题,本文采用 ResNet18 网络结构作为基本框架对这些行为的微多普勒谱图进行分类。




图3 微多普勒特征获取流程

Fig. 3 Micro-Doppler feature acquisition process

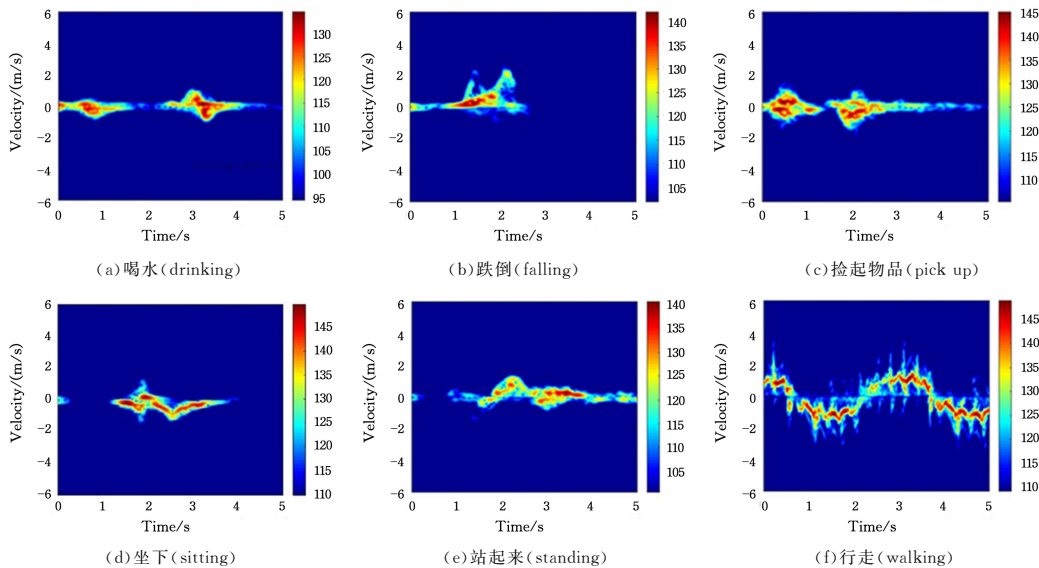


图4 每个活动的微多普勒谱图

Fig. 4 Micro-Doppler spectrogram for each activity

本文采用 ResNet 的主要原因是卷积网络的空间特性有助于在考虑附近信号位置的情况下提取局部特征,而不是仅从单个位置提取。此外,它将提取的频率信息保留为网络各层的特征^[19],因为卷积网络对不同频率的信号具有尺度不变性^[20]。ResNet 在卷积网络的基础上增加了跳连接,允许原始信息直接传到后面的层中。原始微多普勒谱图中的信息对于有效区分每种行为至关重要,采用 ResNet 作为分类网络,不仅可以更好地进行特征提取,也可以有效解决神经网络随着深度增加而丢失原始信息导致

特征提取不充分的问题。

3 残差网络模型

本文构建了如图 5 所示的人体行为识别模型。为了降低网络训练的复杂度,模型的输入是被裁剪为 256×256 的微多普勒谱图,谱图特征提取部分由 3 个卷积核为 3 的小卷积层加最大池化层以及 4 个 $[2, 2, 2, 2]$ 结构的残差块 (Residual Block, RB) 构成。输出分类部分由全局平均池化层和全连接层组成。

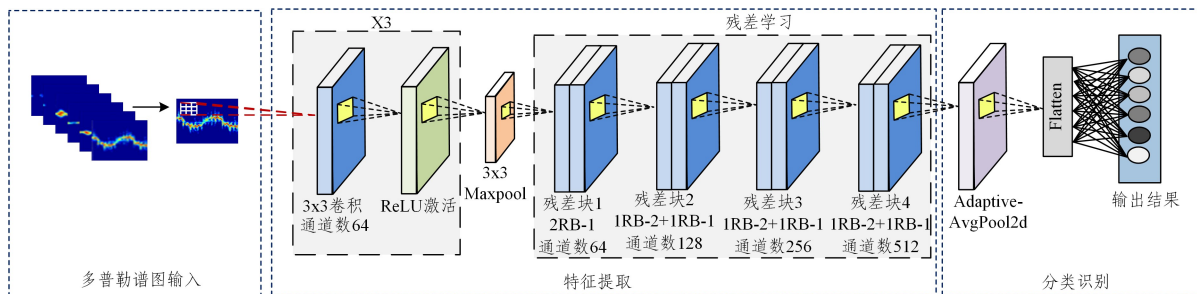


图5 残差网络模型

Fig. 5 Residual network model

将 ResNet18 网络的输入结构由卷积核为 7 的大卷积层换成 3 个 3×3 的小卷积层,以减少网络的参数量,并且在每个小卷积层之后加入了激活层,用 3 个非线性激活层代替

单一的激活层,提高模型的特征学习能力。

RB 结构如图 6 所示,它有两层,可以表示为:

$$F = W_2 \sigma(W_1 x)$$

(6)

其中, σ 代表非线性激活函数 ReLU。通过跳连接的输出可以表示为:

$$H(x) = F(x, \{W_i\}) + x \quad (7)$$

这里为了保证输入和输出维度一致,需要在跳连接变换时对 x 做一个线性变换,可以表示为:

$$H(x) = F(x, \{W_i\}) + W_s x \quad (8)$$

RB-2 相较于 RB-1,在跳连接部分增加了一个卷积核大小为 1 的卷积层对输入做线性变换。微多普勒时域谱图中包含人体运动部位的速度信息,并且每种运动信息具有一定的变化规律,在 RB 的输出部分添加卷积块注意模块(Convolutional Block Attention Module, CBAM)。CBAM 是一个结合了通道注意模块(Channel Attention Module, CAM)和空间注意模块(Spatial Attention Module, SAM)的轻量级注意机制模块。在这里,通道注意力模块关注输入谱图的颜色变化情况,空间注意力模块关注谱图中每种颜色的位置信息,将通道注意力模块和空间注意力模块结合,建立每种行为的运动信息之间的联系,使提取的特征更有效,达到提升模型性能的目的。此外,ResNet18 的残差结构中使用的归一化方法是批量归一化(Batch Normalization, BN),但是 BN 对于 batch size 的大小比较敏感,较小的 batch size 会影响模型的性能,较大的 batch size 对设备显存的要求又较高。考虑这一问题,在 RB 中使用自适应归一化方法(Switchable Normalization, SN),SN 在不依赖 batch size 的同时对各个维度统计有很好的鲁棒性。使用 4 个 $[2, 2, 2, 2]$ 结构的 RB 加深网络深度,提高模型对微多普勒特征的提取能力。

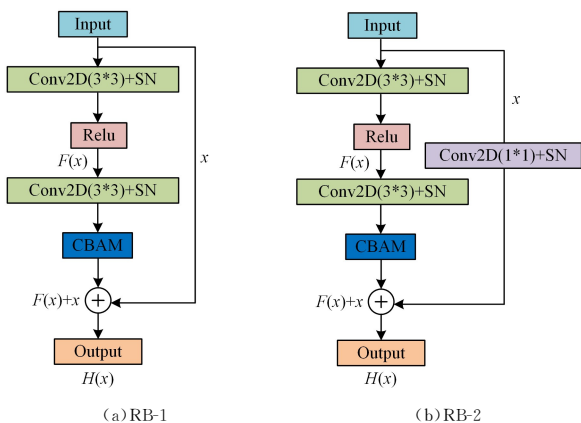


图 6 RB 结构

Fig. 6 Residual block structure

网络模型输出部分的全局平均池化层对每一个通道的特征图的所有像素求平均值,得到一个新的 1×1 的特征图,最终输出识别结果。全局平均池化层可以降低网络的参数量,防止网络过拟合。

4 实验验证

4.1 数据集介绍

实验数据来自格拉斯哥大学公开的数据集^[16]。数据由工作在 5.8GHz,带宽为 400MHz 的 FMCW 雷达收集得到,数据集在 9 个不同的地方收集了 56 名以上受试者的 6 种不同行为,每个受试者对同一种行为重复 3 次左右。以前的雷达数据采集仅在室内实验室环境中进行,该数据集的收集场景包括开放环境和实验室。收集到每种行为的数据样本量如

图 7 所示,出于安全考虑,跌倒这种行为仅对部分受试者进行了采集。




图 7 数据集中每种行为的样本数直方图

Fig. 7 Histogram of the number of samples for each behavior in datasets

4.2 识别模型参数设置

仿真程序在 NVIDIA GeForce RTX 2080 上进行,使用的深度学习框架为 Pytorch,运行环境为 Python3.8。采用 Adam 优化器更新网络训练参数,因为 Adam 优化器具有最小的权重更新,可以在训练阶段更好地学习。模型训练 100 个 Epoch,学习率根据经验值进行尝试,分别设为 0.1, 0.01, 0.001, 0.0001, 训练曲线如图 8 所示,可见学习率设置为 0.0001 时模型易收敛,且较稳定。本文模型参数设置如表 1 所列。




图 8 学习率训练对比图

Fig. 8 Chart of learning rate training comparison

表 1 模型参数设置

Table 1 Model parameter setting

Conv	$3 \times 3 \times 3, 64, \text{stride}=2$	256×256
Maxpool	$3 \times 3, 64, \text{stride}=1$	128×128
Block1(2RB-1)	$\begin{bmatrix} (3, 1, 64) \\ (3, 1, 64) \end{bmatrix}$	56×56
Block2(RB-2+RB-1)	$\begin{bmatrix} (3, 2, 128) \\ (3, 1, 128) \end{bmatrix}$	28×28
Block3(RB-2+RB-1)	$\begin{bmatrix} (3, 2, 256) \\ (3, 1, 256) \end{bmatrix}$	14×14
Block4(RB-2+RB-1)	$\begin{bmatrix} (3, 2, 512) \\ (3, 1, 512) \end{bmatrix}$	7×7
Avgpool	—	1×1
Softmax	—	6

表 1 中,每个 Block 包含 2 个 RB。例如 Block2 中 $\begin{bmatrix} (3, 2, 128) \\ (3, 1, 128) \end{bmatrix}$ 代表一个 RB 中的参数,其中, $(3, 2, 128)$ 表示 Block2 中第一个卷积层的卷积核为 3,步长为 2,通道数为 128; $(3, 1, 128)$ 表示 Block2 中第二个卷积层的卷积核为 3,步长为 1,通道数为 128。因为第一个卷积层的步长为 2,表示会将输入图片的尺寸减小一半,这会使得残差模块输入大小与输出大小不一致,因此需要使用在跳连接部分加入了步长为 2、卷积核大小为 1 的 RB-2,使得该 RB 中的输入与输出匹配。

4.3 实验结果及分析

4.3.1 基于模型的结果

将数据集按 8:2 的比例随机划分为训练集和测试集,训练曲线如图 9 所示。由图可见,随着 epoch 的增多,训练数据和测试数据的准确率都提高了,训练曲线表明模型在新的测试图像中学习效果更好;并且该模型在训练了大概 25 个 epoch 之后准确率趋于稳定,表明该模型容易收敛。




图 9 模型训练曲线图

Fig. 9 Model training curve

图 10 给出了 6 种活动在该模型中分类的混淆矩阵,横轴为预测值,纵轴为真实值。在行走和跌倒这两种具有显著多普勒特性的行为上获得了 100% 的识别准确率;对捡起物品和站起来两种活动识别率较低,并且两种活动之间存在误判的情况,主要原因是两种活动的运动形式和运动方向相似,因此容易产生混淆;捡起东西和拿杯子喝水两种活动可以归为弯曲类运动,因为两者都有手和肘部的运动,但由于两种运动的速度有差异,喝水有停顿的时间,因此弯曲类行为被误判的概率较小。该模型最终的平均分类准确率可达 98.17% 左右,对微多普勒特征相似的行为最低识别准确率也可达 95%,因此可以认为该模型具有较好的识别能力。

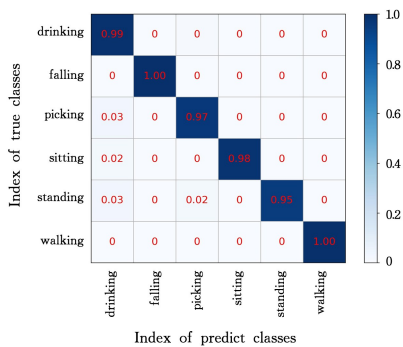


图 10 混淆矩阵

Fig. 10 Confusion matrix

为了验证本文在 ResNet18 基础上改进部分的效果,设置了 3 个变体:变体一为归一化方法使用 BN;变体二为无 CBAM 注意力模块;变体三为特征提取输入部分采用一个卷积核为 7 的大卷积块。每种方法对应每个动作的识别准确率如图 11 所示,可见改进部分不仅提升了除行走之外的活动

识别准确率,并且在多普勒特性相似的活动中识别准确率差异很小,说明该模型对于具有微多普勒特征的人体行为识别的鲁棒性较好。网络的参数量和浮点运算量决定模型的性能。网络浮点运算量和参数量可分别表示为:

$$FLOPs = \sum_{l=1}^D M_l^2 \cdot K_l^2 \cdot C_{l-1} \cdot C_l \quad (9)$$

$$Params = \sum_{l=1}^D K_l^2 \cdot C_{l-1} \cdot C_l \quad (10)$$

其中, M 表示每个卷积输出特征的边长, K 表示卷积核尺寸, C_{l-1} 表示 $l-1$ 个卷积层的输出通道数, C_l 表示 l 个卷积层的输出通道数。

$$M = (X - K + 2 * Padding) / Stride + 1 \quad (11)$$

结合表 1 模型参数设置可计算出几种模型的计算复杂度,如表 2 所列。其中,Resnet18 仅使用了普通残差块进行分类,运算量相较于其他模型较小,但是分类准确率也更低。本文所用模型与其他模型运算量差异不大,但平均识别准确率明显高于其他模型。因此,本文所提模型具有较好的性能。




图 11 改进部分识别准确率

Fig. 11 Recognition accuracy of improved part

表 2 开销对比

Table 2 Cost comparison

方法	Params	FLOPs	平均准确率/%
本文模型	1 1761 976	35 612 184 960	98.17
Resnet18	11 689 512	2 382 254 592	95.50
归一化方法为 BN	11 769 656	35 738 014 080	96.83
无 CBAM	11 761 192	35 595 125 120	96.5
输入采用 7×7 卷积块	11 768 872	34 325 126 784	95.3

4.3.2 与其他行为识别模型比较

表 3 列出了其他模型的人体行为识别结果,将本文的结果与这些模型比较。本文的模型在分类准确率上均超过了之前的识别方法。考虑到室内和室外数据采集的真实环境,本文采用多人参与的室内和室外采集的数据集,并与最近使用相同数据集的模型进行比较。有作者融合时间-距离域频谱、距离-多普勒域频谱和时间-多普勒域频谱三域特征,用 CNN-LSTM 组合网络作为分类模型,获得了 94.25% 的准确率^[15]。也有作者从多普勒谱图的各个颜色通道提取特征,CNN 作为学习网络,获得了 97.58% 的准确率^[21]。本文将微多普勒谱图作为输入特征,并将改进的 ResNet18 作为分类模型,分类准确率得以提高。

表 3 本文模型与其他模型比较

Table 3 Comparison of the proposed model and other models

雷达类型	行为类型	输入特征	受试者数量	深度神经网络类型	分类准确率/%
连续波雷达 ^[22]	4-室内	去噪谱图灰度图	—	堆叠式自动编码器	87.00
FMCW 雷达 ^[23]	12-室内	频谱图+物理特征	11	深度卷积自动编码器	94.20
FMCW 雷达 ^[15]	6-(室内+室外)	时间-距离、时间-多普勒、距离-多普勒三域融合	56	CNN+LSTM	94.25
FMCW 雷达 ^[24]	7-室内	距离-多普勒谱图	20	CNN	95.00
FMCW 雷达 ^[21]	6-(室内+室外)	频谱图 R+G+B 三通道	56	CNN	97.58
FMCW 雷达	6-(室内+室外)	多普勒谱图	56	本文模型	98.17

结束语 本文提出了一种基于微多普勒特征的 FMCW 雷达人体行为识别方法。该方法通过对雷达回波数据分析处理得到每种行为的微多普勒谱图,将行为映射成为雷达信号在时域上的图像;并使用加入了 CBAM 注意力模块的 ResNet18 对这种具有物理意义的图像分类,平均分类准确率可达 98.17%,且对于具有相似微多普勒特征的行为分类准确率也较好,表明本文的分类模型在 FMCW 雷达人体行为识别方面具有较好的性能。本文模型虽然可以获得较理想的识别准确率,但在模型的复杂度方面需要进一步改善。

参考文献

- [1] LI C, LUBECKE V M, BORIC-LUBECKE O, et al. A review on recent advances in Doppler radar sensors for noncontact health-care monitoring [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2013, 61(5): 2046-2060.
- [2] LI H, SHRESTHA A, HEIDARI H, et al. Magnetic and radar sensing for multimodal remote health monitoring [J]. *IEEE Sensors Journal*, 2018, 19(20): 8979-8989.
- [3] WANG P, LIU H, WANG L, et al. Deep learning-based human motion recognition for predictive context-aware human-robot collaboration [J]. *CIRP annals*, 2018, 67(1): 17-20.
- [4] LI X, HE Y, JING X. A survey of deep learning-based human activity recognition in radar [J]. *Remote Sensing*, 2019, 11(9): 1068.
- [5] CHEN Z, LI G, FIORANELLI F, et al. Personnel recognition and gait classification based on multistatic micro-Doppler signatures using deep convolutional neural networks [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5): 669-673.
- [6] NKWARI P, SINHA S, FERREIRA H. Through-the-wall radar imaging: A review [J]. *IETE Technical Review*, 2018, 35(6): 631-639.
- [7] TAN Z G, LU M, HU Y P, et al. LIDAR target recognition based on point cloud-model matching [J]. *Computer Engineering & Science*, 2012, 34(4): 32-36.
- [8] LAI J L, YANG Z C, BAO R H, et al. Daily motion classification based on ultra-wideband radar [J]. *Radar Science and Technology*, 2021, 19(3): 265-270.
- [9] JANKIRAMAN M. *FMCW Radar Design* [M]. Artech House, 2018.
- [10] KIM Y, LING H. Human activity classification based on micro-Doppler signatures using a support vector machine [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(5): 1328-37.
- [11] SEYFIOĞLU M S, ÖZBAYOĞLU A M, GÜRBÜZ S Z. Deep Convolutional Autoencoder for Radar-Based Classification of Similar Aided and Unaided Human Activities [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2018, PP(4): 1709-1723.
- [12] KIM Y, MOON T. Human detection and activity classification based on micro-Doppler signatures using deep convolutional neural networks [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 13(1): 8-12.
- [13] JIN F, ZHANG R, SENGUPTA A, et al. Multiple patients behavior detection in real-time using mmWave radar and deep CNNs [C] // *Proceedings of the 2019 IEEE Radar Conference (RadarConf)*. IEEE, 2019.
- [14] WANG B, GUO L, ZHANG H, et al. A millimetre-wave radar-based fall detection method using line kernel convolutional neural network [J]. *IEEE Sensors Journal*, 2020, 20(22): 13364-13370.
- [15] DING W, GUO X, WANG G. Radar-Based Human Activity Recognition Using Hybrid Neural Network Model With Multidomain Fusion [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(5): 2889-98.
- [16] TAYLOR W, DASHTIPOUR K, SHAH S A, et al. Radar sensing for activity classification in elderly people exploiting micro-doppler signatures using machine learning [J]. *Sensors*, 2021, 21(11): 3881.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016
- [18] AHMAD A, ROH J C, WANG D, et al. Vital signs monitoring of multiple people using a FMCW millimeter-wave sensor [C] // *Proceedings of the 2018 IEEE Radar Conference (RadarConf18)*. IEEE, 2018.
- [19] ZHOU Z, CAO Z, PI Y. Dynamic gesture recognition with a terahertz radar based on range profile sequences and Doppler signatures [J]. *Sensors*, 2017, 18(1): 10.
- [20] WANG J, CHEN Y, HAO S, et al. Deep learning for sensor-based activity recognition: A survey [J]. *Pattern Recognition Letters*, 2019, 119: 3-11.
- [21] HELEN VICTORIA A, MARAGATHAM G. Activity recognition of FMCW radar human signatures using tower convolutional neural networks [J]. *Wireless Networks*, 2021: 1-17.
- [22] JOKANOVIĆ B, AMIN M. Fall detection using deep learning in range-Doppler radars [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 54(1): 180-189.
- [23] SEYFIOĞLU M S, ÖZBAYOĞLU A M, GÜRBÜZ S Z. Deep convolutional autoencoder for radar-based classification of similar aided and unaided human activities [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2018, 54(4): 1709-1723.
- [24] BHAVANASI G, WERTHEN-BRABANTS L, DHAENE T, et al. Patient activity recognition using radar sensors and machine learning [J]. *Neural Computing and Applications*, 2022, 34: 16033-16048.



LUO Jinyan, born in 1996. Her main research interests include radar human behavior recognition and so on.



CHANG Jun, born in 1970, associate professor, postgraduate's supervisor, is a member of China Computer Federation. His main research interests include intelligent wireless perception and wireless communication.