

DOI:10.19651/j.cnki.emt.2518794

基于雷达时频特征提取和CBAM-MFResNet的人体行为识别^{*}

颜凌嵐¹ 常俊^{1,2} 赵楠¹ 胡涛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)

摘要: 针对现有雷达人体行为识别存在的时频特征表征能力不足,以及神经网络识别准确率较低的问题,提出一种基于雷达时频特征提取和CBAM-MFResNet的人体行为识别方法。在时频特征提取部分,对雷达回波信号进行处理,运用距离窗函数约束行为信号中的频谱能量扩散问题,并沿慢时间维度构建自适应小波阈值-切比雪夫窗函数协同处理机制抑制杂波干扰,通过时频分析获得微多普勒时频图。在网络模型构建部分,构建用于行为识别的CBAM-MFResNet模型,将轻量化卷积注意力机制引入到残差神经网络中,从而增强关键特征表示;同时设计高效的并行多尺度特征学习模块学习多样化特征信息,最大限度地反映不同行为的特征差异;最后,将融合后的特征输入到全连接层进行分类。实验结果表明,本文所提的模型和杂波滤除算法有效提高了识别系统的准确率,对不同人体行为的平均识别准确率达到98%。

关键词: 行为识别; FMCW雷达; 时频特征提取; 杂波抑制; 并行多尺度特征

中图分类号: TN95; TP391 文献标识码: A 国家标准学科分类代码: 510.99

Human action recognition based on radar time-frequency feature extraction and CBAM-MFResNet

Yan Linglan¹ Chang Jun^{1,2} Zhao Nan¹ Hu Tao¹

(1. College of Information, Yunnan University, Kunming 650500, China; 2. University Key Laboratory of Internet of Things Technology and Application, Kunming 650500, China)

Abstract: To solve the problems of insufficient time-frequency feature representation ability and insufficient neural network feature learning in the existing radar human behavior recognition, a human behavior recognition method based on radar time-frequency feature extraction and CBAM-MFResNet is proposed. In the time-frequency feature extraction section, radar echo signals are processed, the distance window function is used to constrain the spectral energy diffusion problem in the behavioral signal, and along the slow time dimension, an adaptive wavelet threshold-Chebyshev window function co-processing mechanism is constructed to suppress clutter interference. Micro-Doppler time-frequency diagrams are obtained by time-frequency analysis. In the network model building section, a CBAM-MFResNet model for behavior recognition is constructed, the lightweight convolutional attention mechanism is introduced into the residual neural network to enhance the representation of key features; and an efficient parallel multi-scale feature learning module was designed to learn diverse feature information to reflect the feature differences of different behaviors to the greatest extent. Finally, the fused features are input into the fully connected layer for classification. Experimental results show that the proposed model and clutter filtering algorithm can effectively improve the accuracy of the recognition system, and the average recognition accuracy of different human behaviors reaches 98%.

Keywords: behavior recognition; FMCW radar; time-frequency feature extraction; clutter suppression; parallel multi-scale feature

0 引言

近年来,随着生物识别技术的不断发展,人机交互的频率不断提高,人体行为识别的研究引起了广泛的关注,在安全保障^[1-2]、医疗健康监护^[3]和智慧家居^[4]等领域具有重要应用价值。

收稿日期:2025-05-13

*基金项目:云南省基础研究计划重点项目(202501AS070066)、云南大学研究生实践创新基金(KC-242410505)项目资助

目前人体行为识别可利用的技术有基于可穿戴式设备的技术以及基于非接触式传感器的技术。基于可穿戴式设备的人体行为识别技术,主要依靠内置陀螺仪和加速度传感器采集运动特征数据^[5],通过分析角度、速度等参数变化,实现动作分类,但随身携带这些设备会影响人体舒适感,缺乏便捷性。相比之下,基于非接触式传感器的行为识别技术可以避免这些问题。非接触式传感器主要使用光学传感器或雷达来识别人体动作。近年来,基于光学传感器的视觉行为识别技术取得显著进展,在性能和识别精度上展现出明显优势^[6]。然而,基于光学传感器的方式对成像质量要求较高,容易受到光照强度、摄像头像素等客观条件的影响,在极端光照环境下无法正常工作,且存在用户隐私泄露风险。相较于其他传感方式,雷达传感器具备非接触探测、抗干扰性强、穿透性能优异及隐私保护等优势,具有重要的研究价值和应用前景。本文采用的雷达为调频连续波(frequency modulated continuous wave,FMCW)制式,体积小,抗干扰能力强,能全天时全气候工作,可以准确连续采集丰富的人体行为数据,使其表征的特征更加丰富。

当前基于 FMCW 雷达人体行为识别技术的文献中,利用微多普勒谱图进行行为特征提取和分析已成为热门的研究方向。相较于其他传统机器学习方法,深度学习方法展现出了较好的鲁棒性^[7]。文献[8]将微多普勒谱图和距离-时间谱图分别输入卷积神经网络(convolutional neural network,CNN)进行特征提取并融合,对六种日常动作进行识别,但对于重要特征提取和利用仍有待增强。文献[9]基于塔式卷积神经网络(tower convolutional neural network,TowerCNN),从微多普勒谱图的各个颜色通道提取特征作为模型的输入,但当雷达特征图色彩信息不丰富时,其模型性能表现不佳。文献[10]使用双向长期记忆网络(bi-directional long short-term memory,Bi-LSTM)学习连续动作的时间序列信息进行人体行为识别,但由于 Bi-LSTM 在处理长序列时会出现信息丢失和混淆等问题,从而导致识别准确率较低。文献[11]提出卷积门控递归单元神经网络,通过短时傅里叶变换生成的微多普勒谱图对不同人体行为进行分类,但由于实验采用模拟数据,未考虑真实环境中噪声干扰的影响。

具体而言,这些基于 FMCW 雷达人体行为识别技术的文献中,普遍未充分考虑静态杂波干扰对后续行为识别应用带来的严重阻碍。同时,以上文献中的神经网络部分大多只采用简单的卷积块堆叠,部分信息丢失,进而影响行为识别的准确率。

针对上述问题,本文使用英国格拉斯哥大学公开的人体行为数据集^[12],提出一种基于雷达时频特征提取和 CBAM-MFResNet 的人体行为识别方法。对雷达回波信号沿距离维度运用布莱克曼窗约束行为信号中的频谱能量扩散问题,并沿慢时间维度构建自适应小波阈值-切比雪夫窗函数协同处理机制抑制杂波干扰,提取微多普勒时域谱

图作为分类特征。同时,基于文献[13]提出的残差网络(residual neural network,ResNet)引入卷积块注意力模块(convolutional block attention module,CBAM)^[14],并设计并行多尺度特征学习(parallel multi-scale feature learning,PMFL)模块用于人体行为识别。实验结果表明,本文所提方法显著提升了特征表征能力,最终实现了较高的行为识别准确率。

1 雷达时频域分析

1.1 调频连续波雷达检测原理

FMCW 雷达系统框图如图 1 所示。

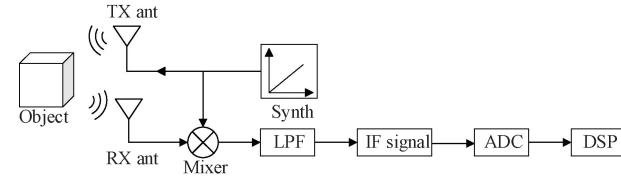


图 1 FMCW 雷达系统框图

Fig. 1 FMCW radar system block diagram

调频连续波(FMCW)雷达通过发射天线(TX)向目标人体行为发射连续调频信号,也称啁啾(Chirp)信号,其频率随时间线性增加。雷达发射的 FMCW 信号如式(1)所示。

$$S_T(t) = A_T \cos(2\pi f_c t + \pi \frac{B}{T} t^2 + \theta(t)) \quad (1)$$

式中: A_T 为发射的 FMCW 信号的幅值; f_c 为载波中心频率; B 为调频带宽, T 为 Chirp 的持续时间, B/T 为调频斜率, $\theta(t)$ 为相位噪声。

当雷达检测到运动目标时,接收天线(RX)捕获经目标反射的回波信号,雷达接收到的反射信号^[15]如式(2)所示。

$$S_R(t) = A_R \cos[2\pi f_c(t - \tau) + \pi \frac{B}{T}(t - \tau)^2 + \theta(t - \tau)] \quad (2)$$

式中: A_R 为回波信号的幅值; τ 为信号在发射和接收过程中的延迟时间。

混频器将发射信号和接收信号进行混频,再经过低通滤波器滤除高频部分,得到中频(intermediate frequency,IF)信号如式(3)所示。

$$S_{IF}(t) = h_{LPF} * \{S_T(t) \times S_R(t)\} = \frac{1}{2} A_T A_R \cos(2\pi \frac{B}{T} \tau t + 2\pi f_c \tau - \pi \frac{B}{T} \tau^2 + \Delta(\theta)) \quad (3)$$

式中: h_{LPF} 为低通滤波器的冲激响应, * 为卷积运算, $\Delta\theta$ 为残余噪声相位项。

模数转换器(analog to digital converter,ADC)将滤波后的中频信号转换为数字信号,以便数字信号处理器(digital signal processing,DSP)进行数字信号处理。

1.2 微多普勒频谱预处理

原始雷达回波数据以一维复杂数组的形式排列,为方便数据处理,将数组重新排列为 $M \times N$ 的二维信号矩阵,

M 表示每个 Chirp 信号上的采样点数, N 表示采集的 Chirp 信号的数量。对每个雷达信号矩阵, 沿快时间维进行距离快速傅里叶变换(fast fourier transform, FFT), 得到二维时间-距离谱图^[16]。对二维时间-距离谱图的慢时间维度进行滤波, 抑制其静态目标和慢速杂波。根据滤波后的时间-距离谱图信息, 选择 10~30 距离单元范围的样本值应用短时傅里叶变换(short time fourier transform, STFT), 最终得到微多普勒时域谱图(doppler-time-map, DTM), 如图 2 所示。

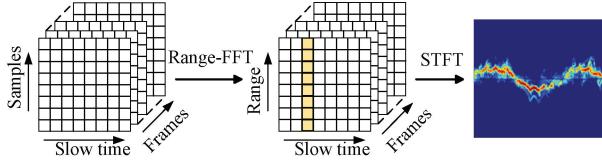


图 2 微多普勒图(DTM)生成方法

Fig. 2 Doppler-Time-Map(DTM) generation method

2 行为识别系统设计

2.1 整体框图

本文行为识别系统整体框架如图 3 所示, 该框架由时频特征提取和网络模型架构两部分组成。首先, 在时频特征提取阶段, 对原始雷达回波数据进行数据重排、在距离维度运用距离窗函数对行为回波信号进行处理、沿快时间维进行距离 FFT 操作以提取距离信息, 得到二维时间-距离特征图; 然后, 通过构建自适应小波阈值-切比雪夫窗函数协同处理机制, 对二维时间-距离谱图的慢时间维度进行高效的杂波干扰去除, 通过 STFT 得到处理后的微多普勒时频图; 最后, 在网络模型架构阶段, 构建用于行为识别的 CBAM-MFResNet 分类模型, 该模型通过引入注意力机制并设计高效的并行多尺度特征学习模块, 有效提升了微多普勒特征的判别性表征能力, 将处理后的微多普勒谱图输入到 CBAM-MFResNet 中进行学习和分类识别。整个流程实现了从原始雷达回波信号到时频特征再到分类结果的端到端处理, 具有较高的人体行为识别精度。

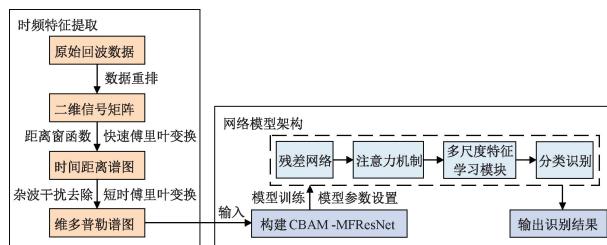


图 3 整体框图

Fig. 3 Overall block diagram

2.2 时频特征提取

1) 二维距离谱图

为提取用户行为模式的多普勒特征信息, 首先对重排

后的 FMCW 信号进行距离 FFT, 将雷达信号从二维时间域转换为距离-慢时间域, 得到二维时间-距离谱图。为解决时间-距离谱图中存在的频谱能量扩散问题, 采用距离窗函数对数据进行处理。窗函数选取 Blackman 窗。对距离特征而言, 该窗函数具有显著的旁瓣衰减特性, 有利于解决由频谱泄露引起的频谱能量扩散问题, 有效实现对距离维度中的杂波抑制以及关键行为信息增强, 应用距离窗函数前后的时间-距离谱图分别如图 4(a)、(b) 所示, 可见行为特征信息更为明显。

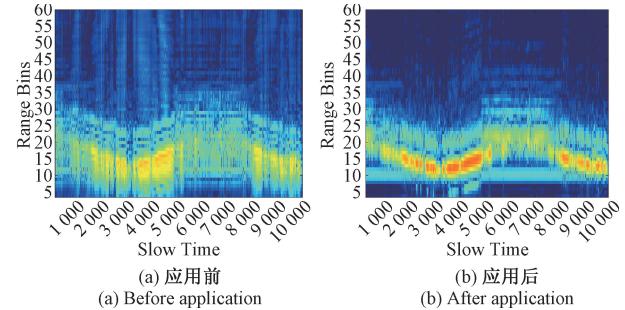


图 4 应用距离窗函数前后的时距谱图

Fig. 4 Range-Time-Map before and after applying the distance window function

2) 静态杂波抑制

实际场景下捕获的雷达回波信号中, 除了预期的行为多普勒频移外, 还包含背景中家具、墙壁和其他静态物体引起的杂波信号。静态杂波会严重干扰目标微动特征的提取, 影响对运动目标的检测性能。

为抑制静态杂波, 本文在时频分析前构建自适应小波阈值-切比雪夫窗函数协同处理机制抑制背景静态杂波。首先选取 Symlet 小波对二维时间-距离谱图进行多尺度小波分解。提取其尺度系数 $c_{j,k}$ 和小波系数 $d_{j,k}^i$, 对每一层的小波系数进行动态调整, 将处理后得到的小波系数 $d_{j,k}^i$ 与尺度系数 $c_{j,k}$ 结合, 重构二维距离谱图。对于微多普勒特征而言, Symlet 小波的正交性和紧支撑性可以使得其谱图在重构时实现信号与杂波的有效分离^[17], 其阈值函数为:

$$f(x) = \begin{cases} 0, & |x| < \lambda \\ \text{sgn}(x) \left[|x| - \frac{1}{\lambda^2 + e^{|x|-\lambda}} \right], & |x| \geq \lambda \end{cases} \quad (4)$$

阈值 λ 可表示为式(5):

$$\lambda = \sigma \sqrt{2 \ln M} \quad (5)$$

式中: σ 为 FMCW 信号的方差; M 为 Chirp 信号上的采样点数。

随后将重建后的谱图通过切比雪夫窗函数进一步滤波。对于微多普勒特征而言, 该窗函数可以有效减少其杂波干扰, 提高目标信号清晰度, 其频谱函数为:

$$W(k) = \sum_{n=0}^{N-1} \frac{\cos \left\{ (N-1) \cos^{-1} \left[\beta \cos \left(\frac{\pi n}{N} \right) \right] \right\}}{\cos[(N-1) \cos^{-1}(\beta)]} e^{-j \frac{2\pi}{N} kn} \quad (6)$$

其中, N 为采样点数, $0 \leq k \leq N - 1$, β 可表示为:

$$\beta = \cosh \left[\frac{1}{N-1} \cosh^{-1} \left(10^{\frac{A}{20}} \right) \right] \quad (7)$$

其中, A 为旁瓣电平 dB 值。

雷达谱图杂波抑制处理效果,如图 5 所示,其中,红色矩形框内表示被滤除的杂波分量。可见通过上述操作可以有效滤除静态干扰,使行为动作更为突出,特征信息更为明显。

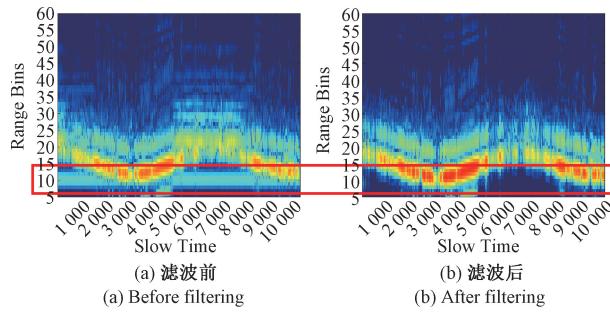


图 5 杂波抑制前后对比图

Fig. 5 Comparison diagram before and after clutter suppression

3) 短时傅里叶变换

时频分析方法可有效提取并表征微多普勒信号的时频特征。为实现对目标微多普勒特征的提取,本实验对滤波后的时间-距离矩阵的距离单元进行短时傅里叶变换,得到微多普勒频谱图像。STFT 的数学表达式为:

$$\text{STFT}(f, k) = \sum_{n=-\infty}^{+\infty} x(n)w(n-k)e^{-j2\pi fn} \quad (8)$$

其中, $w(n)$ 表示窗口函数,本文采用汉明窗口。最后将多个距离单元的微多普勒图进行非相干叠加得到 6 种行

为的微多普勒图,如图 6 所示。微多普勒频谱图通过振荡捕捉目标的细微运动。由于不同身体部位在各种动作中的速度会发生变化,因此,微多普勒频谱图可以有效地用于人体动作识别。

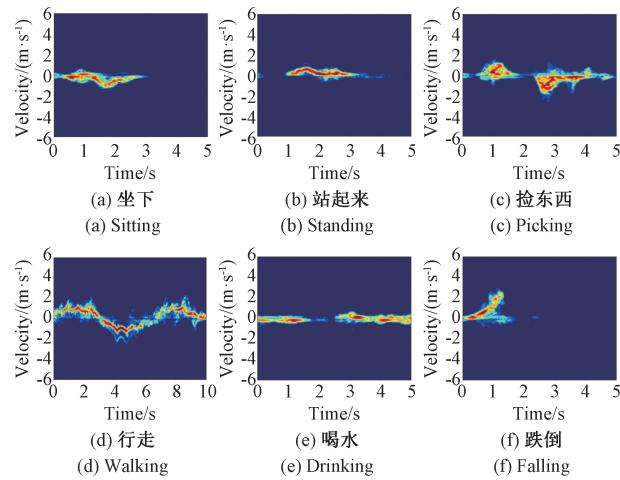


图 6 不同人体行为的微多普勒频谱图

Fig. 6 Micro Doppler spectrum of different human behaviors

2.3 网络模型架构

本文构建的人体行为识别网络模型,如图 7 所示。该模型由特征提取层、特征增强层和分类器三部分组成。首先通过基于迁移学习的 Resnet18 对输入微多普勒图进行初始特征提取,将提取到的特征通过特征增强层进行特征过滤和增强,特征增强层由 CBAM 注意力机制和并行多尺度特征学习模块组成。最后经过全局平均池化层和全连接

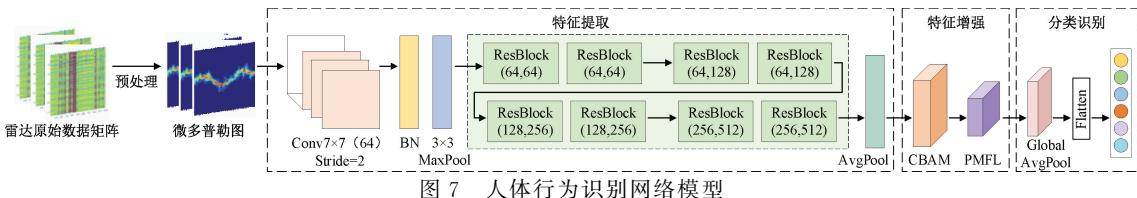


图 7 人体行为识别网络模型

Fig. 7 Human behavior recognition network model

层进行分类处理。

1) 骨干网络

本文选用 ResNet18 作为骨干网络。ResNet18 不仅网络深度适中,还引入了残差结构,有效地解决了随着神经网络深度增加而丢失信息的问题。该模型通过对输入图像进行多层特征映射,最终提取出 512 维度的特征向量。

传统的卷积神经网络在训练数据量有限的情况下难以展现出良好效果。相比之下,迁移学习(Transfer Learning)通过利用在大规模数据集 ImageNet 上预训练的模型参数作为初始化,可以有效解决人体行为识别任务中训练数据不足的难题,提升模型的特征提取能力和训练效率。因此,本文采用模型级迁移学习^[18]方法,即使用大规模数据集 ImageNet 自然图像作为源域进行预训练,将学

习到的知识在模型层面迁移到目标域 DTM 中实现跨域学习。该方法首先通过 ImageNet 数据集对 ResNet18 进行预训练,得到预训练的权重参数;然后冻结 ImageNet 预训练 ResNet18 的全部卷积层,以保留其强大的特征提取能力,并在平均池化层后引入 CBAM 注意力机制和多尺度特征学习模块,仅训练新增模块和分类器来实现对目标任务的适配优化,最终输出分类结果。通过该方法能充分利用在大规模数据上训练得到的特征,显著提升模型的训练效率和判别能力。基于迁移学习的 ResNet18 网络模型结构图如图 8 所示。

2) CBAM 注意力机制

微多普勒特征中包含人体运动速度的变化情况以及运动信号的关联信息,因此,本实验在模型架构中引入

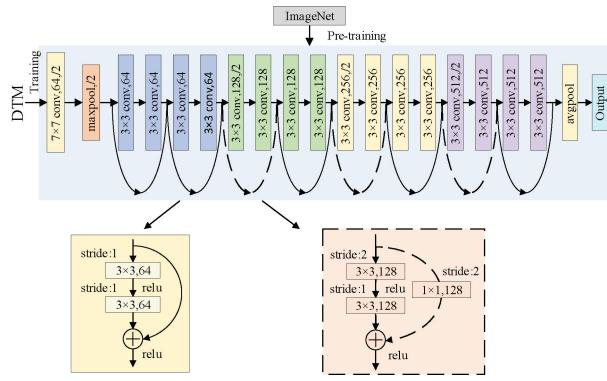


图 8 ResNet18 网络结构

Fig. 8 ResNet18 network architecture

CBAM 注意力机制,其通道-空间注意力结构可自适应增强关键运动特征。CBAM 是集成了通道注意模块(channel attention module,CAM)和空间注意模块(spatial attention module,SAM)的轻量级注意力机制模块^[14],如图 9 所示。

通道注意力模块利用具有两个全连接层的多层感知器来处理通道维度信息,以捕捉微多普勒谱图的色彩特征变化。空间注意力模块从输入中揭示相关的位置信息,关注谱图中各个色彩分量的位置信息。通过该模块,能帮助模型更好地关注谱图重要的颜色或纹理特征,从而更有效地提取不同行为特征关键像素区域,同时区分其相似性,最终得到较高的准确率。整体注意力过程可以表示为:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F \end{cases} \quad (9)$$

其中, \otimes 表示逐元素乘法, F'' 是最终的精化输出。

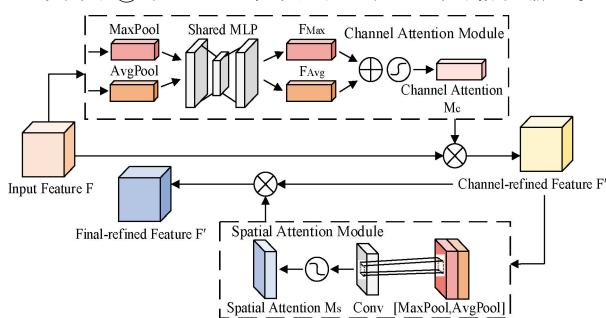


图 9 注意力机制网络架构

Fig. 9 Attention mechanism network architecture

3) 并行多尺度特征学习模块

为最大限度地反映不同行为的特征差异以提高识别准确率,本研究创新性地设计了并行多尺度特征学习模块,如图 10 所示。即运用多种尺度的卷积核更全面地捕捉动作特征,增强模型的特征抽象能力。

该模块采用四路并行架构,选用 1×1 、 3×3 和 5×5 的 3 种尺度的小卷积核,获取 4 类不同感受野的特征数据。

然后,将得到的四路特征信息在通道维度上进行拼接。最后,采用 3×3 最大池化与 1×1 卷积对多尺度特征进行更高层次的抽象和整合,获得更具判别性的多尺度特征表示。该模块用公式表示为:

$$Output = Conv_{1 \times 1}(Cat(f_1, f_2, f_3, f_4)) \quad (10)$$

其中, f_i 表示第 i 个分支提取到的特征, $Cat(\cdot)$ 表示拼接操作, $Conv_{1 \times 1}(\cdot)$ 表示卷积核大小为 1×1 的卷积操作。

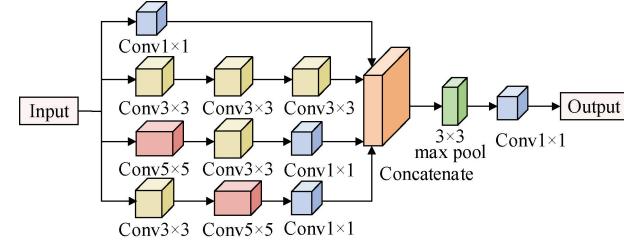


图 10 PMFL 网络结构

Fig. 10 PMFL network structure

3 实验验证

3.1 数据集与实验设置

本文所用数据集采用英国格拉斯哥大学公开的人体行为数据集^[12],使用的雷达是 Ancortek 公司生产的 FMCW 雷达,该雷达中心频率为 5.8 GHz,带宽为 400 MHz,每个 Chirp 信号的持续时间为 1 ms。该数据集包含 7 个不同时间点采集到的子数据集,共有 72 名不同年龄、身高、体重的志愿者参与数据采集,每个受试者对同一种行为重复 2~3 次,共测得 1 754 个原始数据。将数据集按照 8:2 分为训练集和测试集。数据类型包含 6 种人体日常活动,活动数据分布如表 1 所示。

表 1 人体活动数据分布

Table 1 Distribution of human activity data

活动	样本个数	测量时间/s
行走	312	10
坐下	312	5
站起来	312	5
捡东西	309	5
喝水	312	5
跌倒	197	5
总计	1 754	—

行为识别模型使用 Pytorch 深度学习框架实现,并在 NVIDIA 公司的 GeForce RTX 3060Ti GPU 上进行训练,输入图像为 224 pixel \times 224 pixel。最大迭代次数为 100,采用 Adam 优化器更新网络训练参数。由于学习率是网络的一个重要参数,它直接影响网络模型的性能,过大的学习率可能会导致损失函数震荡或模型训练不稳定,而

学习率过小会使收敛速度过慢或陷入局部最优。为探寻合适的学习率使网络快速收敛到最优解,本文将学习率设置为 0.1、0.01、0.001、0.000 1 进行对比,训练曲线如图 11 所示,可见学习率设置为 0.000 1 时模型准确率较高,且较稳定。因此,选择 0.000 1 作为本文网络的最佳学习率。

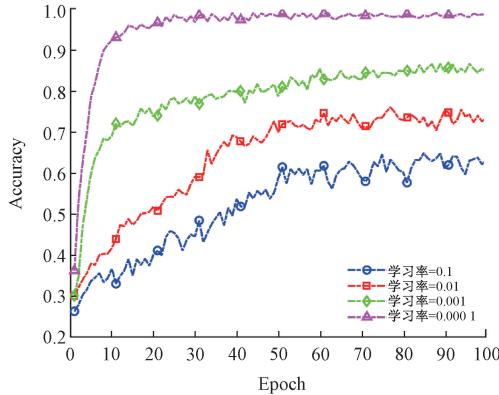


图 11 不同学习率的准确率对比

Fig. 11 Accuracy comparison of different learning rates

3.2 模型评估

训练集的损失曲线如图 12 所示。由图 12 可知,随着模型的训练深入,训练集的损失值会逐渐降低并趋于稳定,表明该模型在训练集上的拟合效果越来越好且较为稳定。

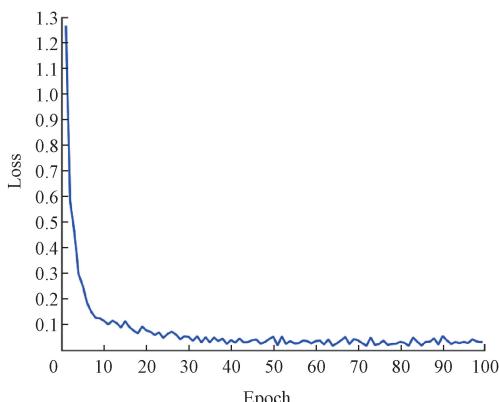


图 12 模型训练的 loss 曲线

Fig. 12 Loss curve of model training

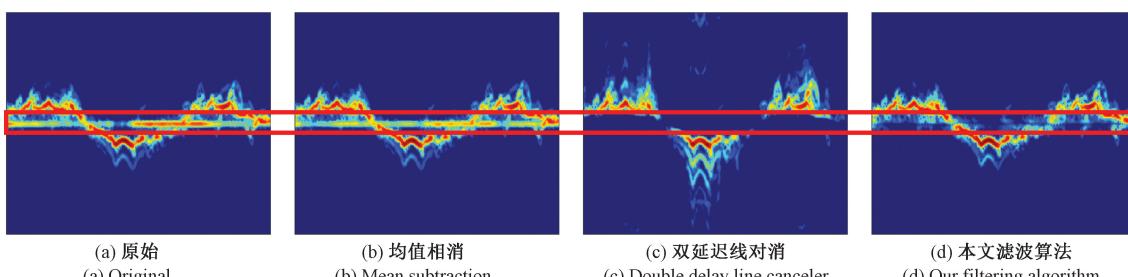


图 15 不同方法滤波结果
Fig. 15 Filtering results of different methods

随着训练轮次的增加,训练数据的准确率逐渐提高并趋于稳定,表明该模型容易收敛,如图 13 所示。为评估该模型在测试集上的性能,本文绘制了 6 种行为分类的混淆矩阵,如图 14 所示。该模型最终的平均分类准确率达到 98.00%,实验结果表明,该模型具有较高的识别准确率。

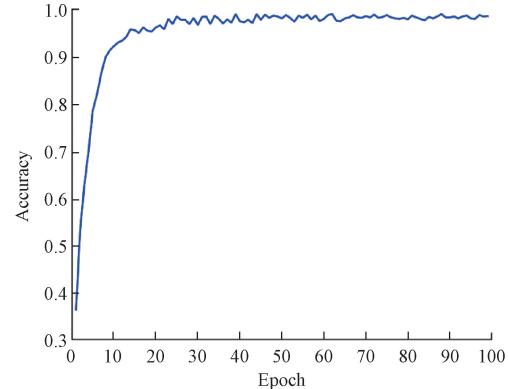


图 13 模型的准确率变化曲线

Fig. 13 Accuracy curve of model

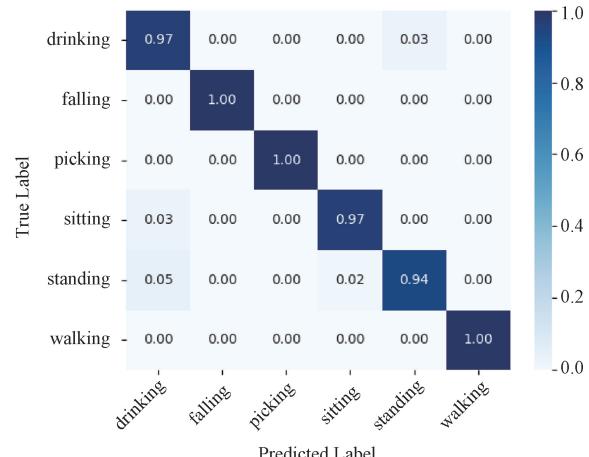


图 14 混淆矩阵

Fig. 14 Confusion matrix

3.3 杂波滤除算法的有效性

为验证本文所提杂波滤除算法的有效性,在相同条件下分别比较了延迟对消法和均值相消法^[19]对微多普勒谱图的处理效果,如图 15 所示,其中,红色矩框内表示不

同方法对零多普勒频率附近的干扰分量的滤除结果。

由图 15 可知,均值相消处理后,零多普勒频率附近的干扰分量依然较强;双延迟线对消结构虽然提升了杂波抑制能力,但牺牲了对连续微多普勒特征的捕获性能;相较之下,本文提出的联合滤波算法在零多普勒频带内实现了均衡的杂波抑制性能,较好地保持了人体行为微多普勒特征的完整性。

为进一步验证不同方法滤波处理得到的特征的识别能力,分别使用均值相消、双延迟线对消以及本文所提滤波方法对原始雷达回波数据进行特征提取,将处理后的微多普勒谱图输入到本文所提网络中进行训练和识别测试。图 16 是 3 种不同滤波算法的各行为特征识别准确率。

从图 16 可知,本文提出的滤波算法在分类性能上要优于均值相消和双延迟线对消算法,平均分类精度分别高出 4%,5%。由此可见,本文提出的滤波方法对行为识别有很大的影响。同时可以看到基于均值相消方法和基于双延迟线对消方法对捡东西、喝水两种人体行为的识别,效果并不是很理想。由于捡东西和喝水属于精细人体行为,均值相消算法对杂波的抑制能力有限难以满足高分辨率场景需求,对精细动作特征的捕捉存在困难,从而影响人体行为的识别精度。

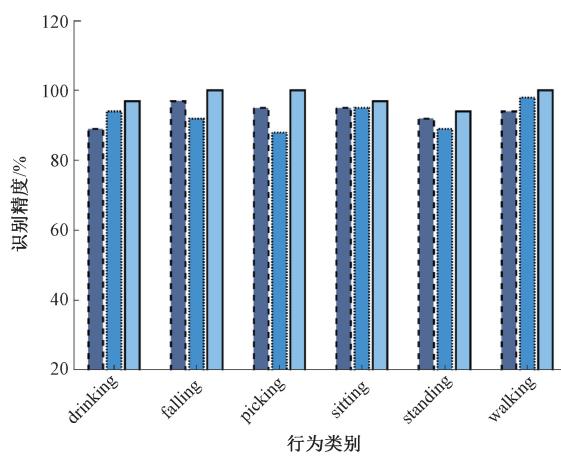


图 16 不同滤波方法的行为识别精度比较

Fig. 16 Comparison of behavior recognition accuracy of different filtering methods

相比之下,本文提出的杂波滤除算法得到的微多普勒谱图具有更高的识别精度,能有效地滤除静态杂波,实现人体行为关键特征的准确提取,无论是对精细动作(如喝

水、捡东西)、日常基础动作(如坐下、站立)还是整体运动(如行走、跌倒)都有较好的识别效果。

3.4 消融实验

为验证本文所提模型各组成部分的合理性,以 ResNet18 模型作为主干网络,进行以下消融实验,结果如表 2 所示。

表 2 消融实验结果

Table 2 Ablation study results

实验	+ResNet18	+CBAM	+PMFL	准确率/%
1	√	—	—	93.41
2	√	√	—	96.85
3	√	—	√	95.42
4	√	√	√	98.00

由表 2 可知,在 ResNet18 基础上分别引入 CBAM 注意力机制和 PMFL 模块时,其准确率均得到提高,表明注意力机制与多路并行多尺度卷积模块各自在增强关键特征、提升模型性能方面的有效性。同时引入 CBAM 注意力机制与 PMFL 模块时,其准确率得到进一步提升,最终达到 98%。这一结果表明了本文所提出的模块组合在提升模型性能方面的优势。

3.5 网络模型实验对比

为客观评价本文方法的性能,验证所提出方法的优越性,将本文模型与近期使用相同数据集的其他行为识别方法进行对比,如表 3 所示。研究结果表明,本文方法在分类准确率上均超过了之前的识别方法。

表 3 不同模型识别人体行为的性能比较

Table 3 Comparison of recognition performance of different models

模型	分类准确率/%
CNN ^[8]	93.97
AlexNet ^[20]	93.54
RD-CNN ^[21]	92.33
VGG-19-Net ^[22]	96.86
本文模型	98.00

此外,为进一步探究输入特征及网络模型对实验结果的影响,与相同传感器下(FMCW 雷达)的不同输入特征及网络模型方法进行比较,如表 4 所示。

表 4 不同输入特征及网络模型方法对比结果表

Table 4 Comparison results of different input characteristics and network model methods

输入特征	行为类型	网络模型	分类准确率/%
去噪频谱图灰度图像 ^[23]	4	堆叠式自动编码器	89.40
频谱图 R+G+B 三通道 ^[9]	6	CNN	97.58
时间-距离、时间-多普勒、距离-多普勒三域融合 ^[24]	6	CNN+LSTM	93.39
时间-距离、时间-多普勒双域融合 ^[25]	6	CNN+SMAN	97.58
微多普勒频谱图	6	本文模型	98.00

研究结果表明,本文所提方法在现有工作基础上分类准确率得以提高。由表 4 可知,与其他不同输入特征相比,本文采用微多普勒频谱图作为输入特征能更好地保留目标动态特征,基于微多普勒频谱图的方法可以达到更优的识别效果;与其他网络模型相比,本文所提人体行为模型 CBAM-MFResNet 在行为识别准确率上更具优势。

4 结 论

本文提出了一种基于雷达时频特征提取和 CBAM-MFResNet 的人体行为识别方法。该方法对雷达回波数据进行分析处理,利用布莱克曼窗约束行为信号的频谱能量扩散,并沿慢时间维度构建自适应小波阈值-切比雪夫窗函数协同处理机制抑制杂波干扰,处理得到每种行为的微多普勒频谱图,以此作为神经网络的输入,并对 ResNet18 进行改进,引入轻量化卷积块注意力模块与并行多尺度特征学习模块,用来增强模型对行为特征的区分能力。实验结果表明,平均分类准确率可达 98%,表明本文提出的杂波滤除算法和分类模型有效提高了 FMCW 雷达行为识别的准确率。在未来的研究中,将针对更精细的行为特征展开研究,同时进一步优化网络模型架构,减少模型复杂度和参数数量。

参考文献

- [1] 陶峰,李燕萍,王瑞.基于图卷积网络改进的人体动作识别模型[J].电子测量技术,2023,46(8):59-64.
TAO F, LI Y P, WANG R. Improved human action recognition model based on graph convolutional networks [J]. Electronic Measurement Technology, 2023, 46(8): 59-64.
- [2] 建中华,南静,刘鑫,等.基于时空张量融合的人体骨架行为自适应识别方法[J].仪器仪表学报,2023,44(6):74-85.
JIAN ZH H, NAN J, LIU X, et al. Adaptive recognition method of human skeleton action with spatial-temporal tensor fusion [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 74-85.
- [3] 方震,简璞,张浩,等.基于 FMCW 雷达的非接触式医疗健康监测技术综述[J].雷达学报,2022,11(3):499-516.
FANG ZH, JIAN P, ZHANG H, et al. Review of noncontact medical and health monitoring technologies based on FMCW radar [J]. Journal of Radars, 2022, 11(3): 499-516.
- [4] 刘雨萌,桑海峰.基于关键帧定位的人体异常行为识别[J].电子测量与仪器学报,2024,38(3):104-111.
LIU Y M, SANG H F. Human abnormal behavior recognition based on keyframes localization [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (3): 104-111.
- [5] THAKUR D, LALWANI P. A method for human behavior identification based on integrated sensor data using XGBoost classifier with PCA techniques [J]. Physica Scripta, 2024, 99(6): 066001.
- [6] FENG Z, WANG X, ZHOU J, et al. MDJ: A multi-scale difference joint keyframe extraction algorithm for infrared surveillance video action recognition [J]. Digital Signal Processing, 2024, 148: 104469.
- [7] JIA M, LI S, LE KERNEC J, et al. Human activity classification with radar signal processing and machine learning [C]. 2020 International Conference on UK-China Emerging Technologies (UCET), 2020: 1-5.
- [8] 张丽丽,刘博,屈乐乐,等.基于特征融合卷积神经网络的 FMCW 雷达人体动作识别[J].电讯技术,2022,62(2):147-154.
ZHANG L L, LIU B, QU L L, et al. Human activity recognition with FMCW radar based on fusion feature convolutional neural network [J]. Telecommunication Engineering, 2022, 62(2): 147-154.
- [9] HELEN VICTORIA A, MARAGATHAM G. Activity recognition of FMCW radar human signatures using tower convolutional neural networks [J]. Wireless Networks, 2021: 1-17, DOI: 10.1007/S11276-021-02670-7.
- [10] SHRESTHA A, LI H, LE KERNEC J, et al. Continuous human activity classification from FMCW radar with Bi-LSTM networks [J]. IEEE Sensors Journal, 2020, 20(22): 13607-13619.
- [11] DU H, JIN T, SONG Y, et al. DeepActivity: A micro-Doppler spectrogram-based net for human behaviour recognition in bio-radar [J]. The Journal of Engineering, 2019, 2019(19): 6147-6151.
- [12] TAYIOR 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.
- [13] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision (ECCV), 2018: 3-19.
- [15] 罗金燕,常俊,吴彭,等.基于残差网络的 FMCW 雷达人体行为识别[J].计算机科学,2023,50(S2):174-179.
LUO J Y, CHANG J, WU P, et al. FMCW radar human behavior recognition based on residual network [J]. Computer Science, 2023, 50 (S2): 174-179.

- Computer Science, 2023, 50(S2): 174-179.
- [16] 唐高鹏, 李从胜, 巫彤宁. 基于数据增强算法和 CNN-LSTM 的高精确度手势识别[J]. 太赫兹科学与电子信息学报, 2024, 22(5): 549-557.
TANG G P, LI C SH, WU T N. High-precision gesture recognition based on data enhancement algorithm and CNN-LSTM[J]. Journal of Terahertz Science and Electronic Information Technology, 2024, 22(5): 549-557.
- [17] 谢锡海, 魏晓会. 一种 FMCW 雷达信号的小波阈值函数去噪法[J]. 西安邮电大学学报, 2017, 22(4): 21-25.
XIE X H, WEI X H. Wavelet threshold function denoising method for FMCW radar signal[J]. Journal of Xi'an University of Posts and Telecommunications, 2017, 22(4): 21-25.
- [18] MARAY N, NGU A H, NI J, et al. Transfer learning on small datasets for improved fall detection[J]. Sensors, 2023, 23(3): 1105.
- [19] 李家强, 任梦豪, 危雨萱, 等. 基于轻量化网络的车载雷达目标分类方法[J]. 雷达科学与技术, 2023, 21(6): 597-604, 612.
LI J Q, REN M H, WEI Y X, et al. Target classification method for automotive radar based on lightweight network [J]. Radar Science and Technology, 2023, 21(6): 597-604, 612.
- [20] LI Z, LIU Y, LIU B, et al. A holistic human activity recognition optimisation using AI techniques[J]. IET Radar, Sonar & Navigation, 2024, 18(2): 256-265.
- [21] KIM W Y, SEO D H. Radar-based human activity recognition combining range-time-Doppler maps and range-distributed-convolutional neural networks [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-11.
- [22] ABDU F J, ZHANG Y, DENG Z. Activity classification based on feature fusion of FMCW radar human motion micro-Doppler signatures [J]. IEEE Sensors Journal, 2022, 22(9): 8648-8662.
- [23] JOKANOVIC 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.
- [24] 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): 2889-2898.
- [25] CAO L, LIANG S, ZHAO Z, et al. Human activity recognition method based on FMCW radar sensor with multi-domain feature attention fusion network [J]. Sensors, 2023, 23(11): 5100.

作者简介

颜凌嵒, 硕士研究生, 主要研究方向为 FMCW 雷达信号处理与行为识别。

E-mail: lanlan02515@163.com

常俊(通信作者), 副教授, 主要研究方向为无线通信信号处理与软件无线电, 智能无线定位与感知等。

E-mail: changjun@ynu.edu.cn

赵楠, 硕士研究生, 主要研究方向为深度学习与雷达人体行为识别。

E-mail: nanzhao1115@163.com

胡涛, 本科, 主要研究方向为雷达传感器信号处理。

E-mail: hutao@stu.ynu.edu.cn