

基于雷达时频变换和残差网络的人体行为检测^{*}孙梓誉¹ 顾晶²

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 无锡学院电子信息工程学院 无锡 214105)

摘要: 与传统惯性传感器和视觉传感器相比,利用毫米波雷达进行人体行为检测不仅对环境要求低、灵敏度高而且能很好地解决摄像头存在的泄露隐私等问题。针对目前毫米波雷达人体行为检测存在的杂波干扰和网络模型复杂度高的问题,本文对现有的残差网络进行改进和量化处理,并结合雷达时频变换和杂波抑制,提出了一套完整的雷达人体行为检测信号处理流程。时频变换部分采用距离维 FFT、沿慢时间维进行高通滤波、短时傅里叶变换得到时间-多普勒谱;残差网络部分则是嵌入 CBAM 注意力机制并对其进行 32~8 位数据量化处理;最后将时间-多普勒谱输入网络模型进行特征提取和分类得到检测结果。实验结果表明,该方法能够消除静态杂波的干扰,检测准确率达 97.33%,模型大小仅为 20.2 MB。

关键词: 毫米波雷达;时频变换;杂波抑制;时间-多普勒;残差网络

中图分类号: TN95 **文献标识码:** A **国家标准学科分类代码:** 510.40

Human activity detection based on radar time-frequency transformation and residual network

Sun Ziyu¹ Gu Jing²

(1. College of Electronics & Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China; 2. College of Electronic Information Engineering, Wuxi University, Wuxi 214105, China)

Abstract: Compared with traditional inertial sensors and visual sensors, using millimeter-wave radar for human activity detection not only requires low environmental demands and high sensitivity but also can effectively address privacy leakage issues associated with cameras. To tackle the problems of clutter interference and high complexity of network models in current millimeter-wave radar human activity detection, this paper proposes improvements and quantization processing of existing residual neural network. By integrating radar time-frequency transformation and clutter suppression, a complete signal processing flow for radar human activity detection is presented. The time-frequency transformation section adopts range dimension FFT, high-pass filtering in slow-time dimension, and short-time Fourier transformation to obtain Time-Doppler spectrum. The residual network section embeds the CBAM attention mechanism and quant it from 32 bits to 8 bits. Finally, the Time-Doppler spectrums are input into the network model for feature extraction and classification to obtain detection results. Experimental results demonstrate that this method can eliminate interference from static clutter, achieving a detection accuracy of 97.33% with a model size of 20.2 MB.

Keywords: millimeter-wave radar; time-frequency transformation; clutter suppression; Time-Doppler; residual neural network

0 引言

人体行为检测作为模式识别的一个重要研究方向,在社会安防、医疗防护、运动监测等领域有着重要价值。目前,人体行为检测所使用的传感器主要包括三轴惯性传感器(inertial measurement unit, IMU)和视觉传感器,通过分

析人体运动加速度方向的变化或者人体检测框长宽比的变化及骨骼关键点来实现人体行为特征的提取^[1-2]。然而由于穿戴设备的不便携性和光学传感器易受光照、遮挡、背景噪声的影响,难以得到大规模的推广应用。近年来,毫米波雷达技术在人体行为识别领域引起了广泛关注,相比于传统的 IMU 和视觉传感器,毫米波雷达具有使用便捷、保护

个人隐私、不受光照和遮挡影响等优势,在人体智能监测系统中有着较好的应用前景^[3]。

基于毫米波雷达的人体行为检测主要有点云和多普勒频率分析两种方式。基于点云的方法直接利用雷达恒虚警概率处理后输出的点云信息,数据预处理比较简便。Yu 等^[4]提出了一种基于雷达点云的人体行为检测算法,通过改进基于的密度聚类算法(density-based spatial clustering of applications with noise, DBSCAN)进行点云聚类,利用雷达旋转对称性进行数据增强,将连续帧的点云数据通过后续分类器进行分类,虽然该方法能够实现轨迹跟踪和行为检测,但室内场景下的电磁波多径效应和噪声点云的干扰会造成点云精度的下降,从而影响检测结果。毫米波雷达可以通过提高扫频周期来获得较高的多普勒分辨率,因此基于多普勒频率分析的方法成为研究热点。丁晨旭等^[5]采用距离-多普勒谱沿速度维投影的方式构建微多普勒谱图,通过奇异值分解(singular value decomposition, SVD)提取特征矢量和支撑向量机(support vector machine, SVM)分类进行人体行为检测,但数据偏少,分类算法收敛速度慢。

随着神经网络在计算机视觉领域的快速发展,其强大的图像特征提取能力为雷达信号人体行为检测提供了新的思路。Li 等^[6]采用半监督迁移学习和生成对抗网络的方式,利用少量数据集训练 HAR 数据集,模型泛化能力高,但准确率仅为 87.2%。元志安等^[7]通过卷积神经网络(convolutional neural network, CNN)对多帧距离-多普勒图进行特征提取,得到特征向量,然后按照时间顺序输入到长短时记忆神经网络(long and short term memory network, LSTM)中,以获取多帧图像的时间相关性信息,再通过分类器进行分类。然而,该网络存在冗余度高和计算量大的问题。许志猛等^[8]提出了一种基于形态滤波和长短时记忆神经网络的方法有效识别人体行为,准确率达到 94%,但数据预处理过程中计算复杂且有部分信息丢失。

大部分文献在做分类任务采用的并不是真实的时间-多普勒谱,而是由时间-多普勒二维矩阵转化成的 RGB 图像(三维),然后用深度学习图像处理的方法对 RGB 图像进行人体行为分类。笔者认为数据由二维扩展成三维会造成数据的失真,本文将原始的时间-多普勒谱作为神经网络的输入,同时抛弃深度学习图像处理的 RGB 三通道特征提取方法,改为单通道的灰度图特征提取方法。目前大部分时频域分析与神经网络结合的分类任务中都沿用一般计算机视觉的数据增强方式,但是时间-多普勒谱的横纵坐标表示的物理含义不同,在旋转、裁剪等过程中会导致大部分特征丢失,影响检测的准确度。

为了解决上述问题,本文提出了一种基于雷达时频变换和残差网络的人体行为检测方法,以及一套完整的雷达人体行为检测信号处理流程。本文没有沿用图像裁剪等通

用数据增强方法,提出一种与雷达时频域相关的数据增强方法,在保留雷达时间和多普勒特征的同时,加强数据集的适用性。残差网络的参数量随网络层数的堆叠呈指数增长,难以在实际的嵌入式处理器中部署落地,因此本文还研究了神经网络压缩算法,将网络模型大小压缩至 20.5 MB,其检测准确率保持在 97.13%。

1 时频域特征提取

1.1 FMCW 信号回波模型

调频连续波(frequency modulated continuous wave, FMCW)是一种不断调整发射频率来检测目标位置和速度的雷达信号,已广泛应用于汽车驾驶辅助、智能交通、航空导航等领域。假设 FMCW 发射信号数学模型为:

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

式(1)为正弦形式的发射信号模型, f_c 为发射信号载波, B 为发射信号带宽, T 为发射信号扫频时间, B/T 即为调频斜率。那么雷达回波信号(忽略信号衰减)可以表示为:

$$r(t) = \cos(2\pi f_c (t - t_d) + \pi \frac{B}{T} (t - t_d)^2) \quad (2)$$

其中, t_d 是回波信号的延迟时间。那么根据 FMCW 的原理,雷达接收器将发射信号和接收信号做混频和低通滤波后得到了中频信号,可以表示为:

$$x_{IF}(t) \approx LPF\{s(t)r(t)\} = A \cos(4\pi \frac{BR}{cT} t + \frac{4\pi}{\lambda} R) = A \cos(f_{IF} t + \Phi_{IF}) \quad (3)$$

其中, R 是目标到雷达的距离, f_{IF} 中频信号载频, Φ_{IF} 为初相。

1.2 距离维 FFT

为了进行进一步的数字信号处理,式(3)中的中频信号 x_{IF} 以采样频率 F_s 被采样 N 次。得到的离散时间复指数信号可以表示为式(4)。

$$x[n] = A e^{j\Phi_{IF}} e^{j\omega_{IF} n}, 0 \leq n \leq N \quad (4)$$

其中,离散时间角频率可以表示为 $\omega_{IF} = 2\pi f_{IF}/F_s$ 。有限持续时间离散时间信号 $x[n]$ 的加窗快速傅里叶变换(快时间维),即 1DFFT,可以推导出式(5)为:

$$X(\omega) = F\{x[n]\} = \sum_{n=0}^{N-1} x[n] e^{-j\omega n} = A e^{j\Phi_{IF}} P(\omega - \omega_{IF}), \omega = 2\pi k/N \quad (5)$$

其中, $P(\omega)$ 是长度为 N 的汉明窗函数的傅里叶变换,可以表示为:

$$P(\omega) = 0.54 P_N(\omega) + 0.23 [P_N(\omega - \frac{2\pi}{N}) + P_N(\omega + \frac{2\pi}{N})] \quad (6)$$

$$P_N(\omega) = \sum_{n=0}^{N-1} e^{-j\omega n} = \text{sinc}(\frac{\omega N}{2}) e^{-j\frac{\omega(N-1)}{2}} \quad (7)$$

那么,在一个发射周期内经上述处理后得到一个二维的时间-距离谱,其表达式为:

$$RT(k, t_s) = F\{x_i[n, t_s]\} = X_i(\omega, t_s) \mid_{\omega=2\pi k/N} \quad (8)$$

其中, t_s 为慢时间, x_i 、 X_i 为随慢时间 t_s 变化函数。

1.3 静态杂波抑制

实际场景下采集的信号会存在诸多的干扰源,既有来自硬件本身也有外界干扰,对于本文,其主要影响来自于静态目标和地杂波等静态杂波。由于本文关注于目标的运动特征,静态杂波经过时频域变换后,在多普勒零频率附近存在大量干扰,导致微动特征湮没。因此,本文在时频分析前设计一个四阶高通巴特沃斯数字滤波器,对时间-距离谱的快时间维 k 进行滤波,得到新的时间-距离谱 RT_f , 滤波器的传递函数如式(10)所示。相较于延迟对消法和均值相消法^[9],既保留了人体微动特征,又滤除了静态干扰。

$$RT_f = Filter\{RT(k)\} \quad (9)$$

$$H(Z) = \frac{0.9697 - 3.8787Z^{-1} + 5.8181Z^{-2} - 3.8787Z^{-3} + 0.9697Z^{-4}}{1 - 3.9384Z^{-1} + 5.8172Z^{-2} - 3.8192Z^{-3} + 0.9403Z^{-4}} \quad (10)$$

1.4 短时傅里叶变换

傅里叶变换只反映出信号在频域的特性,无法在时域内对信号进行分析。为了将时域和频域相联系,Gabor 于1946年提出了短时傅里叶变换(short-time fourier transform, STFT),将信号变换到时频域。短时傅里叶变换在做傅里叶变换之前乘一个时间有限的窗函数 $g(n)$,并假定非平稳信号在分析窗的短时间间隔内是平稳的,通过窗函数 $g(n)$ 在时间轴上的移动,对信号进行逐段分析得到一组局部频谱^[10]。离散信号 $x[n]$ 短时傅里叶变换的定义为:

$$X(\tau, f) = STFT\{x[n]\} = \sum_{n=-1}^{N-1} x[n]g(n-mR)e^{-j2\pi fn} \quad (11)$$

其中, τ 为窗中心所在的时间, m 为窗序号, R 为窗间隔。

对滤波后的时间-距离矩阵 RT_f 的距离单元进行 STFT 并相加,可以得到时间-多普勒矩阵 TD :

$$TD(t, d) = \sum_{k=1}^K STFT\left\{\sum_{t_s=1}^T RT_f(k, t_s)\right\} \quad (12)$$

其中, K 距离单元数, T 为采样时间。为了更好地提取目标运动特征,同时减少计算量,本文在最优距离门限内进行短时傅里叶变换,即 $R \in R^*$ 。

2 残差网络及优化

2.1 残差网络原理

经过上述信号预处理和时频域特征提取后得到了一系列的时间-多普勒谱,接下来要基于这些谱图对人体行为进行分类。传统方法通过解算多普勒带宽、多普勒频率范围、动作发射时间等参数,结合先验阈值来进行分类^[11],虽然算法简单,但是不适合本文的大样本数据集。近年来,随着

深度学习和神经网络的快速发展,使其成为分类任务的主流方法。残差网络(residual neural network, ResNet)是卷积神经网络中一种性能较好的网络结构,它解决了传统 CNN 网络中网络层数增加导致梯度消失或梯度爆炸的问题,在图像检测等领域得到广泛应用。

本文选择 ResNet34^[12]为基础网络模型,为了加快模型训练,将原始模型的输入裁剪为 $1 \times 448 \times 448$ 大小的时间-多普勒特征图。特征提取部分由卷积层、最大池化和残差块(图2)构成,残差结构为[3,4,6,3]。输出分类部分由全局平均池化和全连接层组成。如图1所示,单个残差块包含两个卷积层、批量归一化层、激活函数和一个跳跃连接,其中残差块的功能是在卷积层的输入和输出之间建立联系,从而使网络能够学习卷积层输出相对于输入的相关性。




图1 单个残差块示意图

2.2 注意力机制

深度学习中的注意力机制,是一种模仿人类视觉的信号处理方式,通过对不同部分的特征图赋权重,注意力权重乘以原始特征,以强调重要的特征通道或位置,抑制不重要的特征。这样可以使得模型更加关注与任务相关的特征信息,提高模型的性能和泛化能力。在雷达信号分类时嵌入注意力机制能够降低时间-多普勒谱在杂糅区域影响,有效提升细节特征,改善检测准确率。

卷积注意力(convolutional block attention module, CBAM)是一种结合了通道注意力(channel attention, CA)和空间注意力(spatial attention, SA)的注意力模块^[13]。通道注意力模块关注输入特征图中各个通道之间的关系,其流程如图2所示,最终输出通道注意力的权重 M_c ; 空间注意力模块注重特征图上面的局部关注区域,如图3所示,经过 Sigmoid 函数处理后得到空间注意力权重 M_s 。




图2 通道注意力




图3 空间注意力

将原特征图 F 和通道注意力权重 M_c 、空间注意力权重 M_s 的对应元素相乘,即可得到最终的特征图 F' ,如式(13)所示。

$$F' = M_s \times M_c \times F \quad (13)$$

2.3 量化与校准

随着残差网络层数的增加,其网络参数呈爆炸式的增长,提高了中央处理器(CPU)、图形处理器(GPU)等通用处理器在计算和存储方面的成本。神经网络量化算法作为一种高效的模型压缩算法,其核心思想是将高精度的浮点型参数和相关运算转化为低精度的定点型参数^[14]。在深度学习 Pytorch 框架中数据默认精度为 32 bit 浮点型数据(FP32),而在实际推理中可以对模型进行量化,将其转化为 8 比特整型数据(Int8),使模型所需的存储资源变为原来的四分之一,同时减少系统读写网络参数所需的带宽。

常用的量化函数如式(14)所示,其中, x_{int} 为量化后的整型数据, Δ 为浮点型的缩放因子, Z 为整型的零点偏移因子,加入了零点偏移后,浮点域的 0 被映射到整数域的 Z ,一定程度上消除了量化误差, $round$ 函数通过四舍五入将浮点数转化为整型,相较于向上或向下取整,该函数避免了可能存在的整体偏移。

$$x_{int} = round\left(\frac{x}{\Delta}\right) + z \quad (14)$$

式(14)中的缩放因子 Δ 通常由截断区间和量化位宽来决定,如式 15 所示, α, β 为截断区间的左右端点, b 为量化位宽。

$$\Delta = \frac{\beta - \alpha}{2^b - 1} \quad (15)$$

选择输入截断区间的过程被称为校准,最直接的方法是将待量化数据的最大值和最小值作为截断区间的左右端点,如式(16)所示。

$$\alpha = x_{\min}, \beta = x_{\max} \quad (16)$$

如图 4 和 5 所示,若截断区间关于原点对称,即 $\alpha = -\beta = \max(|x_{\min}|, |x_{\max}|)$,则被称为对称量化,而截断区间的左右端点不关于原点对称,即 $\alpha \neq -\beta$,则被称为非对称量化。对称量化形式简单,能够省去零点偏移相关的额外计算,计算复杂度较低;非对称量化能够更充分利用其量化区间,具有更好的动态映射范围,避免一部分无效的量化区间。基于上述分析,本文采用对称量化和非对称量化相结合的方法,对残差网络进行量化和校准。具体做法是,对于神经网络的权重采用对称量化,对于偏置和激活函数采用非对称量化。

3 实验与分析

3.1 实验处理流程

本文设计了如图 6 所示的雷达人体行为检测信号处理流程,对连续输入啁啾(chirp)的复采样正交信号进行距离 FFT、静态杂波滤除、STFT 得到单通道的时间-多普勒




图 4 对称量化




图 5 非对称量化




图 6 雷达人体行为检测信号处理流程

谱,然后经优化后的残差网络完成分类任务。

3.2 数据集与实验环境

本文的数据集采用英国格拉斯大学公开的“*Radar Signatures of Human Activities*”数据集^[15]。该数据集采集了 6 种人体行为的雷达回波信号,包括喝水、摔倒、弯腰捡物体、坐下、站起、来回走动,这些数据由 20~100 岁之间的志愿者在不同时间和地点完成。数据集采用的雷达为

FMCW 体制,中心频率为 5.8 GHz,扫频带宽为 400 MHz,Chirp 持续时间 1 ms,采样频率 128 kHz。

本文实验环境为 Windows10 操作系统,运行内存 16 G,RTX4060Ti GPU,Intel Xeon W-2102 CPU,CUDA12.3 加速计算。采用 Python3.9 编程语言在 Pytorch2.2 深度学习框架上进行训练和检测。训练参数设置如下:初始学习率设置为 0.001,最大迭代次数为 100。

3.3 雷达信号时频变换

在本文的实验中为了验证所设计的滤波算法有效性,将距离-时间谱通过不同的滤波器得进行对比。均值相消法是对距离通道上的信号减去该通道信号的均值,以消除回波的静态分量。在连续波雷达中沿用脉冲雷达的延迟线对消法消除静态杂波,单延迟线对消和双延迟线对消的传递函数如式(17)~(18)所示。

$$H(z) = 1 - z^{-1} \quad (17)$$

$$H(z) = (1 - z^{-1})^2 = 1 - 2z^{-1} + z^{-2} \quad (18)$$

图 7 为原始时间-多普勒谱和 4 种消除静态杂波后的时间-多普勒谱,图 7(b)在零多普勒频率附近仍然有很大干扰,图 7(c)和(d)虽然在零多普勒频率的杂波得到了抑制,但非零多普勒频率部分的功率谱出现较大的偏差,而图 7(e)零多普勒频率处的干扰较少,主要频率处的功率谱与原始结果比较接近。




图 7 5 种滤波结果

从时频域上来看,目标运动过程中多普勒频率区间内的平均回波功率为:

$$\bar{p} = \frac{\sum_{d=Bin-N}^{Bin+N} \sum_{t=0}^T 20 \times \log_{10}(TD(t, d))}{2NT} \quad (19)$$

其中, TD 为杂波滤除和短时傅里叶变换后的时间-多普勒谱, Bin 为 0.5 倍的最大多普勒单元,多普勒区间为 $(-N, N)$ 。表 1 为不同区间的平均多普勒回波功率。

实验结果表明,由于均值相消法对背景噪声的依赖较大不适合分辨率需求较高的应用场景,零多普勒区间的杂波功率不降反升;延迟线方法对杂波的抑制太强,难以捕捉连续的微多普勒特征。本文采用的方法在整个零多普勒区

表 1 平均多普勒回波功率

N \ P/dB	2	5	10
原始	134.70	137.18	122.74
均值相消	141.76	138.03	127.13
单延迟线对消	80.44	85.80	88.03
双延迟线对消	57.34	59.05	61.89
本文	91.85	92.10	92.84

间内的杂波功率抑制效果适中,起伏程度也最小,降低了多普勒频率的测量误差。

通过上述时频域分析方法将数据集划分为 6 类时间-多普勒谱,如图 8 所示。




图 8 时间-多普勒谱

3.4 数据增强

在深度学习中,通常要求样本的数量充足,因此,在制作完数据集后需要进行数据增强,来提高模型的泛化能力和鲁棒性。相较于传统的图像处理数据增强方法,雷达时间-多普勒谱与时间具有一定的相关性,不能将一般的图像裁剪、旋转、HSV 变化等方法应用到时间-多普勒谱的数据增强上。

本文所采用的数据增强方法是按时间轴移动和置均值,数据增强效果如图 9 所示。由于处理后的二维矩阵的列表示时间,将矩阵按列左右移动,可以模拟目标在时间轴上的运动,从而产生更多的场景;矩阵的每一列数据表示每一个多普勒通道的功率谱,随机取某一列,将这列的全部数

据置为该列信号值的均值,从而增加时间-多普勒谱的检测误差,使其更好地反映真实场景中的情况。




图 9 数据增强结果

3.5 残差网络分类

将本文的网络模型与文献[15]、[16]以及原始 ResNet34 进行对比,所有类的检测准确率分别为 97.33%、78.13%、93.17%、94.55%,本文网络模型的每个人体行为识别的准确率均高于其他方法,混淆矩阵如图 10~13 所示。由图 10 可知,在经过本文所提出的数据增强方法后,较文献[16]不进行数据增强的算法得到的准确率有所下降,主要表现在“弯腰捡物体”和“喝水”、“坐下”和“站起”在随机单位时移和测量误差的作用小,使得这种时间-多普勒谱相似度较高的人体行为难以区分。以 VGG16 为基础的文献[17]以及 ResNet34 的分类深度网络模型,对这种相似




图 10 文献[16]混淆矩阵




图 11 文献[17]混淆矩阵




图 12 ResNet34 混淆矩阵




图 13 本文模型混淆矩阵

度较高的时间-多普勒谱的处理能力明显高于一般堆叠的神经网络。通过本文所提的改进 ResNet34 后“喝水”和“做下”两类目标的检测准确率提高到了 95% 和 100%。

为了验证所提改进算法的有效性,本文进行了一组消融实验,逐步将所提改进方法添加到原始 ResNet34 模型中,结果如表 2 所示。

表 2 消融实验

算法	准确率/ %	计算量/ GMac	模型 大小/MB
ResNet34	94.55	14.2	81.3
ResNet34+CBAM	96.27	14.4	81.4
ResNet34+CBAM+Int8	43.55	7.02	20.5
ResNet34+CBAM+Int8+ Calibration	97.13	7.02	20.5

由实验结果可知,本文在网络的第一层和最后一层加入 CBAM 注意力机制,提高模型的局部和全局注意力特征,注意力热力分布如图 14 所示,该图反映了注意力分布与人体多普勒运动特征呈正相关,CBAM 使检测准确率提高了 1.72%。在使用本文所提残差网络量化后模型的计算量和模型大小均得到大幅度下降,但准确率也下降到

43.55%,在该模型的基础上进行量化处理后恢复其准确率,最终达到97.13%。因此,本文所设计的残差网络将ResNet与CBAM进行了较好的融合,计算复杂度和存储占用都达到了实际应用的要求。




图14 注意力热力分布图

4 结 论

本文将雷达信号处理与神经网络相结合,提出了一种基于雷达时频变换和残差网络的人体行为检测方法。首先,将雷达IQ信号变换进行距离维FFT处理得到时间-距离谱;接着,在每个距离单元内进行静态杂波抑制,提升信号的运动特性;然后,在距离门限内进行短时傅里叶变换得到时间-多普勒谱;最后,设计了一种雷达时间-多普勒谱的数据增强方法并改进了ResNet34残差网络模型,通过训练后的模型完成人体行为分类任务。实验结果表明,本文采用的时频变换方法能够消除静态杂波对多普勒频率的影响,并保留完整的人体运动信息,提高检测的准确率;本文设计的残差网络模型能够较好的实现人体行为检测,准确率达到了97.33%,同时该模型的计算量和模型大小较原始模型得到大幅下降,节省了系统的计算资源和存储空间,有望在嵌入式系统中得到应用。

参考文献

- [1] 李梦荷,许宏吉,石磊鑫,等. 基于骨骼关键点检测的多人行为识别[J]. 计算机科学,2021,48(4): 138-143.
- [2] 岳雨豪,武一,李家兴. 基于可穿戴传感器的家居行为

识别算法[J]. 电子测量技术,2020,43(5): 6-10.

- [3] YANG S, KERNEC J L, ROMAIN O, et al. The human activity radar challenge: Benchmarking based on the 'Radar signatures of human activities' dataset from Glasgow University[J]. IEEE Journal Biomed Health Inform,2023,27(4): 1813-1824.
- [4] YU C, XU Z, YAN K, et al. Noninvasive human activity recognition using millimeter-wave radar[J]. IEEE Systems Journal,2022,16(2): 1-12.
- [5] 丁晨旭,张远辉,孙哲涛,等. 基于FMCW雷达的人体复杂动作识别[J]. 雷达科学与技术,2020,18(6): 584-590.
- [6] LI X, HE Y, FIORANELLI F, et al. Semisupervised human activity recognition with radar micro-doppler signatures[J]. IEEE Transactions on Geoscience and Remote Sensing,2022,60: 1-12.
- [7] 元志安,周笑宇,刘心溥,等. 基于RDSNet的毫米波雷达人体跌倒检测方法[J]. 雷达学报,2021,10(4): 656-664.
- [8] 许志猛,张钊钊,陈良琴,等. 基于时空域增强微多普勒谱图的行为识别方法[J]. 电子测量与仪器学报,2022,36(7): 144-151.
- [9] 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.
- [10] 何密,平钦文,戴然. 深度学习融合超宽带雷达图谱的跌倒检测研究[J]. 雷达学报,2023,12(2): 343-355.
- [11] 李俊侠,张秦,郑桂妹. 超宽带雷达人体姿态识别综述[J]. 计算机工程与应用,2021,57(3): 14-23.
- [12] 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: 770-778.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [14] 何义乾. 神经网络量化算法研究及其在FPGA上的部署实现[D]. 北京: 北京邮电大学,2023.
- [15] FIORANELLI F, SHAH A S D, LI H, et al. Radar sensing for healthcare[J]. Electronics Letters, 2019, 55(19):1022-1024.
- [16] CHEN Z, LI G. Human activity classification with neural network using radar micro-doppler and range signatures [C]. IET International Radar Conference (IET IRC 2020),2021: 222-227.
- [17] 马博昂,张海瑛. 基于改进VGG16的超短时频谱图分类方法[J]. 计算机测量与控制,2022,30(12): 211-217.

作者简介

孙梓誉,硕士研究生,主要研究方向为雷达信号处理与数据处理、深度学习等。

E-mail:202212490553@nuist.edu.cn

顾晶(通信作者),硕士,研究员高级工程师,主要研究方向为雷达信号处理与数据处理、智能感知与信息融合等。

E-mail:121311263@qq.com