

DOI:10.19651/j.cnki.emt.2210883

基于毫米波雷达传感器 RAI 图像的手势识别方法^{*}

许妍¹ 常俊^{1,2} 吴彭¹ 罗金燕¹ 王义元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: 针对现有的手势识别方法存在数据集过少、利用特征信息较少和神经网络部分提取信息不充分的问题,提出一种基于毫米波雷达传感器 RAI 图像的手势识别方法。首先使用 TI 公司的 IWR1443 毫米波雷达传感器采集 10 类手势数据构建数据集,再通过对手部反射的雷达信号进行时频分析,获取固定帧数的 RDI 和 RAI。为了充分提取手势特征并精确分类,在卷积神经网络基础上,引入了残差块和通道注意力块。实验结果表明,相较其他特征如 RDI, RAI 能更准确的表征手势,所提出的网络相比 CNN 方法准确率提高了 12.72%,相比于 VGG16-Net 和单参数 VGG16-Net 方法准确率提高了 8.93% 与 10.41%,参数量降低了 90.68%,时间复杂度降低了 17.2%。

关键词: 手势识别;毫米波传感器;距离角度图像;残差注意力;卷积神经网络

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

Gesture recognition method based on RAI image of millimeter wave radar sensor

Xu Yan¹ Chang Jun^{1,2} Wu Peng¹ Luo Jinyan¹ Wang Yiyuan¹

(1. College of information, Yunnan University, Kunming 650500, China;

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

Abstract: Aiming at the problems that the existing gesture recognition methods have too few datasets, less feature information and insufficient information extracted by the neural network, a gesture recognition method based on RAI image of millimeter-wave radar sensor is proposed. First, use TI's IWR1443 millimeter-wave radar sensor to collect 10 types of gesture data to build a dataset, and then perform time-frequency analysis on the radar signal reflected by the hand to obtain a fixed frame number of RDI and RAI. In order to fully extract gesture features and classify them accurately, residual blocks and channel attention blocks are introduced on the basis of convolutional neural network. Experimental results show that compared with other features such as RDI, RAI can more accurately characterize gestures, the accuracy of the proposed network is increased by 11.78% compared with the CNN method, the accuracy rate of VGG16-Net and single-parameter VGG16-Net is increased by 7.98% and 11.78%, the parameter volume is reduced by 90.68%, and the time complexity is reduced by 17.2%.

Keywords: gesture recognition; millimeter wave sensor; range-angle image; residual attention; convolutional neural networks

0 引言

随着现代社会正在向数字化、网络化、智能化转型,传统通过键盘、鼠标和触屏等接触式的人机交互方式(human-computer interaction, HCI)已经越来越满足不了信息化社会的需要。新兴的非接触式手势人机交互方式可广泛应用于医疗健康^[1]、智慧家居^[2-4]、智能驾驶^[5]、虚拟现实^[6]等领域,成为了国内外学术界和工业界的研究热点。

现有的手势检测和识别技术主要包括基于穿戴式设备^[7]、基于视觉图像^[8-9]、基于超声波^[10]、基于无线通信信号^[11]和基于雷达等方法。基于穿戴式设备需要使用者训练并习惯设备的使用,对使用者有一定的要求,其适用场合也有限。基于视觉图像的方法发展迅速,但受所处环境的光照和设备可视距离影响,且处理数据量大,功耗大,存在一定的隐私安全隐患。基于超声波方法受传播速度和衍射影响明显。基于无线通信信号方法非宽带分辨率低依赖信

收稿日期:2022-07-29

*基金项目:国家自然科学基金(61562090)、云南大学研究生实践创新基金(2021Y190)项目资助

号带宽限制,背景干扰难以滤除。本文采用调频连续波(frequency modulated continuous wave, FMCW)制式的毫米波雷达传感器方法,具备全天候、全天时、小型化的优点,且具有隐私性、安全性的优势。

传感器采用 77~81 GHz 的毫米波段、Chirp 调频连续波和二发四收的多天线技术,能够带来更好的测距、测速、测角分辨率,适合对手势动作信号的检测。借助数据驱动的深度学习方法,进而进行手势动作的分类识别研究,具有显著的应用价值。

目前基于毫米波调频连续波雷达的手势识别研究大多采用从原始数据估计的距离和速度,如时频谱图、微多普勒谱图或距离多普勒图像(range-doppler image, RDI)。文献[12]提出一种基于二维距离多普勒(range-Doppler, RD)的雷达手势识别方法,将雷达回波进行快速傅里叶变换和相干积累,获取目标手势的二维 RD 像,将 RD 像作为卷积神经网络(convolutional neural networks, CNN)的输入进行手势识别;文献[13]考虑了 Chirp 信号的距离信息,将目标手势的时频频谱图作为神经网络的输入来进行手势识别;文献[14]是绘制出目标手势的微多普勒谱图,采用了手势数据的速度和时间两种特征;文献[15]则是同时考虑了每帧的距离和速度信息,将 RDI 作为神经网络的输入。以上方法都仅利用了目标手势的两种特征信息,存在单一数据信息量不足的问题。文献[16]提出一种基于 FMCW 雷达多维参数的手势识别方法,构建具有手势目标的距离、多普勒和角度多维参数的数据集,后结合多维参数(range-doppler-angle of time, RDA-T)卷积神经网络进行学习,虽然解决了数据量信息量不足问题,但是所提出的方法复杂度较高,工作量巨大,不利于实际运用。文献[17]设计出距离-多普勒-时间图特征表征手势,结合轻量化卷积神经网络进行分类,但其方法仅针对微动手势,不符合人们日常生活习惯的手势动作。以上文献神经网络部分大多只采用简单的卷积块堆叠,提取信息不充分。

针对上述问题,本文提出一种基于毫米波雷达传感器的距离-角度图像(range-angle image, RAI)的手势识别方法。首先,通过对大量手势信号的采集和变换处理,形成具有距离、速度和角度特征信息的 RAI 图像,构建标注为 10 类手势的数据集。其次,基于深度卷积神经网络,引入残差注意力机制,构建并训练模型。最后通过与其他网络的对比,验证了该网络能够进行更充分的特征提取,最终获得更高的手势分类准确率。

1 手势识别系统设计

本文构建的基于毫米波雷达传感器的 RAI 图像手势识别方法的整体系统框架如图 1 所示,主要包括数据采集、数据处理、模型训练和手势分类与识别 4 个模块。首先使用 TI 公司生产的 IWR1443BOOST 毫米波雷达开发板和 DCA1000EVM 实时数据采集板在实验室场景下采集

10 类手势原始数据,再对数据进行预处理和时频分析,在距离-多普勒图像的基础上新加入了角度信息,得到了各类手势的距离-角度图像。然后构建了包含手势特征提取和分类的注意力神经网络,该网络在特征提取阶段进行距离-速度-角度信息关注,减少了信息的丢失。最后进行特征分类时,可得到较高的手势分类准确率。

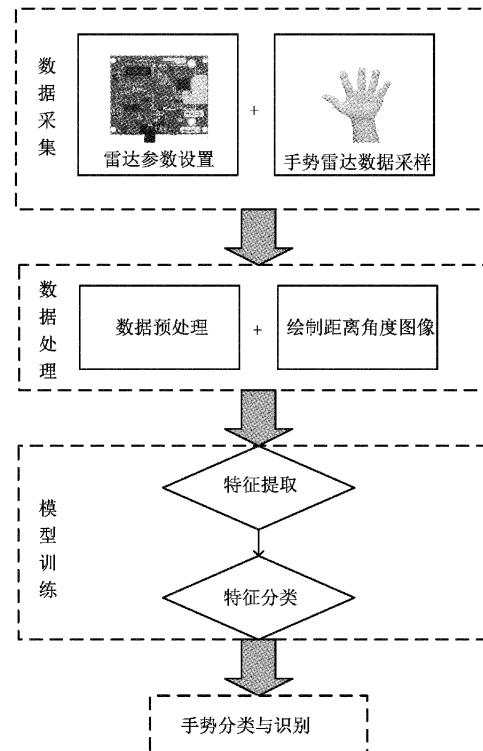


图 1 手势识别整体系统框架

2 数据的获取与处理

2.1 FMCW 制式雷达传感器

FMCW 雷达系统发射的是一种叫做线性调频脉冲的信号,也称 Chirp 信号,其频率随时间呈线性增加,时间带宽较大,利于提高探测分辨率,如图 2 所示。

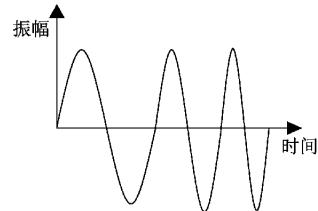


图 2 Chirp 信号

FMCW 雷达传感器由频率合成器(Synth)产生信号,发射天线(TX ant.)将其发射出去,接触到目标后反射出回波,回波被接收天线(RX ant.)接收,接收信号经过混频器后生成中频信号(intermediate frequency signal, IF signal),组成框图如图 3 所示。

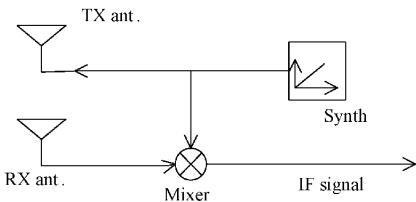


图 3 FMCW 雷达工作原理

则发射信号与接收信号的差频 f 和目标相对雷达的距离 r 表示为：

$$f = S \cdot \frac{2r}{c} \Rightarrow r = \frac{fc}{2S} \quad (1)$$

其中， S 表示 Chirp 信号的斜率， τ 表示雷达与目标之间的往返时间， c 表示光速。利用 IF 信号的相位对物体距离的微小变化非常敏感的特性，可求出 Chirp 信号之间的相位差 $\Delta\varphi$ 与目标物体的速度 v 的关系如式(2)。

$$\Delta\varphi = \frac{4\pi v T_c}{\lambda} \quad (2)$$

其中， T_c 为连续发射 Chirp 信号间隔周期， λ 表示波长。角度估计需要用到多根接收天线，假设每两根天线之间的距离为 d ，目标到达角为 θ ，如图 4 所示。

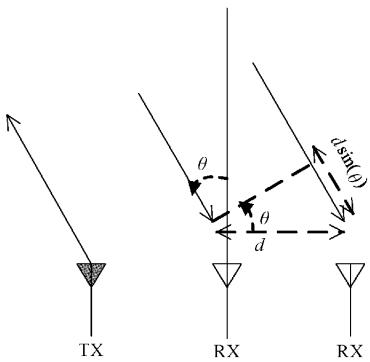


图 4 到达角度估计

通过两个天线接收信号的相位 ω 可得到 θ ：

$$\omega = \frac{2\pi d \sin\theta}{\lambda} \Rightarrow \theta = \arcsin \frac{\omega\lambda}{2\pi d} \quad (3)$$

2.2 数据采集

实验设备使用 TI 公司生产的 IWR1443BOOST 毫米波雷达开发板和 DCA1000EVM 实时数据采集板来评估该手势识别系统的性能。雷达频点为 77 GHz，带宽为 4 GHz，天线采用一发四收，采集板用来获取毫米波雷达芯片输出的中频信号采样数据。FMCW 雷达每帧有 128 个 Chirp 信号，每个 Chirp 信号上有 256 个采样点，每帧持续时间为 40 ms，在实际环境中，一个手势动作时长约为 0.5~1.0 s，本文绘制 32 帧数据的 RAI，持续时长约为 1.3 s(能保证捕捉完整手势)。具体的参数设置如表 1 所示。采取手势数据完成后经以太网传输到戴尔 OptiPlex 3060 台式机上，在 MATLAB 2016a 中进行数据预处理和

生成手势数据相对应的 RAI，卷积神经网络的训练基于 Pytorch 深度学习框架，采用 NVIDIA 公司的 GeForce RTX 2080 显卡进行加速计算。

表 1 雷达传感器参数设置

参数	数量
频点/GHz	77
带宽/GHz	4
天线	1 发 4 收
帧时间/ms	40
采集帧数/帧	32
Chirps/个	128
快时间采样点数/个	256

本次实验邀请了性别和外形不同的 10 名志愿者在实验室场景采集手势数据。要求志愿者分别在距离雷达的 0.3~0.5 m 的位置做如图 5 所示的指定 10 类手势动作：#0:向上，#1:向下，#2:向右，#3 向左，#4 顺时针转圈，#5 逆时针转圈，#6 向上再向下，#7 向下再向上，#8 向左再向右，#9 向右再向左。每名志愿者分别重复每个动作 50 次，共采集 5 000 个数据，每类手势数据采集完以后都用类标签标注，并以 7:3 的比例划分为训练集和测试集。

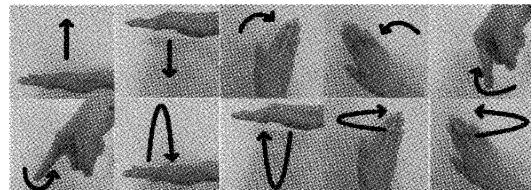


图 5 手势动作示意

2.3 数据处理

将采集到的每个 IF 信号对应的回波数据进行模拟数字转换 (analog-to-digital conversion, ADC) 处理，每个 Chirp 信号上的 N_{adc} 个采样点存储为矩阵的列向量。帧 (Frame) 是由 N_{chirp} 个 Chirp 信号组成的时间序列，再将属于同一帧的 N_{chirp} 个 Chirp 信号对应的列向量级联，得到 $N_{adc} \times N_{chirp}$ 的二维 (two-dimensional, 2D) 矩阵。再对每一个 2D 矩阵快时间维做距离快速傅里叶变换 (fast Fourier transform, FFT)，对矩阵慢时间维做多普勒 FFT。距离 FFT 可得到目标的距离信息，多普勒 FFT 可得到目标的速度信息。取距离-多普勒的绝对值得距离-多普勒矩阵，如图 6 所示。画出前 N_f 帧的距离-多普勒信息，得 N_f 张 RDI。

雷达上的 R 个接收天线接收了同一物体反射的不同相位的数据，将上述得到的 2D 矩阵按 R 个天线级联，得到一个三维 (three-dimensional, 3D) 矩阵。沿着天线维做最后一次 FFT，得到距离-多普勒-角度矩阵，具体过程如图 7。将距离-多普勒-角度矩阵沿着多普勒维求和，得到距离-角度矩阵。画出前 N_f 帧的距离-角度信息，得 N_f 张 RAI。

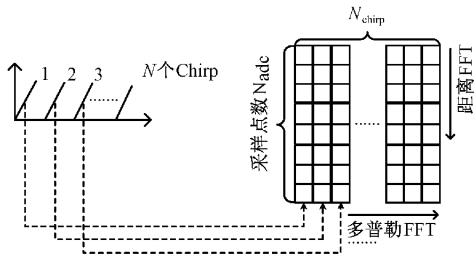


图 6 距离多普勒矩阵

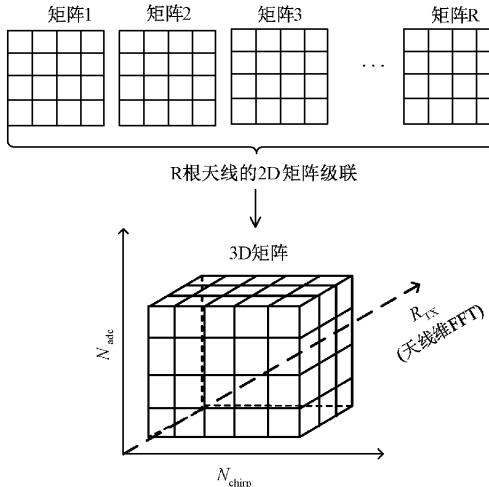


图 7 距离-多普勒角度矩阵

2.4 手势特征图像

图 8 和 9 分别为手势 #0: 向上和 #3: 向左最终的一部分特征图。图 7 所示 RDI 和 RAI 图像中最亮的点都是从较小的距离缓慢移动到较大的距离, 代表手离雷达传感器越来越远。图 8 所示 RAI 图像最亮的点是往左缓慢移动, 而 RDI 图像则几乎观察不到水平运动。证明了角度特征的采用提供了距离和多普勒观察不到的信息。

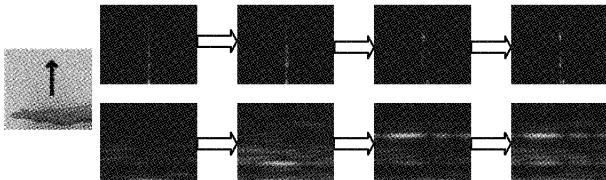


图 8 向上的 RDI 与 RAI

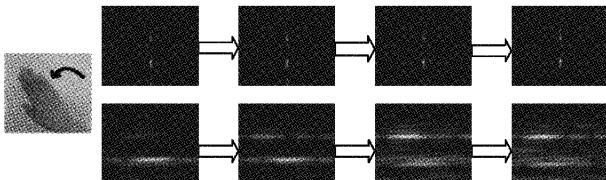


图 9 向左的 RDI 与 RAI

3 网络模型设计

本文结合通道注意力机制, 构建了一个能够用于手势

识别的卷积神经网络。设计的网络整体结构由两部分构成, 特征提取模块、特征分类模块。图 10 展示了卷积神经网络的具体结构。

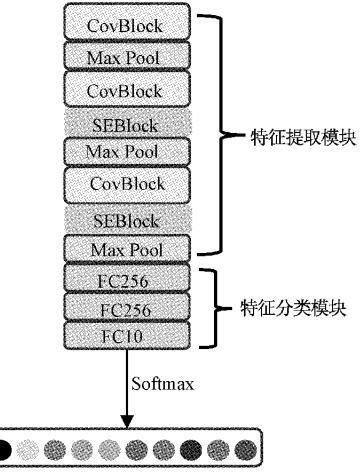


图 10 网络模型

特征提取模块, 主要由卷积块层 (convolution block, ConvBlock)、池化层 Max Pool、压缩块 (squeeze-and-excitation block, SEBlock) 层构成, 其中 CovBlock 层由两个卷积核大小为 1×1 和激活函数 (rectified linear units, ReLU) 组成。与常见的特征提取模块相比, 考虑到池化操作时会丢失一部分信息, 故加入了 SEBlock 进行特征关注, 减少池化时信息的丢失。

特征分类模块, 为了减少特征位置对分类带来的影响, 进行了 3 层分类, 每个线性层后连接一个 ReLU 激活函数层, 增加网络的特征表达能力, 最后经过 softmax 层, 用于输出分类结果和相似度分布数组。

3.1 Res Block 机制

为了避免手势特征提取中出现的梯度爆炸现象, 残差块 (residual block, ResBlock) 被作为一个特征提取模块与通道注意力相结合, 如图 11 所示, 其中输入为 $x^{[l]}$, 输出为 $x^{[l+1]}$ 。 $x^{[l+1]} = \delta(\Gamma(x^{[l]}, \{\Omega_i^{[l]}\}) + x^{[l]})$, 其中 $\Gamma(x^{[l]}, \{\Omega_i^{[l]}\})$ 是一个可学习的残差映射函数, 在图中, $\Gamma(x^{[l]}, \{\Omega_i^{[l]}\}) = BN(\Omega_2^{[l]}(\delta(BN(\Omega_1^{[l]}x))))$, 其中 $\Omega_i^{[l]}$ 代表第 i 个卷积层的权重, BN 代表 Batch Normalization 层, δ 代表激活函数 ReLU。

3.2 SE Block 机制

文献 [18] 提出了压缩与激励网络 (squeeze-and-excitation network, SENet), 该网络能够通过自动学习的方式去获取每个通道的程度, 然后根据其重要程度去提升重要信息, 抑制冗余信息。通过该机制, 该方法能更好的关注 RAI 图像中手势特征的重要信息, 同时区分其相似性, 从而得到较高的准确率。SEBlock 如图 12 所示, 其中 CA (channel attention, CA) module 代表通道注意力模块。让 $F_{N-1} = [f_1, f_2, \dots, f_c]$ 代表通道注意力模块的输入, 有 C

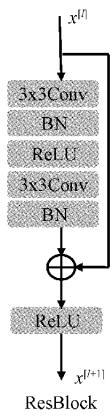


图 11 ResBlock

个通道,空间分辨率为 $H \times W$ 。为了有效聚集特征,首先经过平均池化,其结果如下:

$$\nu_C = \frac{1}{H \times W} \sum_i^H \sum_j^W f_C(i, j) \quad (4)$$

$f_C(i, j)$ 代表 C 通道位置中的值,将全局信息压缩到向量 ν ,为了充分利用聚合信息生成 CA 的掩码 M_{CA} ,对 ν 采用 sigmoid 激活函数 $\sigma(\cdot)$ 的门控机制。

$$M_{CA} = \sigma(\Omega_{CA,2}(\delta(\Omega_{CA,1}\nu))) \quad (5)$$

$\delta(\cdot)$ 代表激活函数 ReLU,其中, $\Omega_{CA,1} \in \mathbb{R}^{C \times (C/r)}$ 和 $\Omega_{CA,2} \in \mathbb{R}^{C \times (C/r)}$ 代表 CA 模块里第 1 个卷积和第 2 个卷积的权重,且卷积核大小为 1×1 ,为了减少计算成本和改善模型的非线性,通道数首先由第 1 个 Conv 层以缩减比 r 减少,然后由 ReLU 操作激活后由第 2 个 Conv 层又增加到 C ,最后经过 sigmoid 激活函数将 $M_{CA} \in \mathbb{R}^C$ 的值映射到 $[0, 1]$ 之间。

$$F_{CA} = F_{N-1} \otimes M_{CA} = [M_{CA,1}f_1, M_{CA,2}f_2, \dots, M_{CA,C}f_C] \quad (6)$$

然后将其经过 Resblock,可得到 F_{CA-RES} ,最后将 F_{CA-RES} 与 F_{N-1} 残差连接可得 F_N 。

$$F_N = F_{N-1} \oplus F_{CA-RES} \quad (7)$$

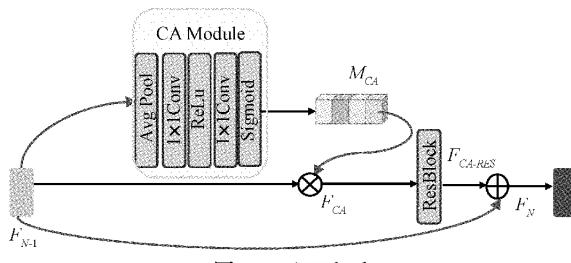


图 12 SEBlock

4 实验结果分析

4.1 网络验证

在本文的网络验证中,RAI、RDI 训练集和测试集数据源相同。每种数据集中的 70% 用于构建训练集,30% 用于构建测试集。每次迭代的 batch_size 为 1,采用随机梯度下

降法(SGD)去优化网络,学习率恒定为 0.000 1,损失函数采用交叉熵损失。

为了选取合适的数据集,在控制其它参数不变的情况下,分别用 RDI 和 RAI 去训练和测试网络。图 13 给出了 RDI 和 RAI 数据集在网络测试时的准确率,由图 13 可知 RAI 数据集在不同迭代步数时对应的准确率都比 RDI 数据集高,且达到了 96% 以上。从而可证明,RAI 能够贡献高质量的手势动作信息。为此,为了达到更好的手势识别效果,本文将采用 RAI 数据集进行网络训练与测试。

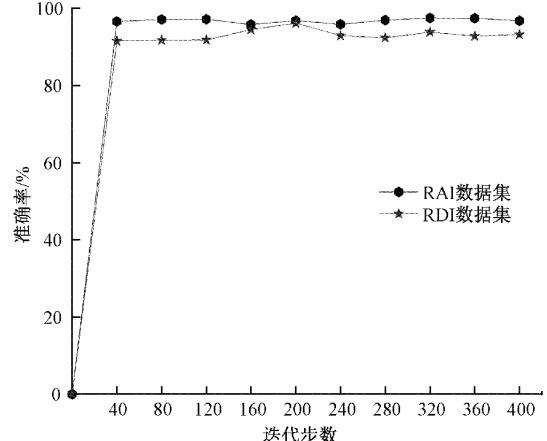


图 13 RDI 和 RAI 的准确率对比

4.2 网络参数寻优和性能分析

基于残差注意力神经网络和 RAI,本节将对不同学习率和迭代步数进行参数讨论和分析。

不同学习率的讨论:学习率是网络一个重要的参数,过大或者过小的学习率都将降低网络的性能,为了避免网络在训练过程中陷入局部最小值,本文将学习率分别设置 0.001,0.000 1,0.000 2,0.000 4,0.000 5 进行训练和测试网络,图 14 给出了测试集上的准确率曲线。显然,当学习率设置为 0.000 1 时得到了较高的准确率曲线。因此,在随后的实验和分析中,选择 0.000 1 为本文网络最佳的学习率。

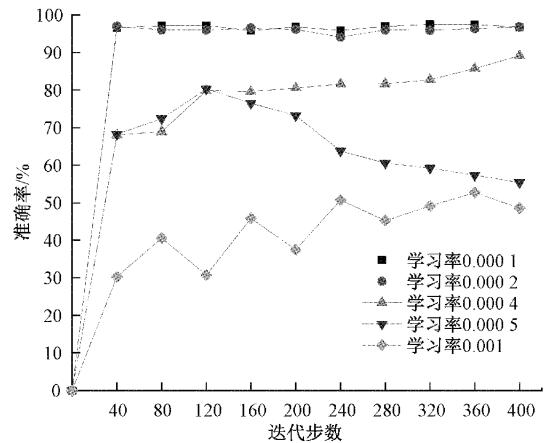


图 14 不同学习率的准确率对比

不同迭代步数的讨论:迭代步数的选取是影响网络性能一个重要参数,过小的迭代步数易出现欠拟合状态。反之,易出现过拟合状态。图 15 给出了不同的迭代步数时的准确率,从图可知,刚开始随着迭代步数的增加,准确率出现较大波动,当迭代步数达到 360 左右时,准确率趋于稳定,后随着迭代步数的增加准确率不再改变。因此,本文最终将迭代步数设置为 400。

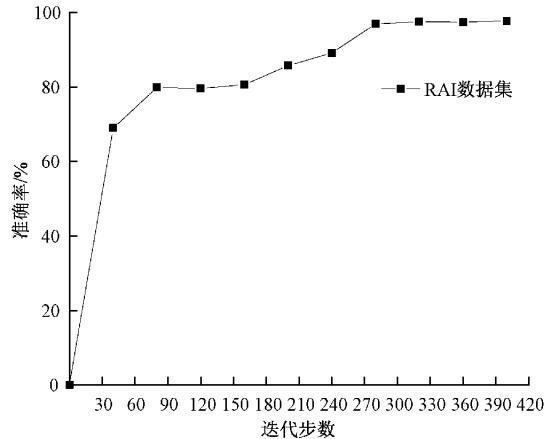


图 15 不同迭代步数的准确率对比

4.3 本文与同类方法的比较与分析

为了验证不同帧数对手势识别性能的影响,本文分别基于 8 帧,16 帧,24 帧和 32 帧的雷达数据构建了数据集,利用残差注意力神经网络进行训练和测试对比,准确率对比由表 2 给出,32 帧数据集达到最高准确率。

表 2 不同帧数准确率

数据集帧数	8	16	24	32
平均准确率	77.50	82.88	85.00	99.54

为了比较同类算法与本文的准确率性能和算法复杂度,本文选择了 CNN^[12]、VGG16-Net^[19] 和 VGG16-Net(单参数网络)^[16]作为对比方法,进行了训练和测试。实验所需的参数遵循了原论文的设置。图 16 给出了 4 种方法的准确率曲线,比较可知,本文提出的方法高于 CNN 网络、VGG16-Net 网络和 VGG16-Net(单参数网络)网络。

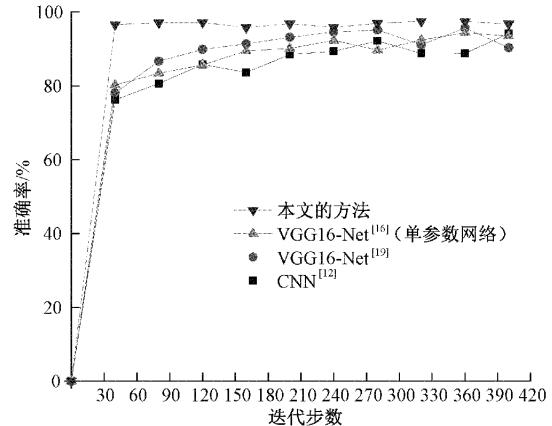


图 16 不同网络准确率对比

在 RAI 数据上对本文网络模型进行评估,得到了表 3 所示的 10 种手势分类的混淆矩阵。同时,表 4 给出了本文方法与其它方法在准确率、参数量、时间复杂度 3 个方面的对比。CNN 虽然拥有了降低的参数量和时间复杂度,但是其识别准确率相对降低。而 VGG16-Net 和 VGG16-Net(单参数网络)与 CNN 相比虽然有较高的识别准确率,但是其参数量和时间复杂度相对较高。本文提出的方法,在保证有较高识别准确率的同时,不会过多增加参数量和时间复杂度,且与 VGG16-Net 相比,准确识别率提高了 6.2%,参数量降低了 90.68%,时间复杂度降低了 17.2%。此外,处理单个样本的时间达到了更低毫秒级别。

表 3 10 种手势分类的混淆矩阵

		预测类别										准确度/ %
		向上	向下	向右	向左	顺时针转圈	逆时针转圈	向上再向下	向下再向上	向左再向右	向右再向左	
真实类别	向上	97.8	2.2	0	0	0	0	0	0	0	0	97.80
	向下	0	100	0	0	0	0	0	0	0	0	100.00
	向右	0	0	100	0	0	0	0	0	0	0	100.00
	向左	0	0	0	100	0	0	0	0	0	0	100.00
	顺时针转圈	0	0.6	0	0.6	98.8	0	0	0	0	0	98.75
	逆时针转圈	0	0	0	0	0	100	0	0	0	0	100.00
	向上再向下	0	0.62	0	0	0	0	99.38	0	0	0	99.38
	向下再向上	0	0	0	0	0	0	0	100	0	0	100.00
	向左再向右	0	0	0	0	0	0	0	0	100	0	100.00
	向右再向左	0	0	0	0	0	0	0	0.62	0	99.38	99.38

表 4 本文与其他方法对比

网络结构	平均准确率/%	参数量(10 ⁶ Params)	时间复杂度(10 ⁹ FLOPs)	单个样本处理时间/ms
CNN ^[12]	86.82	1.68	9.66	0.57
VGG16-Net ^[19]	90.61	121.58	27.63	3.34
VGG16-Net ^[16] (单参数网络)	89.13	3 431.87	21.45	18.48
本文方法	99.54	30.90	10.43	1.098

5 结论

本文提出一种基于毫米波传感器的 RAI 手势识别方法。构建了一个具有 10 类手势的数据集,在采用距离、多勒信息特征进行手势识别的基础上加入角度信息,绘制出同时具有距离、速度和角度信息的 RAI 图像,解决了输入数据单一而信息量不足或信息量足够而工作量大的问题。针对 RAI 图像设计了残差注意力神经网络,实验表明,相较于其他特征如只包含距离、速度两种信息的距离多普勒图像,RAI 能更准确的表征手势,本文所提网络相比于 CNN 方法准确率提高了 12.72%,相比于 VGG16-Net 和 VGG16-Net(单参数网络)手势识别方法的准确率分别提高了 8.93%与 10.41%,参数量降低了 90.68%,时间复杂度降低了 17.2%。从而验证了本文提出的残差注意力神经网络的有效性和可靠性。本文不足之处在于数据集不能囊括日常手势,因此探究如何提升应用价值和提高识别准确率是未来的研究重点。

参考文献

- [1] 吴青聪,张祖国. 基于屏障 Lyapunov 函数的上肢康复机器人自适应主动交互训练控制[J]. 仪器仪表学报, 2022, 43(2): 9.
- [2] BOUCHARD K, BOUCHARD B, GIROUX S, et al. Regression analysis for gesture recognition using passive RFID technology in smart home environments [J]. International Journal of Smart Home, 2014, 8(5): 245-260.
- [3] DINH D L, KIM T S. Smart home appliance control via hand gesture recognition using a depth camera [M]. Smart Energy Control Systems for Sustainable Buildings, 2017, 67:159-172.
- [4] DINH D L, KIM T S, KIM J T. Hand gesture recognition and interface via a depth imaging sensor for smart Home appliances[J]. Energy Procedia, 2014, 62: 576-582.
- [5] KHAN F, LEEM S K, CHO S H. Hand-Based gesture recognition for vehicular applications using IR-UWB radar[J]. Sensors, 2017, 17(4): 833.
- [6] ZENG X, SANG X Z, CHEN D, et al. An interactive VR system based on full-body tracking and gesture recognition [C]. Optical Design and Testing VII,
- [7] 于昌立,范书瑞,刘洋,等. 基于数据手套的无人机端侧控制系统设计[J]. 电子测量技术, 2022, 45(12): 40-47.
- [8] 舒子超,曹松晓,谢代梁,等. 基于三维视觉特征的数字手势语义识别新方法研究[J]. 电子测量与仪器学报, 2021, 35(6): 124-130.
- [9] 王剑波,朱欣娟,吴晓军,等. 融合静态手势特征和手部运动轨迹特征的手势交互方法[J]. 国外电子测量技术, 2021, 40(7): 14-18.
- [10] YANG Q F, TANG H, ZHAO X B, et al. Dolphin: Ultrasonic-based gesture recognition on smartphone platform [C]. IEEE International Conference on Computational Science and Engineering, 2014, DOI: 10.1109/CSE.2014.273.
- [11] ZOU Y, JIANG X, HAN J, et al. GRfid: A device-free gesture recognition system using COTS RFID device[J]. IEEE Transactions on Mobile Computing, 2016, 16(2): 1-1.
- [12] 王俊,郑彤,雷鹏,等. 基于卷积神经网络的手势动作雷达识别方法[J]. 北京航空航天大学学报, 2018, 44(6): 7.
- [13] ZHANG Z, TIAN Z, ZHOU M. Latern: dynamic continuous hand gesture recognition using FMCW radar sensor[J]. IEEE Sensors Journal, 2018, 18(8): 1-1.
- [14] DEKKER B, JACOBS S, KOSSEN A S, et al. Gesture recognition with a low power FMCW radar and a deep convolutional neural network [C]. 2017 European Radar Conference (EURAD), 2017, DOI: 10.23919/EURAD.2017.8249172.
- [15] SUH J S, RYU S, HAN B, et al. 24 GHz FMCW radar system for real-time hand gesture recognition using LSTM [C]. 2018 Asia-Pacific Microwave Conference (APMC), 2018, DOI: 10.23919/APMC.2018.8617375.
- [16] 王勇,吴金君,田增山,等. 基于 FMCW 雷达的多维参数手势识别算法[J]. 电子与信息学报, 2019, 41(4): 822-829.
- [17] 夏朝阳,周成龙,介钧誉,等. 基于多通道调频连续波毫米波雷达的微动手势识别[J]. 电子与信息学报, 2020, 42(1): 9.

- [18] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8):2011-2023.
- [19] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014, DOI: 10.48550/arXiv.1409.1556.

作者简介

许妍,硕士研究生,主要研究方向为毫米波雷达信号处理和手势识别。

E-mail:18760959827@163.com

常俊,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

吴彭,硕士研究生,主要研究方向为毫米波传感器信号处理与生命体征信号探测。

E-mail:wupeng9803@163.com

罗金燕,硕士研究生,主要研究方向为 FMCW 雷达和人体行为识别。

E-mail:18487362521@139.com

王义元,硕士研究生,主要研究方向为深度学习与信道估计。

E-mail:wangyiyuan826@163.com