

基于 EfficientNet 模型的毫米波雷达人体行为识别

陈鑫^{1,2}, 叶宁^{1,2}, 徐康^{1,2}, 王甦^{1,2}, 王汝传^{1,2}

(1. 南京邮电大学 计算机学院、软件学院、网络空间安全学院, 江苏 南京 210023;

2. 江苏省无线传感网高技术研究重点实验室, 江苏 南京 210023)

摘要:针对基于传统光学摄像头实现人体行为识别系统所带来的隐私暴露, 易受光照、遮挡的影响等问题, 设计基于 EfficientNet 模型的 FMCW 雷达人体行为识别系统。首先对 FMCW 雷达实测数据采用距离多普勒算法构建每一帧距离-速度图像; 接着采用逐帧积累的方法延长观测时间窗口, 构建覆盖整个动作过程的距离-速度轨迹; 最后采用改进预训练的 EfficientNet 模型对不同人体行为进行识别。实验结果表明, 在 5 秒观测时间窗口内, 改进预训练的 EfficientNet-B4 模型对已知个体和未知个体 9 种行为识别准确率达到 99.3% 与 98.2%, 均高于传统机器学习方法及经典深度学习方法, 进一步缩短观测时间窗口至 2.5 秒, 改进预训练的 EfficientNet-B4 模型对已知个体和未知个体的 9 种行为识别准确率仍能达到 96.7% 与 95.4%。除此之外, 在 5 秒观测时间窗口内, 所提方法对已知个体和未知个体的 9 种行为识别准确率比常见利用时间-速度提取行为参数的方法分别提高了 3.5% 与 4.9%, 缩短观测时间窗口至 2.5 秒, 所提方法准确率提高了 4.2% 与 4.8%, 可见所提方法可以有效地提升 FMCW 雷达人体行为识别的准确率, 且模型的泛化能力较强。

关键词:调频连续波雷达; 行为识别; 距离多普勒; EfficientNet; 深度学习; 机器学习; 迁移学习

中图分类号: TP391.4

文献标识码: A

文章编号: 1673-629X(2022)09-0134-08

doi:10.3969/j.issn.1673-629X.2022.09.021

FMCW Radar Human Action Recognition System Based on EfficientNet Model

CHEN Xin^{1,2}, YE Ning^{1,2}, XU Kang^{1,2}, WANG Su^{1,2}, WANG Ru-chuan^{1,2}

(1. School of Computer Science, School of Software, School of Cyberspace Security, Nanjing

University of Posts and Telecommunications, Nanjing 210023, China;

2. Jiangsu High Technology Research Key Laboratory for Wireless Sensor Networks, Nanjing 210023, China)

Abstract: Since using traditional optical camera to realize human action recognition system will bring some problems, such as privacy exposure, easy to be affected by light and occlusion, a FMCW radar human action recognition system based on EfficientNet model is designed. Firstly, range Doppler algorithm is used to construct range-velocity images of each frame from the measured data of FMCW radar. Then the range velocity trajectory covering the whole movement process is constructed by using the method of frame-by-frame accumulation to extend the observation time window. Finally, the improved pre-training EfficientNet model is used to recognize different human actions. The experimental results show that within the 5-second observation time window, the accuracy of the improved pre-training EfficientNet-B4 model for identifying nine actions of known and unknown individuals is 99.3% and 98.2%, which are both higher than that of traditional machine learning methods and classical deep learning methods. When the observation time window was further shortened to 2.5 seconds, the recognition accuracy of the improved pre trained efficientnet-b4 model for 9 behaviors of known and unknown individuals could still reach 96.7% and 95.4%. In addition, within the 5-second observation time window, the accuracy of the proposed method for identifying 9 actions of known and unknown individuals is 3.5% and 4.9% higher than the common methods of extracting behavior parameters by time-velocity. When the observation time window is shortened to 2.5 seconds, the accuracy of the proposed method is improved by 4.2% and 4.8%. It can be seen that the proposed method can effectively improve the accuracy of FMCW radar human action recognition, and the model has strong generalization ability.

Key words: FMCW radar; action recognition; range Doppler; EfficientNet; deep learning; machine learning; transfer learning

收稿日期: 2021-09-29

修回日期: 2022-01-31

基金项目: 江苏省科技重点研发资助项目(社会发展)(BE2020713)

作者简介: 陈鑫(1995-), 男, 硕士研究生, 研究方向为雷达信号处理、深度学习; 叶宁, 教授, CCF 高级会员(10059S), 硕导, 博士, 研究方向为无线传感网络信息与安全; 王汝传, 教授, CCF 高级会员(E20-0006259S), 研究方向为无线传感网络信息与安全。

0 引言

近年来,人体行为识别的研究在公共安全、智慧养老、人机交互等领域取得了深入的发展^[1-3]。利用传统光学摄像头在构建人体行为识别系统时会带来隐私暴露、受光照、遮挡等条件影响的问题,具有一定的局限性^[4]。利用雷达等无线射频传感器从人体反射的无线电磁波信号中,提取出人体姿态相关的信息,弥补了传统光学摄像头方法易受光照、物体视线遮挡的缺点,同时更加注重隐私保护,已经成为当前人体行为识别领域研究的一个热点方向^[5]。

目前,基于雷达实现人体行为识别的系统多采用微多普勒技术与机器学习方法。V. C. Chen 于 2000 年开始了最早的对于雷达微多普勒效应的研究,他用实验表明了目标的微动与雷达微多普勒效应之间的联系,利用时频分析法从雷达回波信号中获得了运动目标的微多普勒特征^[6-8]。Kim 和 Ling 从雷达采集的微多普勒图中手动提取了相应的特征,利用支持向量机(SVM)模型进行了人体运动的 7 分类^[9],分类结果的准确率为 92.8%。H. B. Li 利用奇异值分解(SVD)将微多普勒图的熵、频谱质心、带宽分解后的统计量作为特征来进行人体行为识别^[10],准确率达到 80.6%。Bryan 等人将主成分分析(PCA)应用于微多普勒特征的提取,采用机器学习方法对 8 种人体活动进行分类^[11],取得了 85% 以上的准确率。B. Erol 和 M. G. Amin 等人利用多维主成分分析法(MPCA),结合时间、微多普勒和距离信息,实现了基于 FMCW 雷达系统的跌倒检测^[12],准确率最高达到 91.6%。

然而人体微多普勒特征是时变和非平稳的,有时比较微弱且不易稳定提取^[7,13]。人体微多普勒特征主要来自于强回波的躯干,会造成躯干多普勒回波遮蔽肢体多普勒回波的现象,这对提取慢速动作的微多普勒特征十分不利^[14],采用机器学习方法进行特征提取,依赖于开发者的经验,容易忽略各动作的隐藏特性,导致泛化能力较弱。

随着深度学习技术的兴起,无需经验即可自动学习特征的 CNN 模型逐步代替需要人工特征选取的机器学习方法,成功应用于人体行为识别中。Y. M. Shao 等人将微多普勒数据分为实部和虚部两部分,采用基于 Inception 的网络进行训练^[15],识别率达到了 96.9%。Y. Kim 等人将由时频分析法得到的人体运动微多普勒图像输入到 DCNN 网络^[16],获得了 97.6% 的准确率。F. Luo 等人设计并实现了卷积神经网络(CNN),根据类型、数量、活动和粗略定位进行目标分类^[17],获得了 97% 以上的分类准确率。

目前,在人体动作识别研究中,应用深度学习的方法还比较少,这与深度学习需要大量数据集训练

有关。与一般图像分类数据集不同,雷达数据集的制作通常繁琐,制作数据集是一项巨大的工程,因此现实生活中常常面对的是小批量的雷达数据分类任务,由于网络参数过多、数据集太少,使得网络模型难以得到充分的训练或者容易出现过拟合现象。因此需要寻求更高效的深度学习模型,以在较少数据集的情况下实现较高的准确率,同时防止出现过拟合现象,提高模型的泛化能力。

对于一些微多普勒特征较弱的动作,运动期间躯干或肢体的空间位置仍然可能会发生显著变化,如果能够获取躯干或肢体的空间位置信息,将有助于对人体行为进行分类。该文提出了利用 FMCW 雷达进行人体行为识别的新方法,通过距离多普勒算法生成了能够感知人肢体运动速度、距离、信号强度的距离多普勒图像,采用逐帧积累的方式延长观测时间窗口,构建了覆盖整个人体运动过程的轨迹。建立了自己的数据集,并以改进预训练的 EfficientNet 模型为基础来构建该系统。在 5 秒与 2.5 秒的两个观测时间窗口中,在改进预训练的 EfficientNet-B4 模型中获得了已知个体和未知个体 9 种行为识别最高的准确率。

1 行为识别系统构成

该文设计的人体行为识别系统属于非穿戴式检测设备,主要由 FMCW 雷达、数据采集板及 PC 机组成,其系统组成如图 1 所示。FMCW 雷达实测数据经数据采集板采集,以太网传输保存至 PC 机,PC 机一次读取一帧数据,经距离傅里叶变换(Range FFT)、多普勒傅里叶变换(Doppler FFT)绘制人体运动的距离-速度图像,逐帧累积后生成覆盖整个人体行为的运动轨迹。PC 机搭载的改进预训练 EfficientNet 模型可以在经过训练后通过该运动轨迹对人体行为进行有效识别。

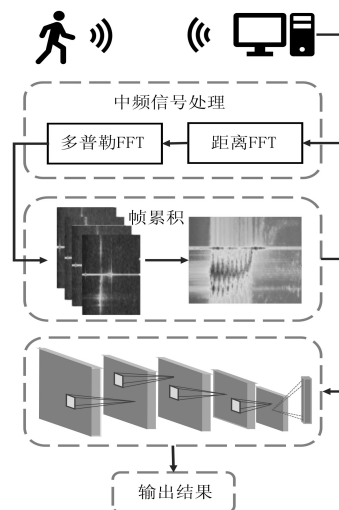


图 1 行为识别系统构成

1.1 调频连续波雷达

该文使用调频连续波雷达又称 FMCW 雷达,其在一个调频周期内,发射天线发射的信号^[18]可表示为:

$$s_T(t) = A_T \cdot \cos[2\pi(f_c t + \pi \frac{B}{T_c} t^2 + \varphi(t))] \quad (1)$$

其中, A_T 为发射信号幅值, f_c 为载波中心频率, B 为带宽, T_c 为信号调频周期, $\varphi(t)$ 为相位噪声。经人体反射后,接收天线接收的回波信号可表示为:

$$S_R(t) = A_R \cdot \cos\{2\pi[f_c(t - t_d) + \pi \frac{B}{T_c}(t - t_d)^2 + \varphi(t - t_d)]\} \quad (2)$$

其中, A_R 为接收信号幅值, t_d 表示信号从雷达发射至接收到人体反射信号的时间, $t_d = 2R(t)/c$, 其中 R 表示目标距离, c 为光速。

接收机将人体反射的回波信号与发射信号混频和低通滤波后得到差拍信号,近似为:

$$S_{IF}(t) = A_{IF} \cos(2\pi f_b t + \varphi_b(t) + \Delta\varphi(t)) \quad (3)$$

其中, A_{IF} 表示接收功率, $f_b = 2BR(t)/cT_c$, 表示差频, 相位 $\varphi_b(t) = 2\pi f_c t_d + \pi B t_d^2 / T_c$ 。在近距离人体运动识别场景中, $\pi B t_d^2 / T_c$ 项可以忽略, 残留相位噪声 $\Delta\varphi(t)$ 也可近似忽略。

最后, 对上述差拍信号采用离散采样, 该差拍信号可表示为数据矩阵的形式:

$$S_{IF}(n, m) = A_{IF} \cdot \cos[2\pi f_b n T_f + \frac{4\pi}{\lambda} R(n T_f + m T_s)] \quad (4)$$

其中, n 表示快时间采样轴上对应的标号, m 表示慢时间采样轴上对应的标号, T_f 表示快时间采样轴上 ADC 采样间隔, T_s 表示慢时间采样轴上 ADC 采样间隔。由此, 得到了所需的雷达采样数据矩阵。

1.2 构建距离多普勒图与帧积累

$S_{IF}(n, m)$ 包含一帧情况下的所有采样数据。对 N 个信号调频周期中的 M 个离散中频采样点数据分别做距离傅里叶变换 (Range FFT) 和多普勒傅里叶变换 (Doppler FFT), 即可得到以距离-速度为坐标轴的人体运动的一帧距离多普勒热图 (Range Doppler Map, RDM)。

人体运动是一个复杂的过程, 一帧数据时间太短, 很难判断某个运动状态, 因此该文采用逐帧积累的方法, 保留每一帧生成的距离多普勒图像, 通过延长观测时间窗口来判断人体运动状态, 其具体流程如图 2 所示。利用此方法, 得到了覆盖人体整个运动过程的距离多普勒轨迹, 并以此作为系统判断人体行为识别的依据。

1.3 EfficientNet 模型

在数据量较少的情况下, 为获得更高的准确率, 深

度学习模型通常会扩展模型的深度、宽度, 又或者是图像的分辨率。传统卷积神经网络尽管可以任意调整这两个或三个维度, 但是都需要繁琐的手动调整, 并且还有可能导致模型性能和效率的下降。为了解决上述问题, Tan M 等人在 2019 年提出了一种新的搜索网络架构 EfficientNet^[19]。EfficientNet 网络的主要构建模块是移动翻转瓶颈卷积 (mobile inverted bottleneck convolution, MBConv)。该模块结构类似于由 Mark 等人 2018 年引入的 MobileNetV2^[20], MBConv 模块引入了压缩与激发 (Squeeze-and-Excitation Network, SENet) 的注意力思想, SENet 注意力机制能够使得网络关注信息量大的通道特征, 抑制不重要的通道特征, 因此能够获得更高的准确率。

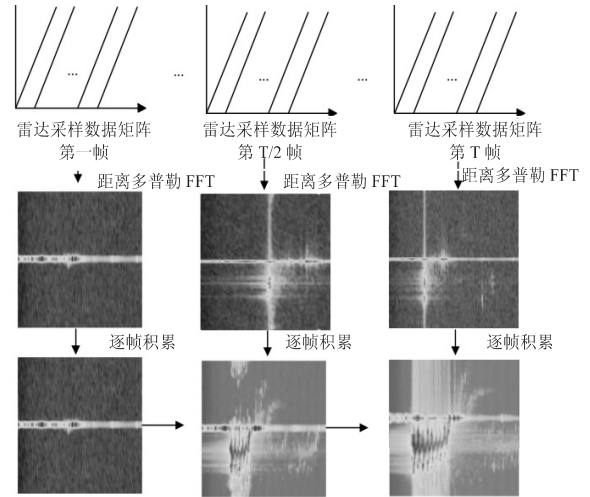


图 2 距离多普勒轨迹构建流程

在此架构基础上, EfficientNet 利用一种复合缩放方法对网络模型的深度、宽度、图像分辨率进行统一的缩放, 其缩放的公式如下:

$$\begin{aligned} \text{depth: } d &= \alpha^\varphi \\ \text{width: } w &= \beta^\varphi \\ \text{resolution: } r &= \gamma^\varphi \\ \alpha &\geq 1, \beta \geq 1, \gamma \geq 1 \end{aligned} \quad (5)$$

其中, α 、 β 、 γ 均为常数, 可通过神经网络搜索得到最优解, φ 是用户指定的系数, 用于控制有多少其他计算资源可用于模型缩放, 当它的值为 1 时, 对应于 EfficientNet-B0。固定 α 、 β 、 γ 的值, 使用不同的 φ 值对应于 EfficientNet-B1 ~ B7。EfficientNet 模型在有限的资源环境下, 可获得比传统深度学习模型更高的性能提升。

1.4 基于改进 EfficientNet 的迁移学习

迁移学习是一种机器学习方法, 它从相似性出发将旧领域学习过的经验知识应用在新领域上。该文使用基于模型的迁移方法。这种迁移方式要求的假设条件是: 源域中的数据与目标域中的数据可以共享一些

模型的参数。为便于比较 EfficientNet 模型各版本的实验效果,实验的 EfficientNet-B0-B7 均已基于 ImageNet 数据集学习了丰富特征表示。为减小模型占用的内存空间,在保留 EfficientNet 核心结构的基础上,采用 GAP 全局平均池化层代替 FC 全连接层。与采用 FC 全连接层相比,该方法可有效降低空间参数,使得模型更加健壮,增加系统向小型设备移植的可能性。针对 EfficientNet 训练参数过多可能导致的模型过拟合问题,在全局平均池化层之后,加入了 Dropout 层,Dropout 层可以在训练过程中有效省略大量的隐藏神经元,保证数据的有效性,同时如果网络在某一层过于依赖某些节点,可以减少或防止数据过拟合。该文还对最后的全连接层进行了调整,使得该网络能够适用于该研究任务。

2 实验与结果分析

2.1 实验设备与参数设定

使用的 FMCW 雷达设备采用 Texas Instruments 公司研发的商用 IWR1642-BOOST 毫米波雷达传感器以及 DCA1000EVM 数据采集板组合。IWR1642-BOOST 毫米波雷达传感器支持 77 GHz~81 GHz 的调频带宽,由 2 个发射天线和 4 个接收天线组成,具有低发射功率、高距离分辨率的特点,几乎不存在测距盲区,可应用于近距离的人体行为识别实验。DCA1000EVM 数据采集板是 Texas Instruments 研发的毫米波雷达传感器数据采集模块,可对雷达数据实时采集并通过以太网传输至 PC 端。本实验设置的雷达参数如表 1 所示。

表 1 FMCW 雷达参数设置

参数	值
调频起始频率 f_0 /GHz	77
调频斜率 K /(MHz/ μ s)	66.6
调频周期 T_c / μ s	160
ADC 采样率 F_s (KSPS)	5 000
ADC 采样点数 N_{adc}	256
帧数	100
帧周期/ms	50
每帧脉冲数 N_{chip}	128

FMCW 雷达的距离分辨率、速度分辨率、最大可观测速度可分别用公式(6)~公式(8)来表示。

$$d_{res} = \frac{C}{2B} \quad (6)$$

$$v_{res} = \frac{\lambda}{2N_{chip} T_c} \quad (7)$$

$$v_{max} = \frac{\lambda}{4T_c} \quad (8)$$

其中, C 表示光速, B 表示调频带宽,且 $B = K \times N_{adc}/F_s$, λ 为发射波长, $\lambda = C/f_0$,其余相关变量均在表 1 给出。

对于表 1 中的雷达参数配置,求得本实验的距离分辨率约为 4.40 cm,速度分辨率约为 0.095 m/s,最大可观测速度为 6.09 m/s。

该文使用的所有深度学习模型都是在 GPU 支持下编译的。所有实验研究都是在 Windows10 操作系统上运行,该操作系统运行在 Intel(R) Core(TM) i5-8400CPU@2.80 GHz 和 16 GB RAM 上, GPU 型号为 NVIDIA GTX1080Ti,深度学习的代码在 Keras2.4.3 及 Tensorflow2.4.0 上运行,利用了 Anaconda 集成于 Pycharm 中的框架。

2.2 实验数据采集与数据预处理

2.2.1 实验数据采集

为验证所提方法具有较高泛化能力,实验分两组进行,第一组由同一位实验者在室内场景采集,该实验者身高 1.82 m,第二组数据由 8 位实验者在室内或者室外不同场景采集,身高从 1.58 m~1.85 m 不等。实验过程中,IWR1642-BOOST 及 DCA1000EVM 被固定于三脚架,距离地面约 80 cm,除实验对象外无其他运动目标干扰,在雷达与实验者直线距离中无静态物体摆放。总共采集了 9 组人体动作,在第一组实验中,每个动作均由同一实验者重复采集 300 组,总共 2 700 条数据。第二组实验中,每个动作由 8 位实验者共同采集完成,每人每个动作 10 组,总共 720 条数据。为确保高质量距离多普勒热图生成,两组实验对象随机站在雷达前 1 m~12 m 范围,每一组动作采集时间均为 5 s,对应 100 帧的数据。

2.2.2 数据预处理

该文设计的系统可以识别 9 种人体行为,图 3 展示了实验中的 9 种行为描述。首先雷达传感器采集的数据经数据采集板实时传输至 PC,PC 端每次读取一帧数据并利用距离多普勒算法逐帧绘制 2D 距离多普




图 3 9 种人体行为描述

勒图像,以 100 帧数据为一个断点生成一组动作的距离多普勒轨迹,大小为 380×380 。实验生成了 9 种动作对应的距离多普勒轨迹,如图 4 所示。中心轴线上上方为检测到的运动物体远离雷达方向,下方为检测到运动物体靠近雷达方向。从图中可以看出,对于位移明显的人体行为,延长观测时间窗口能够清晰展示其对应的特征,由于以距离和速度为坐标轴,获得的特征图具有一点的可解释性。




图 4 9 种人体行为的距离多普勒轨迹




图 5 PCA 降维特征

表 2 机器学习方法识别结果

模型	已知个体 Acc	未知个体 Acc
决策树	0.92	0.88
KNN	0.87	0.84
SVM	0.78	0.74
朴素贝叶斯	0.72	0.66

2.4 基于深度学习模型的行为识别

2.4.1 改进 EfficientNet 模型及训练策略

为了能够比较得到最佳精度的 EfficientNet 模型,在 EfficientNetB0-B7 结构中融入了相同的改进方法及迁移学习策略,图 6 展示了取得最高精度的模型 EfficientNet-B4 的网络结构。为了能够降低训练数据集过小对准确率的影响,以及快速得到最佳的精度,采用了迁移学习的方法进行模型参数的初始化。为此通过加载在 ImageNet 数据集上预训练的 EfficientNet 权重

2.3 基于机器学习模型的行为识别

为了验证本系统行为识别的准确率优于传统使用机器学习方法构成系统的准确率,首先采用本领域常用的基于主成分分析^[11,21]的特征提取方法,并选取决策树模型、KNN 模型、SVM 模型、朴素贝叶斯模型等机器学习方法来构建系统,完成了行为识别。首先对所有的距离多普勒轨迹图进行灰度化并调整大小为 256×256 ,再通过 PCA 方法将其降维为 64 维的向量,该 64 维向量对原始特征的累计贡献率达到了 99%。经主成分分析降维后的特征图像如图 5 所示。对经过主成分分析降维后的数据,实验采用了基于决策树、最近邻算法(KNN)、支持向量机(SVM)、朴素贝叶斯的机器学习方法进行训练和分类,其中用于训练的数据占第一组数据的 70%,系统对已知个体和未知个体的行为识别结果如表 2 所示。由表 2 可知决策树模型在本轮实验获得了双最高的准确率,对于已知个体的 9 种行为识别,其总体准确率达到 92%。利用已知个体的训练模型对未知个体的行为进行预测,其对 9 种行为预测的总体准确率也达到了 88%。由此可知,使用机器学习方法对该文实验数据进行特征提取后分类的方法是可行的,但实验准确率还有较大提升空间。

对去除全连接层的 EfficientNet 网络模型进行参数初始化,考虑到 ImageNet 数据集和实验数据集之间的巨大差异,对于网络层的训练从每一层重新开始。为了缩小模型空间参数,防止网络过拟合以及提升模型的准确率和泛化能力,用 GAP 全局平均池化替代了 FC 全连接层,在 Dense 层前加入了 dropout 模块,其比例为 0.5。最后一层选择 Softmax 作为激活函数,选择分类交叉熵作为损失函数。采用 Adam 优化器,初始学习率为 0.000 1,每次输入网络的样本量 Batch_size 为 8。




图 6 改进 EfficientNet-B4 模型结构

将 5 秒观测时间窗中对已知个体采集的 2 700 条数据按照 7 : 2 : 1 的比例划分为训练集、验证集、测试集,并将对未知个体采集的 720 条数据全部划分为测试集,以验证模型的泛化能力。在改进预训练的 EfficientNet 架构中,准确率最高的 EfficientNet-B4 模型的迭代曲线如图 7 所示。从图中可以看出,在 100 个 epoch 中,本实验在训练集与验证集上的准确率经过 20 个 epoch 后即逐渐趋于平稳,最终均能够接近 100%。以同样的方法对 VGG16、ResNet50、Xception、Inception-V3、MobileNet-V2 进行了改进和预训练,并将结果与改进预训练的 EfficientNet 结果做对比,其比较结果如表 3 所示。从表 3 中可知,对应于 5 秒观测时间窗口,基于改进预训练的 EfficientNet-B4 模型组成的系统对已知个体和未知个体行为识别的准确率均达到最高,分别为 99.3% 和 98.2%,表明系统具有较高准确率且泛化能力较强。进一步缩短测试集的观测时间窗口至 2.5 秒,系统对已知个体和未知个体行为

识别的准确率仍能达到最高 96.7% 与 95.4%。通过与表 2 采用机器学习的方法进行比较,发现采用深度学习方法对已知个体和未知个体的行为识别准确率均远超机器学习方法,因此本系统更适合采用深度学习的方法。




图 7 改进 EfficientNet-B4 迭代曲线

表 3 深度学习实验结果比较

模型	5 秒观测时间窗		2.5 秒观测时间窗	
	已知个体 Acc	未知个体 Acc	已知个体 Acc	未知个体 Acc
EfficientNet-B0	96.3	93.5	93.3	90.5
EfficientNet-B1	97	96	94.7	91.1
EfficientNet-B2	98.1	97.8	95.5	92.8
EfficientNet-B3	98.5	97.8	95.8	94.3
EfficientNet-B4	99.3	98.2	96.7	95.4
EfficientNet-B5	98.5	94.4	95.6	93.3
EfficientNet-B6	98.1	92.8	94.5	91.7
EfficientNet-B7	97	93.1	92.5	91
VGG16	97.4	91.1	93.3	89.5
ResNet50	96.7	95.2	92.8	90.5

续表 3

模型	5 秒观测时间窗		2.5 秒观测时间窗	
	已知个体 Acc	未知个体 Acc	已知个体 Acc	未知个体 Acc
Xception	98.5	96.7	95.2	93.3
Inception-V3	98.5	97.8	96.7	94.3
MobileNet-V2	97	94.3	92.5	90.5

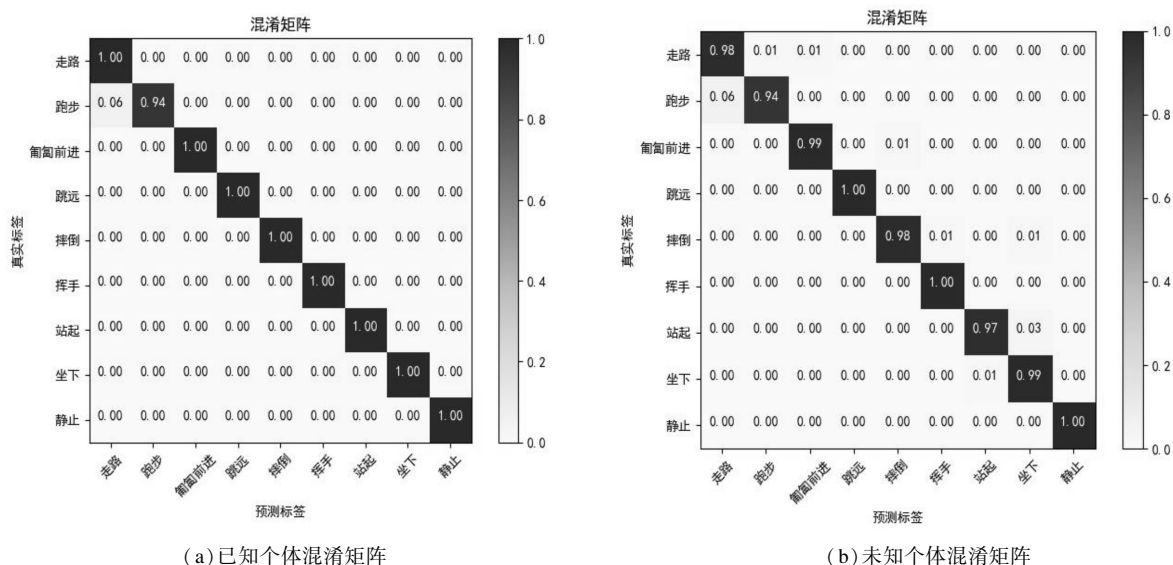


图 8 EfficientNet-B4 混淆矩阵

通过进一步评估 5 秒 EfficientNet-B4 模型在已知个体与未知个体的测试集中的表现,得到了如图 8 所示的混淆矩阵,其中(a)为已知个体识别的混淆矩阵,(b)为未知个体识别的混淆矩阵。通过对混淆矩阵的分析,发现最容易出现分类错误的人体行为是跑步,常常被错分为走路,原因可能是因为跑步的速度过慢,产生的距离多普勒轨迹与走路过于相似。除此之外的其他行为分类,几乎不存在误分类的情况。

表 4 距离多普勒与微多普勒实验结果比较

参数提取方法	5 秒观测时间窗口		2.5 秒观测时间窗口	
	已知个体 Acc	未知个体 Acc	已知个体 Acc	未知个体 Acc
微多普勒	95.8	93.3	92.5	90.6
距离多普勒	99.3	98.2	96.7	95.4

由表 4 可知,对应 5 秒和 2.5 秒观测时间窗口,缺少距离特征后行为识别系统仍能保持较高准确率,但准确率均有所下滑,由此可以证明对上述 9 种人体行为,采用距离-速度提取行为参数的方法更加具有优势。

3 结束语

针对微多普勒特征提取以及机器学习分类的弊端,提出了一种新的雷达实现人体行为识别的方法。该方法的基础是根据距离多普勒算法产生以距离-速

2.4.2 距离多普勒与微多普勒实验对比

为进一步验证采用距离-速度提取行为参数的优势,本节采用本领域常见的利用微多普勒特征进行参数提取实验,并利用 EfficientNet-B4 模型进行建模。仍然按照 2.4.1 节的训练策略,仅利用时间-速度进行参数提取的实验结果与利用距离多普勒提取行为参数的实验结果进行比较,如表 4 所示。

度为标轴的每一帧图像,并以逐帧积累的方式产生能够区分人体 9 种运动的轨迹。根据产生的特征图,在雷达进行人体行为识别的方法中首次利用改进预训练的 EfficientNet 模型来构建整体架构,并在 Efficient-B4 模型中取得了最高的准确率。验证了利用深度学习方法的优越性,能够大幅度提高系统的准确率。比较了距离多普勒方法与微多普勒方法对识别准确率的影响,通过对已知个体和未知个体的 9 种人体行为识别验证了模型具有较高的泛化能力。

当然,该系统尚存在一些局限性,仅实现了对面向

雷达的上述9种动作有效识别,下一步将利用多块雷达传感器,从不同方位进行数据采集,以争取识别更多更复杂的人体动作。

参考文献:

- [1] 张莹莹,郭星. 基于 Kinect 动态手势识别算法的研究与实现[J]. 计算机技术与发展,2017,27(12):11-15.
- [2] 刘勇,谢若莹,丰阳,等. 智能家居中的居民日常行为识别综述[J]. 计算机工程与应用,2021,57(4):35-42.
- [3] 高新闻,沈卓,许国耀,等. 基于多目标跟踪的交通异常事件检测[J]. 计算机应用研究,2021,38(6):1879-1883.
- [4] 蒋留兵,魏光萌,车俐. 基于字典学习的 77 GHz 雷达人体动作识别[J]. 科学技术与工程,2020,20(6):2317-2324.
- [5] LI X Y, YUAN H, JING X J. A survey of deep learning-based human activity recognition in radar[J]. Remote Sensing,2019,11(9):1068.
- [6] CHEN V C, LIPPS R D. Time frequency signatures of micro-Doppler phenomenon for feature extraction[J]. Proceedings of SPIE,2000,4056:220-226.
- [7] CHEN V C. Micro-Doppler effect of micro-motion dynamics: a review[J]. Proceedings of SPIE,2003,5102:240-249.
- [8] CHEN V C. Spatial and temporal independent component analysis of micro-Doppler features[C]//2005 IEEE international radar conference. Arlington:IEEE,2005:348-353.
- [9] 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):1328-1337.
- [10] LI H B, SHRESTHA A, FIORANELLI F, et al. Multi sensor data fusion for human activities classification and fall detection[C]//2017 IEEE sensors. Glasgow:IEEE,2017:1-3.
- [11] BRYAN J D, KWON J, LEE N, et al. Application of ultra-wide band radar for classification of human activities[J]. IET Radar Sonar Navigation,2012,6(3):172-179.
- [12] EROL B, AMIN M G, BOASHASH B. Range-Doppler radar sensor fusion for fall detection[C]//2017 IEEE radar conference (RadarConf17). Seattle:IEEE,2017:819-824.
- [13] 庄钊文,刘永祥,黎湘. 目标微动特性研究进展[J]. 电子学报,2007,35(3):520-525.
- [14] 谢晓兰,陈梓涵. 基于时间距离像的人体动作深度学习分类[J]. 桂林理工大学学报,2019,39(1):197-203.
- [15] SHAO Y M, DAI Y L, YUAN L Z, et al. Deep learning methods for personnel recognition based on micro-Doppler features[C]//Proceedings of the 9th international conference on signal processing systems. Auckland: Association for Computing Machinery,2017:94-98.
- [16] KIM Y, MOON T. Human detection and activity classification based on micro-Doppler signatures using deep convolutional neural networks[J]. IEEE Geoscience & Remote Sensing Letters,2016,13(1):8-12.
- [17] LUO F, POSLAD S, BODANESE E. Human activity detection and coarse localization outdoors using micro-Doppler signatures[J]. IEEE Sensors Journal,2019,19(18):8079-8094.
- [18] AHMAD A, ROH J C, WANG D, et al. Vital signs monitoring of multiple people using a FMCW millimeter-wave sensor[C]//2018 IEEE radar conference (RadarConf18). Oklahoma City:IEEE,2018:1450-1455.
- [19] TAN M, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks[C]//Proceedings of the 36th international conference on machine learning. Long Beach: ACM,2019:6105-6114.
- [20] SANDLER M, HOWARD A, ZHU M L, et al. MobileNet V2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF conference on computer vision and pattern recognition. Salt Lake City:IEEE,2018:4510-4520.
- [21] 王文兵,李华,梁龙. 基于微多普勒特征的外辐射源雷达目标识别方法[J]. 电子信息对抗技术,2018,33(5):20-25.