

## 基于可穿戴设备的姿势识别方法研究

吴秋雯, 廖薇

上海工程技术大学电子电气工程学院, 上海 201620

**【摘要】**针对现有的基于图像以及毫米波雷达进行人体姿势识别在医疗保健领域存在的不足,提出一种基于人体区域通信技术的穿戴式姿势识别方法。该方法通过人体姿势导致的信道衰减进行姿势识别。文中首先建立了人体站、蹲、坐、跑、走5种姿势模型,并在人体上放置1个发射器、2个接收器,构成两条信道,计算5种姿势下的信道衰减作为数据集。然后,对两条信道分别使用多种单一分类器进行识别,获得94.33%的最高准确率。最后,通过Stacking方法融合两条信道的特征得到99.67%的准确率。结果表明,基于人体区域通信技术的穿戴式姿势识别方法是可行的,并利用Stacking特征融合方法使识别结果相比单一特征下的最高准确率提高了5.34%。

**【关键词】**可穿戴设备;人体区域通信;信道衰减;姿势识别

**【中图分类号】**R318;TN915

**【文献标志码】**A

**【文章编号】**1005-202X(2023)08-1002-07

### Pose recognition method based on wearable device

WU Qiuwen, LIAO Wei

School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

**Abstract:** A pose recognition method using wearable devices and human body area communication technology is proposed to overcome the drawbacks of current methods based on image and millimeter wave radar and realize the recognition through the channel attenuation caused by human posture. Five postures of human standing, squatting, sitting, running and walking are modeled, and two channels are constructed with one transmitter and two receivers for calculating the channel attenuation with 5 postures as the data set. The highest recognition accuracy of multiple single classifiers for the two channels is 94.33%, and the accuracy is improved to 99.67% with feature fusion of the two channels using Stacking method. The results show that the pose recognition method using wearable devices and human area communication technology is feasible, and that the highest accuracy rate using Stacking feature fusion is improved by 5.34% as compared with single feature.

**Keywords:** wearable device; human body area communication; channel attenuation; pose recognition

### 前言

人的行为与动作往往能够通过人体的姿势表现出来,因此对姿势进行识别是可行的<sup>[1]</sup>。伴随着人口深度老龄化以及少子化的发展趋势,通过姿势识别能够对空巢老人的行为安全提供解决方案,同时能够缓解医院陪护人员人手不足造成的医疗资源短缺问题。由此可见,姿势识别在医疗保健领域的应用具有广阔的前景<sup>[2]</sup>。

现如今,针对姿势识别的研究中,Jaj等<sup>[3]</sup>从RGBD图像中提取反应人体姿势的骨架数据,对其分割后创建代表整个活动的特征向量进行姿势识别。Huang等<sup>[4]</sup>通过使用3D卷积神经网络(Convolutional Neural Network, CNN)模型计算以时间序列为基准的人类姿势特征,用于视频中的姿势识别。刘帅<sup>[5]</sup>利用光学图像采集器采集运动姿势图像,将从图像中提取的信息融合后完成姿势识别工作。上述方法都是基于监控摄像机进行的,有暴露隐私的风险,同时对天气等外部环境变化较为敏感,由此衍生出另一种通过雷达信号进行姿势识别的方法。邓泽夫<sup>[6]</sup>利用毫米波雷达,通过卷积神经网络-支持向量机(CNN-SVM)方法实现人体姿势识别。冯心欣<sup>[7]</sup>基于调频连续波(Frequency Modulated Continuous Wave, FMCW)雷达,针对获取到的受姿势影响产生的FMCW信号进行信息提取,对多源信息融合实现了

**【收稿日期】**2023-03-26

**【基金项目】**国家自然科学基金(62001282)

**【作者简介】**吴秋雯,硕士研究生,研究方向:人体区域通信, E-mail: wuqiwen97@163.com

**【通信作者】**廖薇,副教授,上海高校青年东方学者,硕士生导师,研究方向:人体区域通信、生物电磁学、医疗领域电磁兼容性, E-mail: liaowei54@126.com

姿势识别。该方法虽然不受环境的影响,但是在医疗领域更适合单人的场景。因为,在单人场景下可以直接发出警报,而当毫米波雷达范围内人数增多时难以判断发出安全提醒的具体目标。

由此,本文提出一种基于人体区域通信技术的穿戴式姿势识别方法,通过单人体域网中的可穿戴设备进行姿势识别可以有效地解决上述问题。本文首先对同一人体的站立、蹲、坐、奔跑以及行走5种姿势建模,并在人体上设置由收发器构成的信道,然后计算由人体姿势导致的信道衰减曲线作为姿势识别的数据集,最后,将数据集输入分类器进行分类识别。

## 1 实验数据集

### 1.1 多姿势人体建模

由于构成细胞的主要成分是水,同时,人体内的电荷伴随外部磁场的作用会发生迁移,故而使得人体能够导电。由此可见,人体是具有电特性的有耗媒介<sup>[8]</sup>。人体组织在不同区域的介电谱中发生的色散与人体组织中大分子的极化相关。上述现象使人体组织具有与频率相关的复介电常数特征。因此,一般使用介电特性对人体组织的相关特性进行建模,可以使用Debye公式表示人体组织的复介电常数特征以及电导率<sup>[9-10]</sup>:

$$\varepsilon_r(\omega) = \varepsilon_\infty + \frac{\sigma_0}{j\omega\varepsilon_0} \quad (1)$$

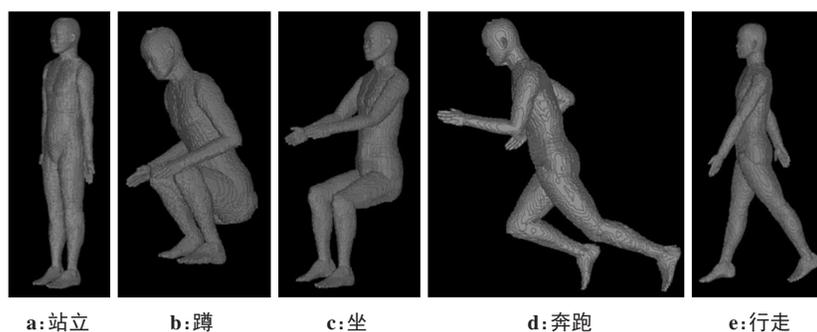


图1 姿势建模图

Figure 1 Posture modeling

为了获取更多的数据用于后续的姿势识别,使得本文实验结果更加准确。在上述5种不同类型的姿势中,对每种类型的姿势设置了10种不同状态的姿势,以增加姿势识别中5种姿势的样本多样性,图2为站立姿态的10种不同状态。

### 1.2 数据采集

在建立好的多姿势模型上设置接收端与发射

式(1)中,第一项代表无穷频率的介电常数,后一项描述色散程度<sup>[11]</sup>。利用公式(1)表征人体模型上人体相关组织的介电特性,该特性被认为是人体相关电磁场的重要特性,主要由电导率和介电常数描述<sup>[12]</sup>。鉴于人体的电磁特性与频率相关,所以在进行人体建模时需要明确在工作频段下各个人体器官组织的介电参数特征,基于本文工作的超宽带(Ultra-Wideband, UWB)频段参数如表1所示。

表1 UWB频段部分人体组织介电参数特征

Table 1 Dielectric parameters of some human tissues in UWB band

组织	电导率/S·m <sup>-1</sup>	相对介电常数
皮肤	4.673 1	34.22
肌肉	6.266 3	47.06
心脏	7.265 5	47.23
脂肪	0.363 27	4.86

为进行基于人体通信的姿势识别研究,还需要进行人体多姿势建模。本文建立的人体模型身体尺寸数据是基于亚洲成年男性统计数据库得到的<sup>[13]</sup>,人体模型为身高175 cm、体重65.57 kg、身材中等的成年男性。对该男性人体模型设定了5种不同类型的姿势,分别为站立、蹲、坐、奔跑以及行走,如图1所示。

端,通过两个大小为3 cm×3 cm×0.02 cm的PCE材质电极片构成收发极,两个电极片间距为0.5 cm,位于左胸的发射极还包含一个高斯脉冲作为信号的激励。鉴于本文的研究目的是在单人体域网中通过信道衰减对站、蹲、坐、走、跑这5个姿势进行识别,因此需要在人体上选择合适的部位作为接收极的安放位置。由于UWB频段下电磁波是沿着体表轮廓传播

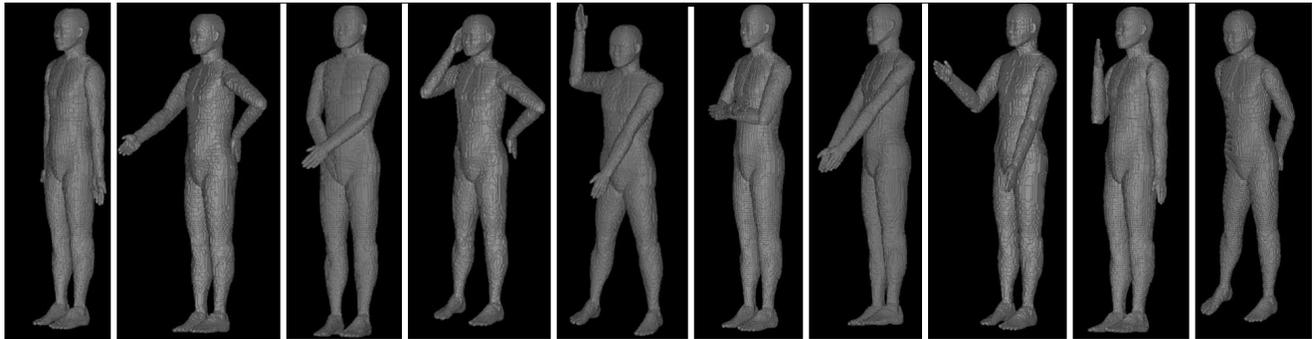


图2 站姿的10种状态

Figure 2 Ten standing postures

的,因此接收极的位置需要尽可能地包含这些姿势的运动部位。结合实际应用考虑,可以将接收极作为智能穿戴式设备,并设置在左、右脚踝位置,将构成的左胸-左脚踝信道与左胸-右脚踝信道分别命名为L1、L2。

本文使用时域有限差分法(Finite Difference Time Domain method, FDTD)对人体模型进行电磁场数值分析<sup>[14]</sup>,该方法由Maxwell方程得出:

$$\frac{\partial E}{\partial t} = -\frac{\sigma}{\varepsilon} E + \frac{1}{\varepsilon} \nabla \cdot H \quad (2)$$

$$\frac{\partial H}{\partial t} = -\frac{1}{\mu} \nabla \cdot E \quad (3)$$

其中, $E$ 和 $H$ 分别为电、磁场强度; $\sigma$ 、 $\varepsilon$ 、 $\mu$ 分别为电导率、介电常数以及磁导率。人体模型上发射极的激励源发射信号,使用电磁仿真软件得到接收极接收的信号,然后通过公式(4)得到生物特征(路径损耗):

$$PL_{ab} = 10 \lg \frac{\int_{f_L}^{f_H} |F[v_i(t)]|^2 df}{\int_{f_L}^{f_H} |F[v_r(t)]|^2 df} \quad (4)$$

其中, $v_i(t)$ 、 $v_r(t)$ 分别为发射、接收电压, $F$ 为傅里叶变换<sup>[15]</sup>, $f_H=10.6$  GHz, $f_L=3.1$  GHz。

考虑到将接收极以脚环的形式进行实际应用时,脚环可能会随着人体运动出现位置的轻微移动,因此接收极的位置在每次测量时不可能完全相同。所以,本文通过对接收极位置在每个方位进行细微的移动,移动距离不超过2 mm,并测量每次移动后接收到的信号。也就是对每种姿势下10个不同状态模型的每条信道进行20次测量,每次测量获得由1001个点组成的信道衰减曲线。最终,每种姿势单个信道的样本数量为200条,构成单一信道下5种姿势的样本数为1000条,每组特征数据有1001个特征值,L1、L2信道总共计算得到2002000个数据。

## 2 姿势识别分类方法

### 2.1 单一分类模型

本文选取常用的随机森林(Random forest, RF)<sup>[16]</sup>、SVM<sup>[17]</sup>、K-近邻(K Nearest Neighbors, KNN)<sup>[18]</sup>、多层感知机(Multilayer Perceptron, MLP)<sup>[19]</sup>以及梯度提升树(Gradient Boosting Decision Tree, GBDT)<sup>[20]</sup>共5种机器学习分类模型进行姿势识别分类。(1)RF。RF是针对决策树缺点进行改进而开发形成的新技术,属于bagging集成算法的一种,具有较高的精度。它灵活且易于使用,对超参数调整的要求较低<sup>[21]</sup>。(2)SVM。SVM作为经典监督学习方法被用来解决分类识别问题时,一般被称为SVM分类法(SVC),鉴于其在小样本、高维问题下的良好表现,已然在模式识别领域得到推广<sup>[22]</sup>。(3)KNN。KNN是一种强大的分类方法,以简单性而闻名,KNN已成为满足各种应用领域不同需求的最灵活的分器之一<sup>[23]</sup>。(4)MLP。MLP是一种前馈神经网络,在输入层和输出层之间有一层或多层,是线性不可分问题的良好解决方案,且有很强的自适应学习能力<sup>[24]</sup>。(5)GBDT。GBDT其全称为梯度提升树,是传统机器学习算法中真实分布拟合的最佳算法之一<sup>[25]</sup>。

### 2.2 Stacking融合方法

过拟合的风险导致Stacking算法在实际操作时引入了交叉验证的思想,结合该方法在上层分类器对样本集进行训练时,能得到更丰富的信息以至于有效避免过拟合问题,基于Stacking融合的算法具体实现流程如图3所示。

如图3所示,基于Stacking融合的算法实现流程可分为3个步骤:(1)将样本数据按照一定比例随机划分成A、B两个部分,其中A用作训练,B用作测试,然后在确定 $C_1$ 、 $C_2$ 、 $\dots$ 、 $C_N$ 这N个“强而不同”的上层分类器的同时选1个下层分类器;(2)将A均等分为 $A_1$ 、 $A_2$ 、 $\dots$ 、 $A_i$ 份进行交叉运算,将其中 $i-1$ 份样本用作训练,剩下的

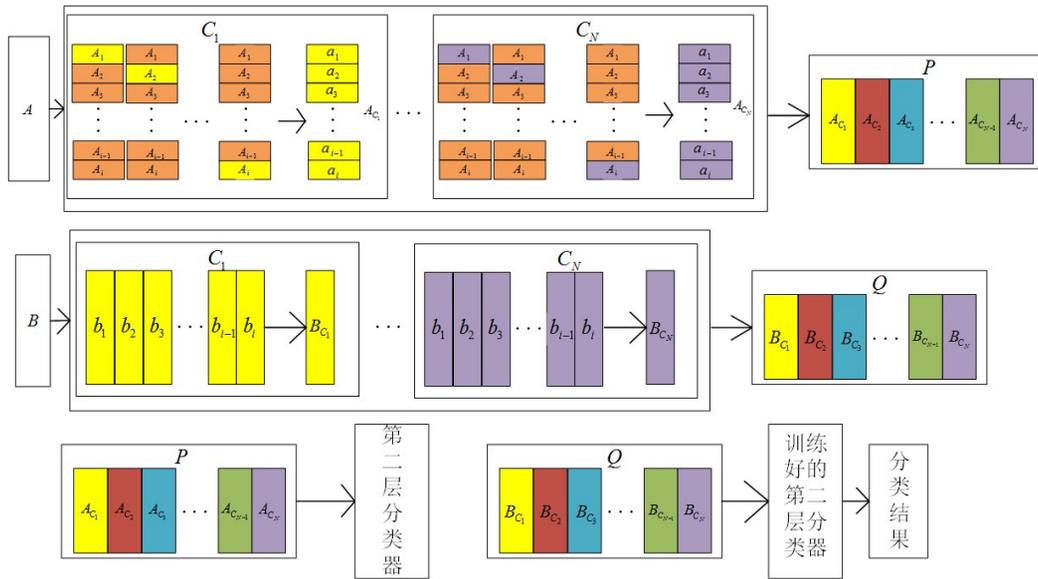


图3 Stacking算法流程

Figure 3 Stacking algorithm process

1份用作测试得到结果  $a_1$ ,同时对  $B$  进行预测得到  $b_1$ ,基于同一个分类器  $C_1$  重复上述过程  $i$  次后得到的  $a_1, a_2, \dots, a_i$  拼接为1个列向量  $A_{C_1}$ ,得到在  $C_1$  下提取的新训练特征,对测试重复  $i$  次后得到的结果  $b_1, b_2, \dots, b_i$  求均值将其变为1个列向量  $B_{C_1}$ 。对其余  $N - 1$  个分类器重复上述过程并将结果进行横向拼接,最终得到以  $A_{C_1}, A_{C_2}, \dots, A_{C_N}$  为新特征的训练集  $P$  和以  $B_{C_1}, B_{C_2}, \dots, B_{C_N}$  为新特征的测试集  $Q$ 。(3)将  $P$  导入下层分类算法中进行学习,再使用  $Q$  进行测试得到结果。

### 3 实验与分析

将两条人体信道衰减数据都按照 7:3 的比例划分训练集与测试集,并分别作为数据集输入模型。为考量基于 Stacking 特征融合的姿势识别的效果,本文实验分为以下 3 个部分。第一部分:分别在 L1、L2 这两个单一信道特征下使用多种单一模型进行实验。然后通过结果的分析对比,分别对各个单一信道特征下的单一模型按照精度、性能由高至低排序。第二部分:继上一部分中利用单一信道特征训练后,将其中表现较好的分类器用作单一信道特征下的 Stacking 融合模型的基分类器,对两种信道获取的特征分别进行姿势识别的实验。第三部分:分别选取在两个信道特征下表现较好的分类模型,将两个信道特征获得的结果进行拼接,作为输入元学习器的特征,进行 Stacking 特征融合实验。

#### 3.1 单信道单一模型分类结果

本小节的实验目的是比较 5 种单一分类器分别在 L1、L2 信道特征下的识别性能。将准确率

(Accuracy)、精确率 (Precision) 与召回率 (Recall) 作为性能评价指标,比较 RF、SVM、KNN、MLP、GBDT 这 5 个单一分类模型的姿势识别效果,分类结果如图 4、图 5 所示。

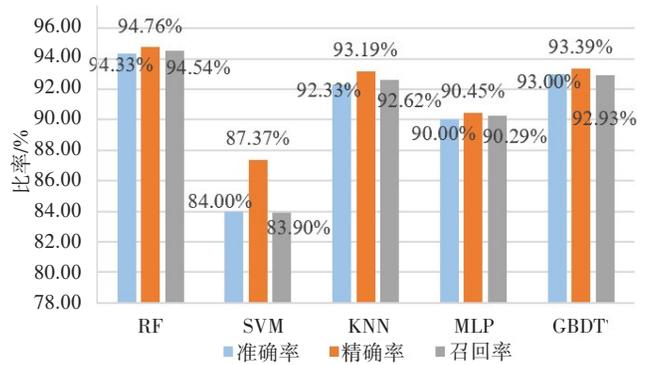


图4 L1信道下单一模型分类结果

Figure 4 Single model classification results for L1 channel

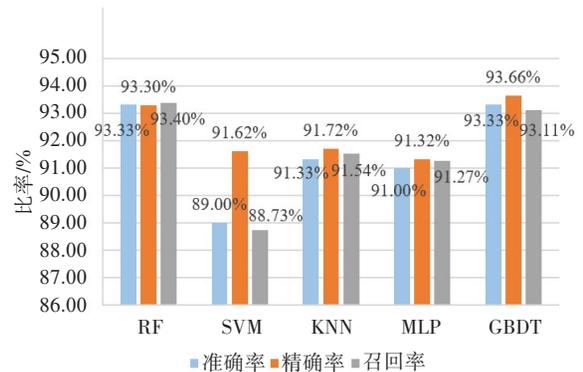


图5 L2信道下单一模型分类结果

Figure 5 Single model classification results for L2 channel

L1 信道特征下的实验结果如图4所示,从识别准确率上看,RF模型对于L1信道特征下的姿势识别效果是最好的,准确率为94.33%,明显优于其他几种分类器。其次为GBDT分类模型,准确率为93.00%。KNN、MLP和SVM分类模型准确率分别为92.33%、90.00%、84.00%,分别位列第三、四、五。

L2 信道特征下的实验结果如图5所示,RF模型与GBDT模型的识别准确率都为93.33%,同时获得最大值,对于L2信道特征下的姿势识别性能明显优于其他几种分类器。其次为KNN分类模型,准确率为91.33%。MLP分类器以91.00%的准确率位列第三,SVM分类模型的准确率最低,为89.00%。从精确率、召回率上看,GBDT模型的精确率比RF模型高0.36%,GBDT模型的召回率比RF模型低0.29%。用于身份识别场景的分类模型中,召回率表示正确预测的样本数占实际该类别数量的比例,能够反映分类模型识别所有相关类别的能力。因此,在本文场景下,召回率的优先级高于精确率。对于准确率数值相同的RF模型与GBDT模型,选取召回率较高的RF模型。

### 3.2 Stacking 单信道模型融合实验结果

本章首先对两个单一信道特征L1、L2分别进行Stacking模型融合实验,并通过选取不同个数的基分类器,在每种信道特征下形成3种融合方案,将其命名为M1、M2、M3方案,具体情况如下所示。(1)方案M1:选取分类性能排名为前二的RF+GBDT分类模型作为基学习器,元学习器选用逻辑回归分类模型。(2)方案M2:选取分类性能排名前三的RF+GBDT+KNN分类模型法作为基学习器,元学习器选用逻辑回归分类模型。(3)方案M3:在方案M2所选择的基学习器基础上,再添加排名第四的MLP分类模型,完成M3的基学习器选择。元学习器选用逻辑回归分类模型。M1、M2、M3 3种方案分别在L1、L2两种信道特征下进行实验,通过识别结果选出结果最优的方案,便于与后面基于Stacking特征融合的方法进行对比。图6、图7分别为基于L1、L2信道特征下Stacking模型融合的姿势识别结果。

如图6所示,在L1信道特征下基于人体通信的姿势识别结果中,M1、M2这两种方案分别融合了2个和3个单一分类模型,M2虽然融合了更多的优秀模型,但是其准确率比M1方案低了1.34%。M3融合了RF、GBDT、KNN、MLP这4种单一分类模型,得到了97.33%的准确率,为3种方案中的最优方案。而在3.1节中,L1信道特征下进行姿势识别效果最好的单一模型是RF,准确率为94.33%。通过L1单一信道特征下的识别结果与L1信道下Stacking模型融合的结果对比可以看出,在L1信道特征下,3种融合不

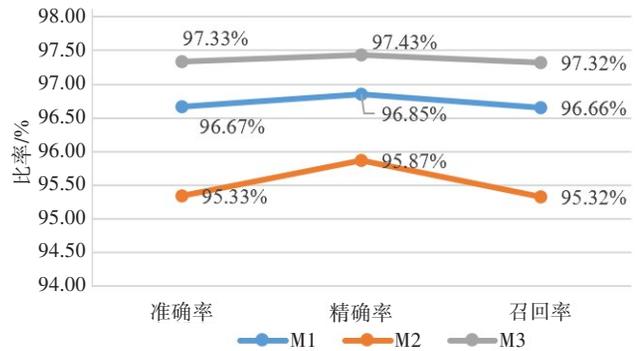


图6 L1信道下Stacking模型融合分类结果

Figure 6 Classification results of Stacking model fusion for L1 channel

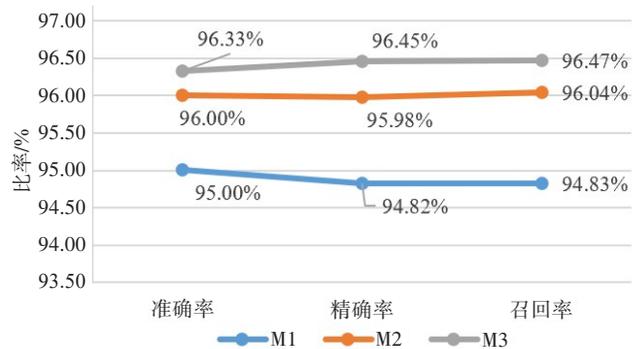


图7 L2信道下Stacking模型融合分类结果

Figure 7 Classification results of Stacking model fusion for L2 channel

同单一模型的Stacking方案的识别效果比单一分类模型的效果更好。

在L2信道特征下基于Stacking模型融合分类结果如图7所示。从3种方案的准确率、精确率以及召回率来看,M3方案的3个指标都高于M2、M1方案,M2方案的3个指标值高于M1方案。M3方案融合了RF、GBDT、KNN、MLP这4种单一分类模型,得到了96.33%的准确率,为3种方案中的最优方案。而在3.1节中,L2信道特征下进行姿势识别效果最好的单一模型是RF模型,准确率为93.33%。通过L2单一信道特征下的识别结果与L2信道下Stacking模型融合的结果对比可以看出,在L2信道特征下,3种融合不同单一模型的Stacking方案的识别效果比单一分类模型的效果更好。

### 3.3 Stacking 双信道模型融合实验结果

基于Stacking信道特征融合的方法是,在每条信道特征下选取识别性能较好的单一模型,基于L1、L2信道特征在单一模型下分别进行五折交叉运算,将其得到的结果进行拼接,作为第二层元学习器的输入。通过Stacking堆叠法进行特征融合,既避免了直接将原始数据进行拼接导致的维度过大的问题,又避免了对原始数据进行降维的繁复工作。

基于 Stacking 特征融合的姿势识别中,选择了排名靠前的 RF 和 GBDT 这两个单一模型。对只使用 GBDT 模型、只使用 RF 模型、以及同时使用 RF 和 GBDT 作为基分类器这 3 种不同情况分别构建 3 种基于 Stacking 特征融合的姿势识别模型进行研究,实验结果如图 8 所示。

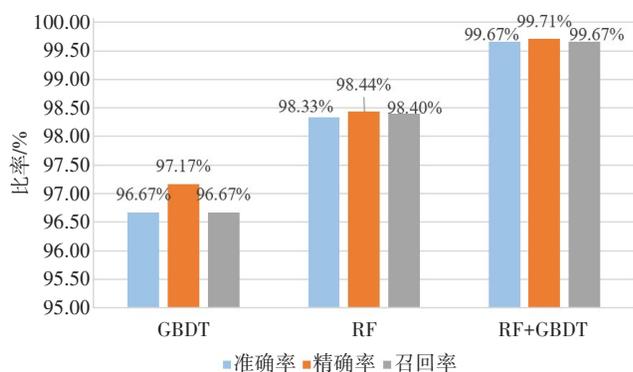


图 8 Stacking 特征融合分类结果

Figure 8 Stacking feature fusion classification results

只使用 GBDT 作为特征融合基分类器的姿势识别准确率为 96.67%,只使用 RF 作为特征融合基分类器的姿势识别准确率为 98.33%,而同时使用 RF+GBDT 作为基分类器进行特征融合后的姿势识别准确率为 99.67%。从实验结果可以看出,由于方法三使用了两种基分类器对两种信道下的训练结果进行堆叠,因此进行特征融合时不仅融合了两个信道特征的信息,也包含了不同分类器的差异性,从而获得了更高的准确率。

## 4 结论

本文对用于单人体域网中的可穿戴设备姿势识别提出了新思路,通过利用人体区域通信技术获取不同姿势下的信道衰减对人体姿势行识别。本文首先基于姿势识别的研究目的,对人体的站、蹲、坐、跑、走这 5 种姿势进行建模,每种姿势分别建立了 10 个不同状态模型,其次通过姿势特点选取接收极位置,形成 L1 与 L2 信道并分别计算信道衰减,以获取两个不同信道下的识别样本。在第一部分实验中,本文分别在两条信道样本集下使用多个单一分类器对姿势进行分类,并对结果进行对比得出,利用单一信道进行识别时,在 L1 信道特征下使用 RF 分类模型得到的准确率最高(94.33%)。为了提升姿势识别的效果,引入了 Stacking 方法在单一信道特征下进行 Stacking 模型融合,又用该思想对 L1、L2 样本特征进行了融合,将上述实验结果进行对比。最终结果表明,本文提出的方法具有可行性,同时 Stacking 特征

融合在个人域网中基于可穿戴设备的姿势识别能够达到较好的效果。

本文只选取了 5 种姿势进行识别,下一步将用于医疗领域的可穿戴姿势识别方法识别,对更多姿势进行识别,并将更多实际场景考虑其中,以向实际应用方向发展。

## 【参考文献】

- [1] 庾晶, 葛军, 郭林. 基于骨架特征的人体动作分类研究[J]. 计算机技术与发展, 2017, 27(8): 83-87.
- [2] Yu J, Ge J, Guo L. Investigation on human action classification based on skeleton features[J]. Computer Technology and Development, 2017, 27(8): 83-87.
- [3] 杨海清, 钱涛. 基于 Kinect 的动态姿势识别方法在医疗康复中的应用[J]. 电子技术应用, 2020, 46(12): 94-96.
- [4] Yang HQ, Qian T. Application of Kinect based dynamic posture recognition method in medical rehabilitation [J]. Electronic Technology Application, 2020, 46(12): 94-96.
- [5] Raj SM, Mukta SJ, Godder TK, et al. An approach for multi-human pose recognition and classification using multiclass SVM [C]// Intelligent Computing and Optimization, 2020: 922-937.
- [6] Huang Y, Lai S H, Tai S. Human action recognition based on temporal pose CNN and multi-dimensional fusion [C]//Computer Vision-ECCV 2018 Workshops, 2019: 426-440.
- [7] 刘帅. 利用多特征融合的运动员人体姿势识别算法[J]. 信息技术, 2019, 43(8): 17-19.
- [8] Liu S. Player's posture recognition algorithm based on multi-feature fusion[J]. Information Technology, 2019, 43(8): 17-19.
- [9] 邓泽夫. 基于 CNN-SVM 的调频连续波毫米波雷达人体姿势识别研究[J]. 软件工程, 2022, 25(10): 28-31.
- [10] Deng ZF. Research on human posture recognition of frequency-modulated continuous wave millimeter-wave radar based on CNN-SVM[J]. Software Engineering, 2022, 25(10): 28-31.
- [11] 冯心欣, 李文龙, 何兆, 等. 基于调频连续波雷达的多维信息特征融合人体姿势识别方法[J]. 电子与信息学报, 2022, 44(10): 3583-3591.
- [12] Feng XX, Li WL, He Z, et al. Human posture recognition based on multi-dimensional information feature fusion of frequency modulated continuous wave radar [J]. Journal of Electronics and Information, 2022, 44(10): 3583-3591.
- [13] 侯宋跃. 基于人体通信的信道传输相关特性研究[D]. 上海: 上海工程技术大学, 2021.
- [14] Hou SY. Research on channel transmission correlation characteristics based on human communication [D]. Shanghai: Shanghai University of Engineering and Technology, 2021.
- [15] Lumnitzer R, Tanner A, Elsherbeni AZ. Debye coefficients for biological tissues from 100 MHz to 100 GHz [C]//2020 International Applied Computational Electromagnetics Society Symposium (ACES). Monterey, CA, USA, 2020: 1-2.
- [16] Velasco A, Hadi MF, Elsherbeni AZ, et al. Debye coefficients for low frequency FDTD dispersive soils analysis [C]//2019 International Applied Computational Electromagnetics Society Symposium-China (ACES), 2019.
- [17] 车克龙, 廖薇, 周灵丽, 等. 基于人体通信的穿戴式医疗设备通信性能分析[J]. 中国医学物理学杂志, 2022, 39(3): 357-363.
- [18] Che KL, Liao W, Zhou LL, et al. Communication performance analysis of wearable medical devices based on human communication [J]. Chinese Journal of Medical Physics, 2022, 39(3): 357-363.
- [19] 王紫阳, 廖薇, 孙悦. 一种基于人体通信的路径损耗模型[J]. 无线电通信技术, 2019, 45(5): 518-522.
- [20] Wang ZY, Liao W, Sun Y. A path loss model based on human body communication [J]. Radio Communication Technology, 2019, 45(5): 518-522.
- [21] 周灵丽, 廖薇, 侯宋跃. 基于 HBC 频段动态人体信道传输特性的研究[J]. 计算机应用研究, 2021, 38(10): 3120-3124.
- [22] Zhou LL, Liao W, Hou SY. Research on transmission characteristics of dynamic human body channel based on HBC band [J]. Computer Application Research, 2021, 38(10): 3120-3124.
- [23] He X, Wei B, Fan K, et al. Explicit Newmark-FDTD method based on

- Maxwell's equation [C]//2020 IEEE International Conference on Computational Electromagnetics (ICCEM). IEEE, 2020: 215-216.
- [15] 吴秋雯, 廖薇. 基于人体通信的生物特征身份识别方法研究[J]. 电子测量与仪器学报, 2022, 36(5): 113-119.
- Wu QW, Liao W. Research on biometric identification method based on human communication [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(5): 113-119.
- [16] Agarwal N, Srivastava R, Srivastava P, et al. Multiclass classification of different glass types using random forest classifier [C]//2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS). IEEE, 2022: 1682-1689.
- [17] Song Y, Jin Q, Yan K, et al. Vote parallel SVM: an extension of parallel support vector machine [C]//2018 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI). IEEE, 2018: 1942-1947.
- [18] Fergani B. An efficient kernel KNN classifier for activity recognition on smartphone [C]//2022 IEEE 21st International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). IEEE, 2022: 73-78.
- [19] Hung JM, Chiang JY, Wang K. Tennis player pose classification using YOLO and MLP neural networks [C]//2021 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS). IEEE, 2021: 1-2.
- [20] 孙宏宇, 吴嘉伊, 吴宇. GBDT算法在无线非接触式人体行为识别中的应用研究[J]. 智能计算机与应用, 2022, 12(10): 224-226.
- Sun HY, Wu JY, Wu Y. Application of GBDT algorithm in wireless contactless human behavior recognition [J]. Intelligent Computer and Application, 2022, 12(10): 224-226.
- [21] Al-Janabi M, Andras P. A systematic analysis of random forest based social media spam classification [C]//Network and System Security, 2017: 427-438.
- [22] Dai H. Research on SVM improved algorithm for large data classification [C]//2018 IEEE 3rd International Conference on Big Data Analysis (ICBDA). IEEE, 2018: 181-185.
- [23] Robindro K, Singh YR, Clinton UB, et al. CD-KNN: a modified K-nearest neighbor classifier with dynamic K value [C]//Applications of Artificial Intelligence and Machine Learning, 2022: 753-762.
- [24] Abhishek L. Optical character recognition using ensemble of SVM, MLP and extra trees classifier [C]//2020 International Conference for Emerging Technology (INCET), 2020: 1-4.
- [25] Zhu X, Yang S, Liu R, et al. Supervised abnormal signal identification method [C]//2020 12th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). 2020: 657-661.

(编辑: 薛泽玲)