

基于脑肌电信号融合的下肢动作识别

周慧,李鹏飞,周松波

(中南民族大学 a.生物医学工程学院; b.认知科学国家民委重点实验室; c.医学信息分析及肿瘤诊疗湖北省重点实验室,武汉 430074)

摘要 为识别踝背屈、踝跖屈两类下肢动作,采集了5名受试者的脑电信号和肌电信号.挑选9通道脑电信号和2通道肌电信号进行预处理及特征提取,脑电信号计算事件相关去同步化(Event Related Desynchronization, ERD)特征,肌电信号计算平均绝对值(Mean Absolute Value, MAV)和斜率符号变换次数(Slope Sign Changes, SSC)特征,特征单独或组合后送入XGBoost(Extreme Gradient Boosting)和支持向量机(Support Vector Machine, SVM)分类器,对不同特征、分类器的识别效果进行比较,结果显示基于XGBoost分类器的脑肌电信号融合识别模式效果最优.

关键词 肌电信号;脑电信号;特征提取;XGBoost算法;动作识别

中图分类号 R318.04 文献标志码 A 文章编号 1672-4321(2025)01-0058-10

doi:10.20056/j.cnki.ZNMDZK.20250108

Recognition of lower limb movement based on EEG and EMG fusion

ZHOU Hui, LI Pengfei, ZHOU Songbo

(South-Central Minzu University, a. College of Biomedical Engineering; b. Key Laboratory of Cognitive Science of State Ethnic Affairs Commission; c. Hubei Key Laboratory of Medical Information Analysis and Tumor Diagnosis & Treatment, Wuhan 430074, China)

Abstract In order to identify dorsiflexion and plantar flexion of ankle, EEG and EMG signals were collected from 5 subjects. The 9-channel EEG and 2-channel EMG signals were selected for pre-processing and feature extraction, and the Event Related Desynchronization (ERD) features of the EEG signals were calculated. The Mean Absolute Value (MAV) and Slope Sign Changes (SSC) characteristics of EMG were calculated. The features were sent to XGBoost (Extreme Gradient Boosting) and Support Vector Machine (SVM) classifiers individually or in combination to compare the recognition effects of different features and classifiers. It is concluded that the recognition effect of EEG signal fusion based on XGBoost classifier is the best.

Keywords EMG; EEG; feature extraction; XGBoost algorithm; gesture recognition

我国老龄化现象越来越严峻,因疾病和体能产生的下肢运动功能障碍给老年人群的日常出行造成不便,也给他们心理上带来了极大的痛苦.以神经康复工程为手段,利用外骨骼设备来辅助下肢运动,能够给患者提供更广的活动空间,更高的生活质量.准确的运动意图识别是下肢外骨骼设备控制的关键.

表面肌电信号(surface Electromyography, sEMG)是从肌肉表面通过电极记录的众多肌纤维中运动

单元动作电位在时间和空间上的叠加,受神经支配的相应肌群检测到的信号反映了中枢神经系统产生的精确运动命令.下肢浅层和深层肌肉彼此之间有相当大的重叠, sEMG信号相比与上肢更复杂,对下肢 sEMG信号进行动作分类的任务比上肢更困难^[1].研究人员采集 sEMG,提取时域、频域或时频特征,对下肢动作识别,下肢外骨骼驱动展开研究^[2-3].LEE等通过采集腿部表面肌电信号输入模糊神经网络实现了对下肢步态的识别^[4];HUANG等利用截肢

收稿日期 2022-07-29

作者简介 周慧(1983-),女,讲师,博士,研究方向:神经康复工程, E-mail: zhouhui@mail.scuec.edu.cn

基金项目 国家自然科学基金资助项目(81601586);中央高校基本科研业务费专项资金资助项目(CPT22021)

者的 sEMG 信号,提取时域特征送入支持向量机,有效地完成了路况识别^[5].KUANG 等利用超限学习机进行下肢肢体动作的分类,取得了较高精度和较高鲁棒性^[6].

从神经肌肉控制原理出发,人体运动意图起源于大脑运动皮质层,头皮脑电 (Electroencephalogram, EEG) 是脑神经细胞的电生理活动在头皮表面的总体反映.NIAZI 等证实可以通过 EEG 提取运动相关皮层电位 (Movement Related Cortical Potentials, MRCPs) 检测运动意图^[7-8].KEE 等利用脑电信号的共同空间模式和功率谱密度算法对左右脚的运动意图检测,达到 72% 以上的识别率^[9].

此外,研究人员利用多源信息融合进行运动意图的识别.HUANG 首次提出将角度、力等运动信息和 sEMG 结合起来,减小下肢运动识别的延时和错误率^[10].ROBERT 提出了基于 EEG 和 sEMG 两个信号的决策层融合的策略,实现了左右手运动意图识别^[11].谢平等对 EEG 与 sEMG 的特征进行融合有效

识别单侧手腕屈伸动作,实现准确率提升^[12].

本文采用 sEMG、EEG 以及脑肌电融合的方法识别踝背屈、踝跖屈两类下肢动作,探索生物电信号中包含的运动信息,以期为下肢外骨骼设备控制提供理论基础.

1 下肢动作识别整体框架

下肢动作识别由实验设计与数据采集、数据预处理、特征提取、模型训练及测试、结果分析几个部分组成,整体框架如图 1 所示.

通过设计实验范式,采集踝背屈、踝跖屈动作时的 EEG 信号与下肢 sEMG 信号.对不同健康受试者在腿部不同动作状态下的 EEG 信号、sEMG 信号进行去噪、滤波、小波变换、有效数据段截取等预处理,再对处理后的数据进行特征提取.将提取的特征送入分类器进行训练与测试,并对分类结果进行量化评价.

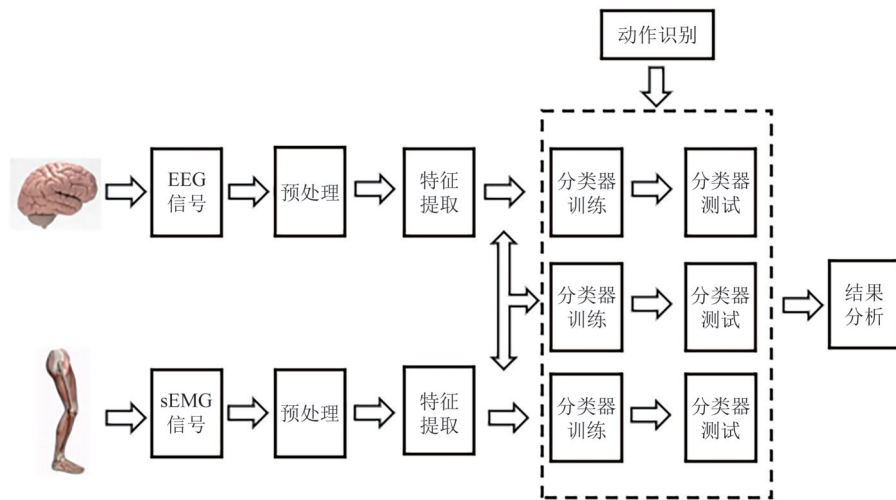


图 1 下肢动作识别整体框架

Fig. 1 Lower limb movement recognition overall framework

2 实验设计与数据采集

2.1 实验设计

实验募集 5 名男性被试者 [身高 (174.3±2) cm, 体重 (64.3±4.70) kg] 做踝背屈、踝跖屈动作.采集被试 32 通道的 EEG 信号、右腿胫骨前肌 (Tibialis Anterior, TA) 及内侧腓肠肌 (Medial Gastrocnemius, MG) sEMG 信号.踝背屈、踝跖屈动作及电极位置如图 2 所示.

利用 E-prime 软件设计实验范式,采用视觉提



图 2 踝背屈和踝跖屈动作

Fig. 2 Ankle dorsiflexion and ankle plantar flexion movements

示.被试者坐于电脑屏幕前,实验开始时,屏幕显示“+”号,持续 3 s,提示被试者进入准备状态.然后随机出现数字 0、1、2,持续时间为 1 s,提示被试者开始对应动作.“0”表示静息状态,“1”表示踝背屈,“2”表示踝跖屈.然后屏幕持续 6 s 空白,在此期间,被试者保持对应动作.完成动作后,屏幕显示“-”号,提示被试者进入放松状态,持续 3

s,直至下一个“+”出现,此为一个动作流程.一组实验过程中,三种数字提示随机出现,每种 10 次,一共 30 次,屏幕显示结束则停止该组实验,被试者可自由放松.每个被试者完成 3 组实验,每组实验中间隔 5 min 休息.实验结束后,每个动作完成 30 次.

实验流程如图 3 所示:




图 3 实验流程图

Fig. 3 Experimental flow chart


2.2 数据采集

采用德国 BrainProducts 公司的 BrainAmp 设备,如图 4(a)所示,根据 10~20 标准放置电极,采集 32 通道 EEG 信号,设置采样率为 500 Hz.实验开始之前,被试者洗净并吹干头发,去除表面油脂.为了保证数据准确,应在测量时使电极贴紧头皮,并在电极与头皮之间注入导电凝胶,通过阻抗检测确定电极输入阻抗小于 5 k Ω .

采用美国 Delsys 公司的 Trigno™ Wireless 肌电设备用于 sEMG 信号采集,如图 4(b)所示,设置采样率为 2000 Hz.用磨砂膏擦拭被试者对应肌肉,去除角质和油脂,然后用医用酒精洗去磨砂膏.用双面胶将 Delsys 无线表面肌电电极贴于被试者胫骨前肌及内侧腓肠肌的肌腹处,电极的放置位置根据 SENIAM 项目的建议设置^[13],并用运动绷带进行二次固定.放置好电极后,受试者需按实验要求做一次动作测试,实时观察 sEMG 信号确定电极放置是否准确.

另外,使用 Delsys 公司的 TriggerBox 模块向 BrainAmp 的 USB 适配器提供触发信号,如图 5 所示.按下

TriggerBox 模块的触发输出按键,肌电设备开始采集肌电,同时脑电设备接收到触发信号,以 marker 的形式保存在 EEG 数据文件中.按照上述方法实现脑电信号和肌电信号的起始同步后,再将 TriggerBox 模块与脑电 USB 适配器的连接口取下,将 Eprime 程序所在主机连接至脑电 USB 适配器.随后被试者在 Eprime 程序的提示下进行对应动作,每个动作开始时,Eprime 程序主机发送 marker 到 EEG 数据文件,实现动作的标记.脑电数据文件和肌电数据文件均存入计算机,以待后续的离线处理.



(a) 肌电 TriggerBox 模块

(b) 脑电 USB 适配器

图 5 脑电及肌电同步模块

Fig. 5 EEG and EMG synchronisation module



(a) 肌电采集设备

(b) 脑电放大器

图 4 数据采集设备

Fig. 4 Data acquisition equipment

3 信号预处理

3.1 脑电预处理

对采集到的 EEG 信号用 1~50 Hz 带通滤波器进行滤波,48~52 Hz 带阻滤波器滤除 50 Hz 频率的工频噪声,然后进行平均参考,处理后 EEG 如图 6 所示.

脑电按照频率划分,可以分为若干频率段,如表 1 所示.

研究人员证实,人体在运动实施或者运动想象




图 6 脑电信号

Fig. 6 EEG signal

表 1 脑电频率划分

Tab. 1 EEG frequency division

波段名称	频率/Hz
Delta	0.2~3
Theta	3~8
Alpha	8~15
Beta	15~30
Gamma	30~Up

状态下,β频段 EEG 能量明显上升^[14-15]. 本文采用时频能量谱方法对 EEG 信号进行多层次分解,重构β频段 EEG,将β频段 EEG 信号用于进一步的特征提

取.方法如下:

(1)对 EEG 进行基于 db1 小波基的 10 层小波包分解,分解得到 $2^{10}=1024$ 个子频段.

(2)EEG 采样率为 500 z,其奈奎斯特频率为 250 Hz,第 10 层分解得到的子频段范围为 $250/1024 = 0.244$ Hz.

(3)选择第 61 到 123 的子频段进行重构,提取出频段为 15~30 Hz ($0.244 \times 61 \sim 0.244 \times 123$) EEG 信号.

小波分解及重构如图 7 所示.



图 7 小波分解及重构

Fig. 7 Wavelet decomposition and reconstruction

3.2 肌电预处理

sEMG 信号采样率为 2000 Hz,为了与 EEG 信号对齐,将 sEMG 信号降采样到 500 Hz.进行 5~240 Hz 带通滤波,并利用小波软阈值去噪法对 sEMG 信号进行基线噪声去除.去噪参数如表 2 所示.

表 2 小波软阈值去噪

Tab. 2 Wavelet soft threshold denoising

名称	参数设置
小波基	db5
层数	5
阈值选择	无偏风险估计准则(rigrsure)
阈值调整	根据每层分解的噪声水平估计进行阈值调整(mln)

运动开始的 maker 标记为 E-prime 程序提示数字出现的时间.图 8 所示为被试 1 完成第 1 组实验的 sEMG 信号.用不同的线段标记动作 maker,点线对应静息开始;点划线对应踝跖屈动作开始;实线对应踝背屈动作开始.从图中可以看出,胫骨前肌 sEMG 信号在踝背屈时有较大激活,而腓肠肌 sEMG 信号在踝跖屈时有明显激活.健康人胫骨前肌在踝背屈时起主要作用,腓肠肌在跖屈中起主要作用,且健康人胫骨前肌、腓肠肌 sEMG 活动比较,前者强于后者.

长度较大的 sEMG 具有静止的特性,能够提高模式识别的准确率.但是,较大数据量引起的计算




图8 胫骨前肌、腓肠肌sEMG信号

Fig. 8 SEMG signal of tibialis anterior and gastrocnemius

负荷,给实时假肢设备控制带来挑战.实时控制要求sEMG激活到设备执行的延迟时间不超过300 ms.研究人员利用少于256 ms的瞬时EMG信号进行动作识别,结果显示可以获得较高的分类准确性^[16-17].为了平衡识别延时和识别性能,本文设置用于动作识别的sEMG信号为100 ms.按照运动起始时间,对EEG和sEMG信号进行100 ms的非重叠时间窗分割,获得动作样本.每次运动分割5个时间窗,每个动作共获得150个样本.

4 特征提取

4.1 脑电信号特征提取

常见的脑电特征提取方法是利用快速傅里叶变换(Fast Fourier Transform)或者小波变换(Wavelet Transform)将EEG从时域转换到频域,分析不同频段的频谱特征^[18-19].共空间模式法(Common Spatial Pattern, CSP)是适用于两分类任务的空域滤波特征提取方法,在运动想象中得到较广泛的应用^[20-22].在CSP算法里,EEG信号经空间滤波器滤波后,方差值差异最大化,得到具有较高区分度的特征向量.另外,研究人员认为,大脑是非线性动力学系统,EEG是复杂的、有限非周期性的随机信号.运用非线性动力学的方法对EEG信号进行非线性参数的分析,能够更准确的评定人脑活动的过程,关联维数、复杂度、熵、李雅普诺夫指数等是常用的EEG信号非线性特征^[23-25].

在真实运动和运动想象中,感觉运动区的EEG频率存在着事件相关去同步化(Event Related

Desynchronization, ERD)和事件相关同步化(Event Related Synchronization, ERS)特征^[17].PFURTSCHELLER等人证实:执行单侧手任务时, α 频段和 β 频段上对侧EEG振幅降低,同侧EEG振幅增加,这种降低和增加的现象称为ERD和ERS^[26].TANG等人使用运动执行或运动想象的28通道EEG信号的ERD/ERS特征来研究左手与右手、左手与双脚的分类,平均分类精度达到85%以上^[27].YU等在脚部运动想象任务中,利用7通道EEG信号的ERD特征进行两分类模式识别,准确率达到78%^[28],分类性能与实际运动执行非常接近.上述的研究为基于少通道EEG的ERD/ERS特征的脚步运动识别提供了可行依据.因此,本文提取ERD作为EEG信号特征,具体步骤如下^[29]:

(1)所有EEG采样值进行均值计算 \bar{x}_j ;

(2)从每个采样值中减去均值,并求差分平方:

$$y_{ij} = (x_{ij} - \bar{x}_j)^2; \quad (1)$$

(3)计算差分平方的均值:

$$A_j = \frac{1}{N-1} \sum_{i=1}^N y_{ij}; \quad (2)$$

(4)选择事件发生的某个事件段为参考间期,计算平均能量:

$$R = \frac{1}{k} \sum_{r_0}^{r_0+k} A_j; \quad (3)$$

(5)相对参考间期,计算能量百分率的降低或者升高:

$$\text{ERD}(\%) = (A - R)/R \times 100\%, \quad (4)$$

式(1)中 x_{ij} 为经过滤波的第 i 次试验的第 j 个采样值, \bar{x}_j 为滤波后的所有第 j 次采样值的均值.式(2)中 N 为50(100 ms信号), A_j 为运动时EEG平均能量;式

(3)中 R 为参考期间内的平均能量,本文选择运动提示前的0.5 s为参考期,则 k 为250.

4.2 肌电信号特征提取

常用的sEMG信号特征有时域特征、频域特征以及时频特征^[30].时域特征因其计算简单而被广泛运用,包括波长(Wave Length, WL)、过零次数(Zero Crossing, ZC)、均方根(Root Mean Square, RMS)、斜率符号变化次数(Slope Sign Changes, SSC)、平均绝对值(Mean Absolute Value, MAV)、方差(Variance, VAR)等.本文提取sEMG信号的MAV和SSC特征.对于离散信号,MAV可体现信号的统计学特征,而SSC表示信号的斜率符号改变的次数,因此也包含了信号的频率信息^[31].

(1)平均绝对值(MAV).

MAV在肌电图中表现为曲线相对于横轴的偏离程度,能够反映肌肉的活动情况.首先对数据进行全波整流,然后使用一个长度为 N 的移动窗口进行计算,计算公式为:

$$\text{MAV} = \frac{1}{N} \sum_{i=1}^N |x_i|, \quad (5)$$

其中: x_i 表现为在第 i 个采样点的sEMG信号的数值大小, N 表示提取的采样点的总数.

(2)斜率符号变化次数(SSC).

作为一种非线性不平稳的生物电信号,sEMG的波形变换与肌电曲线的斜率有一定的相关性.SSC是统计sEMG斜率符号变化次数的特征量.在特征值求取过程中设置一个阈值 λ 来抑制干扰,以降低表面肌电信号中存在的微弱噪声.SSC计算公式如下:

$$\text{SSC} = \sum_{i=2}^{N-1} \text{sgn}([\ (x_i - x_{i-1}) \times (x_i - x_{i+1}) \]), \quad (6)$$

$$\text{sgn} = \begin{cases} 1 & \text{if } x \geq \lambda \\ 0 & \text{otherwise} \end{cases},$$

其中 x_i 表现为在第 i 个采样点的sEMG信号的数值大小, N 表示提取的采样点的总数,本文中设置 λ 为0.00005.

5 动作识别

5.1 分类器

在分类方法中,线性判别分析(Linear Discriminant Analysis, LDA)是经典的学习算法,且不容易被过度拟合,而支持向量机(Support Vector Machine, SVM)在识别更复杂的模式时表现更好.LDA和SVM分类器已被应用于上肢运动和步态分类,获得了较好的分类效果^[32-33].极端梯度提升(Extreme Gradient Boosting,

XGBoost)是华盛顿大学陈天奇博士在2014年提出的一种分类算法,属于集成学习领域的Boosting策略,该策略对传统决策树算法进行优化和升级,将多个弱分类器来组合成一个强分类器,不断地迭代产生新的模型.XGBoost具有高效、灵活的特点,代价函数中加入了正则化,其能够有效防止过度拟合.本文选择SVM和XGBoost作为动作识别的分类器.

特征数据被分割成训练数据集和测试数据集,使用十折交叉验证法更精确地估计分类性能.所有数据被随机地划分为10个子集,在10个子集中,保留一个子集作为验证数据,其余的9个子集被用作训练数据.重复10次确保每一个子集都被用作验证数据,最后平均10个验证子集的结果作为分类器的结果.十折交叉验证过程如图9所示.




图9 十折交叉验证

Fig. 9 Ten fold cross validation

5.2 性能评估

分类性能从准确率、召回率、精确率、F1-score值四个方面进行评定^[34],定义分别如下:

(1)准确率(Accuracy):

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{all data}}, \quad (7)$$

准确率表示预测正确的样本占所有样本的比例.准确率越大,表明分类性能越好.

(2)精确率(precision):

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad (8)$$

精确率表示在预测为正例的样本中真实类别为正样本所占比例.

(3)召回率(recall):

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (9)$$

召回率表示在真实为正例的样本中预测正确的样本占比.

(4)F1-score值:

$$\text{F1} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (10)$$

精确率和召回率往往会互相制约.精确率越高,召回率就低;而召回率高,反过来又影响精确率.F1-score是精确率和召回率的调和平均值,能够较

为全面地评价分类性能, F1-score 越大说明分类质量更高.

6 结果和分析

6.1 基于脑电信号的分类结果

在人体运动的神经控制过程中, 大脑感觉运动皮层与肌肉之间的控制反馈联系发挥着至关重要的作用. 选择感觉运动皮层对应的九通道 EEG 信号进行分析, 包括: Fz、Pz、Cz、C3、C4、P3、P4、F3、F4, 如图 10 所示. 基于九通道 EEG 计算 ERD 值, 作为分类特征输入分类器, 分类准确率如表 3 所示.




图 10 EEG 电极通道

Fig. 10 EEG electrode channels

表 3 基于 EEG-ERD 特征的分类准确率

Tab. 3 Classification accuracy based on EEG-ERD features

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	58.7	61.1	53.9	54.0	57.7	57.1
SVM	62.3	60.0	65.6	56.7	59.0	60.7

6.2 基于肌电信号的分类结果

两通道 sEMG 的 MAV 和 SSC 特征分别送入分类器, 其结果如表 4-5 所示.

表 4 基于 EMG-SSC 特征的分类准确率

Tab. 4 Classification accuracy based on EMG-SSC features

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	66.1	61.7	60.4	71.7	63.7	64.7
SVM	76.0	63.0	71.3	71.0	63.0	68.9

表 5 基于 EMG-MAV 特征的分类准确率

Tab. 5 Classification accuracy based on EMG-MAV feature

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	72.7	57.3	70.6	72.3	64.7	67.5
SVM	77.7	63.7	71.0	76.0	66.3	70.9

6.3 脑肌电信号融合的分类结果

将脑电信号和肌电信号的特征进行组合, 分别为: (1) 9 通道 ERD+2 通道 MAV; (2) 9 通道 ERD+2 通道 SSC; (3) 9 通道 ERD+2 通道 MAV+2 通道 SSC.

融合分类结果如表 6-8 所示.

将 6 种特征的分类结果进行对比, 如图 11-12 所示.

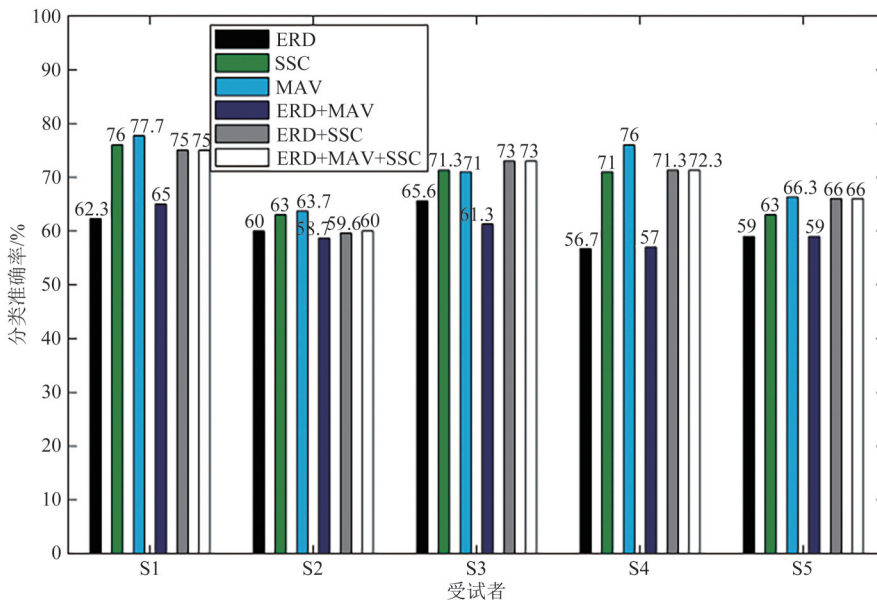


图 11 基于 SVM 的分类结果

Fig. 11 Classification results based on SVM

表 6 基于 ERD+MAV 融合的分类准确率

Tab. 6 Classification accuracy based on ERD+MAV fusion

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	80.3	64.0	82.0	76.0	69.2	74.3
SVM	65.0	58.7	61.3	57.0	59.0	60.2

表 7 基于 ERD+SSC 融合的分类准确率

Tab. 7 Classification accuracy based on ERD+SSC fusion

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	77.0	61.0	75.0	67.3	65.7	69.2
SVM	75.0	59.6	73.0	71.3	66.0	68.9

表 8 基于 ERD+MAV+SSC 融合的分类准确率

Tab. 8 Classification accuracy based on ERD+MAV+SSC fusion

分类器	准确率/%					平均值
	S1	S2	S3	S4	S5	
XGBoost	79.0	63.3	83.0	76.0	64.3	72.9
SVM	75.0	60.0	73.0	71.3	66.0	69.0

特征融合时分类器的综合性能指标如表 9 所示.

6.4 讨论分析

融合 EEG 和 EMG 是进行动作识别以此控制康复辅助设备的新方法,本文利用不同的 EEG-EMG 特征组合,实现单侧脚部运动的分类.表 3-5 可以看出,使用单一 EMG 或者 EEG 特征应用于 SVM 和 XGBoost 时,两通道 sEMG 特征的分类准确率高于九通道 EEG 特征.sEMG 是肌肉收缩的直接体现,其信号的稳定性高于 EEG,因此识别性能优于 EEG 特征.同时在单一特征下,SVM 的分类效果优于 XGBoost.

一般认为:单一的生理信号出现噪声、干扰等情况,会对分类结果存在影响,多源融合可以提高准确性.图 12 基于 XGBoost 的分类结果证实了:5 个受试者的两类融合特征(ERD+MAV、ERD+MAV+SSC)的识别准确率较三类单一特征均有上升.

而由图 11 基于 SVM 的分类结果比较发现,单一肌电特征的识别效果并不一定劣于融合特征,在 SVM 分类器中,被融合的脑电特征对分类效果没有贡献甚至是负贡献.综合图 11-12 可知,XGBoost 更

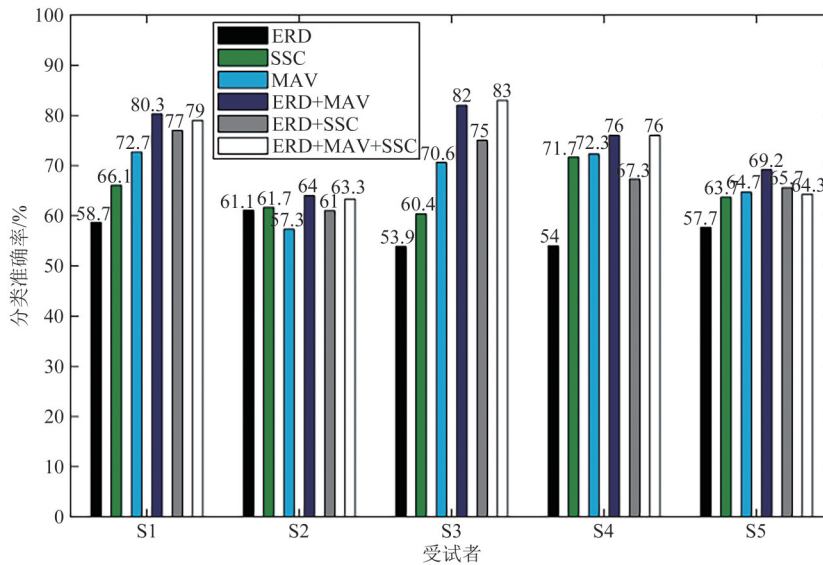


图 12 基于 XGBoost 的分类结果

Fig. 12 Classification results based on XGBoost

表 9 基于脑电信号融合特征的分类器性能指标

Tab. 9 Classifier performance index based on EEG and EMG fusion feature

分类器	特征	准确率/%	精确率/%	召回率/%	F1 评分/%
XGBoost	ERD+MAV	73.7	73.9	73.7	75.3
	ERD+SSC	69.2	68.5	71.1	69.7
	ERD+MAV+SSC	72.9	71.5	77.0	74.1
SVM	ERD+MAV	60.2	60.7	60.3	59.9
	ERD+SSC	68.9	64.6	85.6	73.1
	ERD+MAV+SSC	69.0	66.7	81.5	72.4

适合识别融合特征,识别效果较三类单一特征有显著提升,其中 ERD 和 MAV 的融合效果最好。

基于脑肌电信号融合特征的分类综合性能指标如表 9 所示,和前述的分析结果一致,XGBoost 分类器、ERD+MAV 特征是最优的组合,对应的 F1-评分最高。

通过结果分析,说明在多源信息融合的分类识别中,识别的性能和组合的特征、选择的分类器有着必然的联系。在具体的实验模式下,要选择合适的分类模型来达到较好的识别结果。

7 结论

基于单一 EEG 或 EMG 特征的动作识别性能有限,例如,痉挛、肢体残缺患者的 EMG 信号并不可靠,基于 EEG 的动作识别假阳性率较高。本文研究基于脑肌电信号融合的腿部运动状态识别,分析时域 sEMG 和 EEG 特征融合方法,比较在不同分类器中的性能优劣。结果证明,脑肌电信号特征融合能够提高动作识别性能,XGBoost 分类器在基于多源信号特征的下肢动作识别中表现更好。但是研究仍存在一定局限性:首先,被试数量较少,后续应该通过大量的受试者来验证结论的普遍性。其次,分析的 sEMG 和 EEG 特征有限,均为时域特征,应该增加频域、时频域特征,同时利用特征选择算法进行特征的筛选。最后,本文研究的融合方法为 EEG 加 sEMG 特征,统一分类器的模式,后续还可以尝试其他的融合模式,如 EEG 特征及分类器、sEMG 特征及分类器,多分类器并行或级联的集成模式。

参考文献

- [1] 刘峻豪. 基于表面肌电信号的下肢步态及姿势识别算法的研究[D]. 成都: 西华大学, 2020.
- [2] WENTINK E C, SCHUT V G H, PRINSEN E C, et al. Detection of the onset of gait initiation using kinematic sensors and EMG in transfemoral amputees [J]. *Gait & Posture*, 2014, 39(1): 391-396.
- [3] 杨新亮, 罗志增. 基于表面肌电信号的时频组合特征融合识别[J]. *华中科技大学学报(自然科学版)*, 2011, 39(S2): 153-156.
- [4] LEE S W, YI T, JUNG J W, et al. Design of a gait phase recognition system that can cope with EMG electrode location variation [J]. *IEEE Transactions on Automation Science and Engineering*, 2017, 14(3): 1429-1439.
- [5] HUANG H, LI T, BRUSCHINI C, et al. EMG pattern recognition using decomposition techniques for constructing multiclass classifiers [C]//2016 6th IEEE International Conference on Biomedical Robotics and Biomechanics (BioRob). UTown: ACM, 2016: 1296-1301.
- [6] KUANG Y, WU Q, SHAO J, et al. Extreme learning machine classification method for lower limb movement recognition [J]. *Cluster Computing*, 2017, 20(4): 3051-3059.
- [7] NIAZI I K, JIANG N, TIBERGHIE O, et al. Detection of movement intention from single-trial movement-related cortical potentials [J]. *Journal of Neural Engineering*, 2011, 8(6): 066009.
- [8] NIAZI I K, MRACHACZ-KERSTING N, JIANG N, et al. Peripheral electrical stimulation triggered by self-paced detection of motor intention enhances motor evoked potentials [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2012, 20(4): 595-604.
- [9] KEE Y J, WON D O, LEE S W. Classification of left and right foot movement intention based on steady-state somatosensory evoked potentials [C]//2017 5th International Winter Conference on Brain-Computer Interface (BCI). Gangwon Province: IEEE, 2017: 106-108.
- [10] HUANG Y, ENGLEHART K B, HUDGINS B, et al. A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses [J]. *IEEE Transactions on Bio-Medical Engineering*, 2005, 52(11): 1801-1811.
- [11] LEEB R, SAGHA H, CHAVARRIAGA R, et al. A hybrid brain-computer interface based on the fusion of electroencephalographic and electromyographic activities [J]. *Journal of Neural Engineering*, 2011, 8(2): 025011.
- [12] 谢平, 陈迎亚, 郝艳彪, 等. 基于脑肌电融合的混合脑机接口研究[J]. *中国生物医学工程学报*, 2016, 35(1): 20-30.
- [13] HERMENS H J, FRERIKS B, DISSELHORST-KLUG C, et al. Development of recommendations for SEMG sensors and sensor placement procedures [J]. *Journal of Electromyography and Kinesiology*, 2000, 10(5): 361-374.
- [14] HASHIMOTO Y, USHIBA J, KIMURA A, et al. Correlation between EEG-EMG coherence during isometric contraction and its imaginary execution [J]. *Acta Neurobiologiae Experimentalis*, 2010, 70(1): 76-85.
- [15] WITHAM C L, RIDDLE C N, BAKER M R, et al. Contributions of descending and ascending pathways to corticomuscular coherence in humans [J]. *The Journal of Physiology*, 2011, 589(Pt 15): 3789-3800.

- [16] HUANG H, KUIKEN T A, LIPSCHUTZ R D. A strategy for identifying locomotion modes using surface electromyography [J]. *IEEE Transactions on Bio-Medical Engineering*, 2009, 56(1): 65-73.
- [17] FARRELL T R, WEIR R F. The optimal controller delay for myoelectric prostheses [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(1): 111-118.
- [18] 乔晓艳, 项春元, 王艳景. 基于小波变换方法的运动想象脑电特征提取 [C]//Proceedings of the 2011 International Conference on Future Computer Science and Application (FCSA 2011 V2). Kota Kinabalu: International Industrial Electronic Center, 2011: 317-320.
- [19] LI M, CHEN W. FFT-based deep feature learning method for EEG classification [J]. *Biomedical Signal Processing and Control*, 2021, 66: 102492.
- [20] 龙佳伟, 郑威, 刘燕, 等. 基于排列熵和CSP融合的脑电信号特征提取[J]. *计算机技术与发展*, 2022, 32(3): 157-162, 168.
- [21] 杨子贤, 罗涛, 李剑峰, 等. 基于脑电信号及其空间模式的抑郁症多分类算法研究[J]. *北京生物医学工程*, 2022, 41(2): 167-173, 178.
- [22] 王美娥, 徐艳华. 基于小波包分解和共空间模式方法的脑电运动想象分类方法[J]. *生物医学工程研究*, 2021, 40(3): 256-261.
- [23] BRARI Z, BELGHITH S. A novel Machine Learning approach for epilepsy diagnosis using EEG signals based on Correlation Dimension [J]. *IFAC-PapersOnLine*, 2021, 54(17): 7-11.
- [24] 王舒欢. 基于复杂度的脑电信号分析 [C]//天津市科学技术协会. 中国(天津)机电装备创新设计与产业发展高峰论坛论文集. 天津:《机械设计》杂志社, 2015: 64-66.
- [25] 陈倩倩, 徐健, 刘秀平, 等. 基于DWT、MEMD和模糊熵的脑电信号特征提取与分类研究[J]. *河南理工大学学报(自然科学版)*, 2022, 41(1): 143-152.
- [26] PFURTSCHELLER G, LOPES DA SILVA F H. Event-related EEG/MEG synchronization and desynchronization: Basic principles [J]. *Clinical Neurophysiology*, 1999, 110(11): 1842-1857.
- [27] TANG Z, SUN S, ZHANG S, et al. A brain-machine interface based on ERD/ERS for an upper-limb exoskeleton control [J]. *Sensors*, 2016, 16(12): 2050.
- [28] GORDLEEVA S Y, LOBOV S A, GRIGOREV N A, et al. Real-time EEG-EMG human-machine interface-based control system for a lower-limb exoskeleton [J]. *IEEE Access*, 2020, 8: 84070-84081.
- [29] GRAIMANN B, HUGGINS J E, LEVINE S P, et al. Visualization of significant ERD/ERS patterns in multichannel EEG and ECoG data [J]. *Clinical Neurophysiology*, 2002, 113(1): 43-47.
- [30] 许栋岳, 李克勇. 肌电信号的特征分析方法及其应用 [J]. *现代生物医学进展*, 2010, 10(13): 2593-2596.
- [31] WEI P N, ZHANG J H, TIAN F F, et al. A comparison of neural networks algorithms for EEG and sEMG features based gait phases recognition [J]. *Biomedical Signal Processing and Control*, 2021, 68: 102587.
- [32] PENG F, PENG W, ZHANG C, et al. IoT assisted kernel linear discriminant analysis based gait phase detection algorithm for walking with cognitive tasks [J]. *IEEE Access*, 2019, 7: 68240-68249.
- [33] ALTAN E, PEHLIVAN K, KAPLANOĞLU E. Comparison of EMG based finger motion classification algorithms [C]//2019 27th Signal Processing and Communications Applications Conference (SIU). Sivas: IEEE, 2019: 1-4.
- [34] 胡士卓, 周斌, 胡波. 基于多视图融合的3D人体姿态估计[J]. *中南民族大学学报(自然科学版)*, 2023, 42(1): 103-110.

(责编&校对 刘钊)