

文章编号: 1004-7220(2022)05-0818-08

# 基于表面肌电信号的手势识别与分析

张瑞轩, 张绪树, 郭媛, 何栋栋, 王瑞雪

(太原理工大学 生物医学工程学院, 太原 030024)

**摘要:**目的 研究利用前臂及手部表面肌电 (surface electromyography, sEMG) 信号进行手势识别的方法, 以及不同手势下拇指、食指的关节角度, 探讨 sEMG 信号控制外骨骼手的可行性。方法 采集 20 名健康右利手受试者右侧前臂及手部 6 块肌肉 sEMG 信号。提取 sEMG 信号的时域特征值, 对比人工神经网络 (artificial neural network, ANN)、K-近邻 (K-nearest neighbor, KNN)、决策树 (decision tree, DT)、随机森林 (random forest, RF) 和支持向量机 (support vector machine, SVM) 等多种分类器对 6 种日常手势进行识别。同时, 采用 Vicon 摄像机跟踪系统捕捉右手拇指、食指运动轨迹, 计算拇指、食指关节角度。结果 利用前臂及手部 sEMG 信号可以实现 6 种手势的模式识别, 其中 ANN 分类器的分类预测效果最好, 测试集预测精度可达 97.9%, Kappa 系数可达 0.975。同时, 计算得到不同手势下拇指、食指的关节角度, 并进行不同手势下关节角度相关性分析。结论 利用前臂及手部 sEMG 信号进行手势识别, 能够实现具有几乎完全一致的分类预测结果。研究结果证明了 sEMG 信号手势识别应用于外骨骼手控制的可行性。

**关键词:** 表面肌电信号; 手势识别; 人工神经网络算法; 自适应增强算法; 运动捕捉

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2022.05.008

## Recognition and Analysis of Hand Gesture Based on sEMG Signals

ZHANG Ruixuan, ZHANG Xushu, GUO Yuan, HE Dongdong, WANG Ruixue

(College of Biomedical Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

**Abstract: Objective** To study the method of hand gesture recognition using surface electromyography (sEMG) signals from the forearm and hand, as well as joint angles of the thumb and index finger under different hand gestures, so as to explore the feasibility of controlling the exoskeleton hand with sEMG signals. **Methods** The sEMG signals of six muscles in the right upper limb of 20 healthy right-handed subjects were collected. The time domain feature values of sEMG signals were extracted. Classifiers such as artificial neural network (ANN), K-nearest neighbor (KNN), decision tree (DT), random forest (RF) and support vector machine (SVM) were used for pattern recognition of six daily hand gestures. Meanwhile, trajectory of the thumb and index finger movements was captured by the Vicon camera tracking system. The thumb and index finger angles were calculated. **Results** Pattern recognition of six hand gestures could be achieved using sEMG signals of the forearm and hand, and the ANN classifier had the best classification prediction, with test set prediction accuracy of 97.9% and Kappa coefficient of 0.975. The thumb and index finger angles under six hand gestures were also calculated, and correlation analysis of joint angles under different hand gestures was conducted. **Conclusions** By using forearm and hand sEMG signals for hand gesture recognition, it is possible to achieve classification prediction with almost identical results. The results in this study demonstrate the feasibility of applying sEMG signal based-hand gesture recognition to exoskeleton hand control.

**Key words:** surface electromyography (sEMG) signal; hand gesture recognition; artificial neural network (ANN) algorithm; adaboost algorithm; motion capture

收稿日期: 2022-03-08; 修回日期: 2022-04-14

基金项目: 国家自然科学基金项目 (11972243)

通信作者: 张绪树, 副教授, E-mail: zhangxushu@tyut.edu.cn

手是一种非常精确和敏捷的人体器官,可完成从微妙复杂到有力且剧烈的运动。手的功能损伤和部分丧失会深刻影响人们的日常生活。研究发现,脑卒中后上肢功能受到严重影响,其中约 80% 患者出现上肢运动障碍<sup>[1]</sup>。上肢功能障碍极大影响了患者生活的独立性,并可能造成长期残疾。手部康复的最新进展表明,机器人辅助治疗可通过外骨骼对手部关节的直接控制,帮助手部运动功能恢复<sup>[2-5]</sup>。

外骨骼的控制系统可以是外部驱动也可通过自身电信号驱动<sup>[6]</sup>。脑电 (electroencephalography, EEG) 信号和肌电 (electromyography, EMG) 信号都可以反映人的运动意图,进而实现对外骨骼的控制。表面肌电 (surface electromyography, sEMG) 信号具有无创采集、处理简单、无线传输及可在实际运动前 50~100 ms 提供运动信息等优点,在辅助康复机器人的控制研究方面有非常重要的应用价值<sup>[7-8]</sup>。但在实际应用中,sEMG 信号对系统中使用的仪器、方法及程序具有很强的依赖性;采集过程中也会产生不同程度的伪影和串扰;信号存在个体差异和位置差异,这都增加了 sEMG 信号的分析难度<sup>[9]</sup>。

因此,有必要开发强健稳定的机器学习算法,根据上肢 sEMG 信号进行手势识别,进而实现利用自身电信号实时控制外骨骼<sup>[10]</sup>。已有研究使用 sEMG 信号的时域、频域及时-频域特征对运动意图进行模式识别,其中利用时域特征的识别算法有较高的预测准确率<sup>[11-13]</sup>。Carl 等<sup>[14]</sup>利用时域特征值进行手势识别,准确率达 90.57%。Ali 等<sup>[15]</sup>利用线性判别法,根据 12 通道 sEMG 信号的 11 个时域特征对 15 类手势进行模式识别,准确率达 90%。Mohammadreza 等<sup>[16]</sup>利用支持向量机算法,根据 4 通道 sEMG 信号的 9 个时域特征对 6 类手势进行模式识别,准确率达 95%。Ganesh 等<sup>[12]</sup>利用独立成分分析和伊卡萨聚类法,根据 11 通道 sEMG 信号的 9 个时域特征对 11 类手势进行模式识别,准确率达 96.6%。Mochammad 等<sup>[18]</sup>利用神经网络算法,根据 11 通道 sEMG 信号的 16 个时域特征,对 5 个手指动作进行模式识别,准确率达 96%。然而,在先前的研究中,较多手势识别选择了 9 个及 9 个以上的特征值作为机器学习的输入值。选择多个

特征值作为分类器的输入确实可以提升分类预测的稳定性及准确率,但也增加了控制系统的运算时间,进而产生控制时延。如何能够在确保分类预测的稳定性及准确率的前提下,以尽可能少的通道及特征值数量进行基于 sEMG 信号的手势识别,是一个亟待解决的问题。

针对上述问题,本文对受试者进行手部运动学实验。实验过程中,同步采集前臂及手部的 sEMG 信号和拇指与食指的关节及指尖处的运动轨迹。根据 sEMG 信号,计算时域特征值,并将其作为机器学习算法的输入,解码手部运动姿势。此外,根据拇、食指运动轨迹,将简单的手势识别细化为关节角度变化的手部运动模型描述,为后续外骨骼手的设计提供依据。本文旨在以尽可能少的 sEMG 信号通道及特征值数量的前提下,对多种模式识别算法进行研究,寻找最优的手势识别算法。

## 1 实验和方法

### 1.1 实验对象

选取 20 名健康右利手受试者(10 名男性,10 名女性),年龄为  $(24 \pm 2.8)$  岁,身体质量指数 (body mass index, BMI) 为  $(21.7 \pm 2.8)$   $\text{kg}/\text{m}^2$ ,利手性均参考爱丁堡利手量表确定。所有受试者均无任何视觉障碍、精神疾病及上肢骨骼肌肉外伤。实验前,受试者均被充分告知研究目的、方法和程序,并签署书面知情同意书。

### 1.2 数据采集

EMG 信号采集设备选取采样频率为 2 kHz 的 Noraxon Ultium 无线 EMG 设备。采集并记录受试者不同手势时 6 块前臂及手部肌肉的 sEMG 信号,分别为拇短展肌 (abductor pollicis brevis, APB)、指浅屈肌 (flexor digitorum superficialis, FDS)、肱桡肌 (brachioradialis, BRA)、尺侧腕屈肌 (flexor carpi ulnaris, FCU)、桡侧腕长短伸肌 (extensor carpiradialis, EC) 和指总伸肌 (extensor digitorum communis, EDC)。为确保数据采集的可靠性,实验前须刮除受试者部分皮肤的外侧体毛,并用 75% 医用酒精擦拭去除油脂皮屑,再将 Ag/AgCl 表面电极贴片沿肌肉纤维走向粘贴于肌腹处。在实验过程中,受试者须对 6 种规定手部姿势进行至少 20 次重复,每种手势在 500 ms 内完成,每次重复间隔 2~

3 s, 每种手势之间休息 5 min。6 种手势分别为滚动鼠标 (roll mouse, RM)、拇指内扣 (thumb button, TB)、拇食指捏合 (thumb & index finger kneading, TI)、4 指弯曲 (four-finger flexion, FF)、握杯 (hold the cup, HC) 及 5 指捏合 (five-finger kneading, FK), 模拟日常生活中的多种精细手部动作。




图 1 6 种手势

Fig. 1 Six hand gestures (a) Roll mouse, (b) Thumb button, (c) Thumb & index finger kneading, (d) Four-finger flexion, (e) Holding the cup, (f) Five-finger kneading

采集 sEMG 信号的同时, 采用 6 摄像头 Vicon 三维运动采集系统同步采集并记录受试者右手拇指、食指的三维运动学数据。将 8 颗直径为 6.5 mm 的标记点粘贴于受试者拇指、食指的 6 个关节和指尖处, 以 1 kHz 采样频率捕捉标记点的运动轨迹

(见图 2)。计算拇指近端、远端和食指近端、中端、远端的关节角度, 对比分析手部运动与关节角度间的关系。




图 2 拇指、食指运动学数据采集

Fig. 2 Thumb and index finger kinematic data acquisition (a) Hand marker configuration, (b) Kinematic data model of the thumb and index finger, (c) Joint angles

注: T\_P 为拇指近端; T\_D 为拇指远端; I\_P 为食指近端; I\_M 为食指中端; I\_D 为食指远端。

### 1.3 sEMG 信号预处理

对采集到的 6 通道原始 sEMG 信号进行预处理操作, 具体步骤如下: ① 进行全段信号整流; ② 采用 20~500 Hz (FIR) 的带通滤波器, 滤除低频噪声和高频干扰; ③ 经过 50 ms 的 RMS 平滑滤波器。以某位受试者进行滚动鼠标手势为例, 6 通道 sEMG 原始信号与预处理后的 sEMG 信号对比如图 3 所示。

## 2 特征提取

### 2.1 特征值计算

受试者每完成 1 个手势称为 1 个事件。根据每

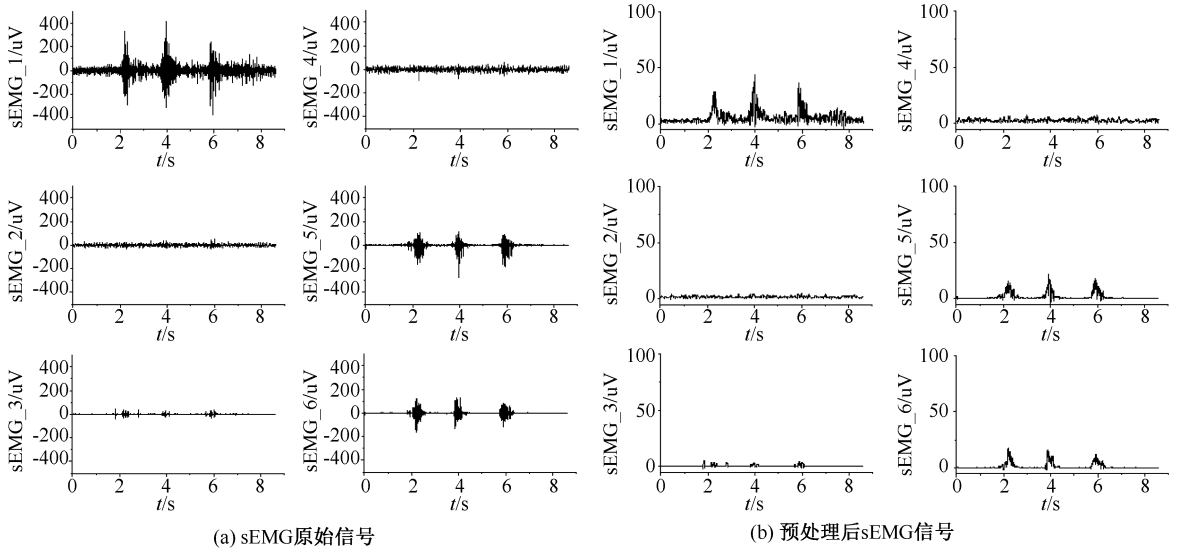


图 3 sEMG 信号预处理前后对比

Fig. 3 Comparison of sEMG signals before and after pre-processing (a) Original sEMG signals, (b) Pre-processed sEMG signal

个事件滤波后的 6 通道 sEMG 信号,截取包括完整肌肉激活周期的分析窗口(宽度为 500 ms)。本文对每个分析窗口计算 1 个特征集,1 个特征集包括 4 个时域特征,分别为积分 EMG 值(integral electromyography, iEMG)、绝对平均值(mean absolute value, MAV)、输入贡献率<sup>[18]</sup>(input contribution rate, ICRi)以及方差(variance, VAR)。各时域特征运算公式如下:

$$iEMG = \int_t^{t+T} |EMG(t)| \cdot dt$$

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i|$$

$$ICRi = \frac{\int_t^{t+T} |EMG(t)_i| \cdot dt}{\sum_{i=1}^N \int_t^{t+T} |EMG(t)_i| \cdot dt}$$

$$VAR = \frac{1}{N1} \sum_{i=1}^N x_i^2$$

## 2.2 特征值选择

将受试者每重复 1 次手势动作获得的 6 通道 sEMG 信号称之为事件。整个实验中有 2 400 个事件,每个手势有 400 个事件(20 个受试者×至少 20 次重复)。每个事件包含 24 个(6×4)特征的特征集较为庞大,本文采用降冗余和强相关两种方法减少特征数量。首先,ICRi 是受试者被要求做某一动作时每条肌肉 iEMG 在 6 条肌肉 iEMG 总和的占比。ICRi 可通过 iEMG 计算得出,属于冗余数据,予以剔除。其次,对 iEMG、MAV 和 VAR 与 6 种手势进行相关性分析。结果表明,iEMG 与手势之间存在较强相关性(见表 1)。最终确定选用 6 通道 sEMG 信号的 iEMG 作为手势识别的输入信号。

表 1 不同肌肉 iEMG、MAV、VAR 与手势的相关性

Tab. 1 Correlation of iEMG, MAV and VAR of different muscles with hand gestures

时域特征	APB	FDS	BRA	FCU	EC	EDC
iEMG	0.648	0.616	0.863	0.523	0.642	0.843
MAV	0.614	0.573	0.768	0.435	0.525	0.689
VAR	0.575	0.470	0.488	0.411	0.516	0.475

注:APB、FDS、BRA、FCU、EC 和 EDC 分别为拇短展肌、指浅屈肌、肱桡肌、尺侧腕屈肌、桡侧腕长伸肌和指总伸肌。下同。

## 3 机器学习

利用机器学习算法,根据每个事件 6 通道

sEMG 信号的 iEMG 进行手势识别。每个事件的 6 通道 sEMG 信号 iEMG 为机器学习算法的输入,6 种手势作为机器学习算法的输出,进行模型训练和模型预测效果验证。2 400 条 6 通道 iEMG 整体数据集对于 6 种手势的模式识别算法能够满足机器学习的数据量需求。本文为 6 手势训练了两种模式识别算法,分别为自适应增强(adaptive boosting, Adaboost)算法和人工神经网络(artificial neural network, ANN)算法。整体数据集的 80% 作为训练集,用于寻找最优参数组合并训练模型;数据集的 20% 作为测试集,用于验证模型预测效果。

### 3.1 Adaboost 算法

Adaboost 算法是一种迭代提升算法,是指针对同一个训练集训练多个弱分类器,再将弱分类器线性组合成强分类器的过程。主要是加强前面弱分类器分类错误样本的权值,更新权值后再次被用到下一个新的弱分类器的自适应过程(见图 4)。

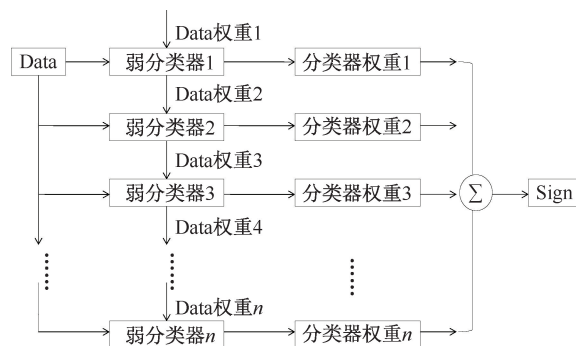


图 4 Adaboost 算法流程

Fig. 4 Flow chart of the Adaboost algorithm

具体来说,Adaboost 算法的迭代过程需要进行如下 4 个步骤:

(1) 第 1 轮构建弱分类器  $f_1(x)$ , 初始化  $N$  个训练样本的权重  $w_{1i}$  为  $\frac{1}{N}$ 。

(2) 计算弱分类器  $f_m(x)$  在训练集上的误判率:

$$e_m = \sum_{i=1}^N w_{mi}^* I(y_i \neq f_m(x_i))$$

(3) 计算弱分类器  $f_m(x)$  对应的权重:

$$\alpha_m^* = \frac{1}{2} \log \frac{1 - e_m}{e_m}$$

(4) 根据弱分类器  $f_m(x)$  预测结果,计算下一

轮用于构建弱分类器的  $N$  个样本点权重:

$$w_{m+1,i}^* = \frac{w_{mi}}{Z_m} \begin{cases} \exp(-\alpha_m^*), & f_m(x_i) = y_i \\ \exp(\alpha_m^*), & f_m(x_i) \neq y_i \end{cases}$$

Adaboost 的算法伪代码如下所示:

输入训练集  $D = \{(x^1, y^1), (x^2, y^2), \dots, (x^N, y^N)\}$ 。其中,  $x^i \in X, X$  为训练样本集合;  $y^i \in Y, Y$  为分类标签集合; 最大迭代次数为  $M$ , 当前迭代次数为  $m$ ; 弱分类算法为  $f(x)$ 。过程如下:

$$w_{1i} = \frac{1}{N}, i = 1, 2, 3, \dots, N$$

For  $m = 1, 2, 3, \dots, M$  do

$$h_m = f(D, w_m)$$

$$e_m = \sum_{i=1}^N w_{mi}^* I(y_i \neq f_m(x_i))$$

If  $e_m > 0.5$  then break

$$\alpha_m^* = \frac{1}{2} \log \frac{1 - e_m}{e_m}$$

$$w_{m+1,i}^* = \frac{w_{mi}}{Z_m} \begin{cases} \exp(-\alpha_m^*), & f_m(x_i) = y_i \\ \exp(\alpha_m^*), & f_m(x_i) \neq y_i \end{cases}$$

End for

$$\text{输出预测函数 } F(x) = \sum_{m=1}^M \alpha_m^* f_m(x)$$

为确定最优参数组合, 本文采用 5 重交叉验证和网格搜索法, 确定基础分类器为分类决策树 (classification and regression tree, CART)、最大基础分类器数量为 500、学习率为 1 的算法参数组合。

### 3.2 ANN 算法

ANN 算法是一种类似于大脑神经突触连接的结构进行信息处理的数学模型, 是对人脑运行机制和组织结构的某种抽象、简化和模拟。ANN 网络结构由不同层的结点组成, 每一层的结点输出到下一层互联的结点, 通过连接权值而被放大、衰减或抑制。每一层结点的激励公式如下:

$$y = f\left(\sum_{i=0}^{n-1} w_i x_i - \theta\right)$$

其中:  $w_i$  为第  $i$  个输入  $x_i$  的连接权重,  $\theta$  为输出阈值,  $f$  为激活函数,  $y$  为该结点的输出。结点的输出值由结点输入、连接权重、输出阈值及激活函数共同决定。ANN 网络由输入层、隐藏层和输出层构成。输入层用于输入特征向量, 输入层结点与隐藏层结点联结构成特征向量的联想矩阵, 隐藏层

结点与输出层结点联结构成特征向量的决策矩阵。通过模型不断地训练调整, 对数据之间的复杂关系进行建模, 最终形成有序、复杂且稳定的网络结构。

此外, ANN 算法在实际应用中也具有一定的局限性, 如网络结构的确定、激活函数的选择以及迭代次数的确定等。本文根据 6 通道 sEMG 信号特征向量的特点、6 种手势识别的实际需求、训练集数据量以及预测结果等因素, 最终确定输入层为 6 个结点, 3 个隐藏层节点个数依次为 128、64、32, 输出层为 1 个结点的网络结构 (见图 5)。其中, 输入层和隐藏层的激活函数为 Relu、输出层的激活函数为 Softmax。

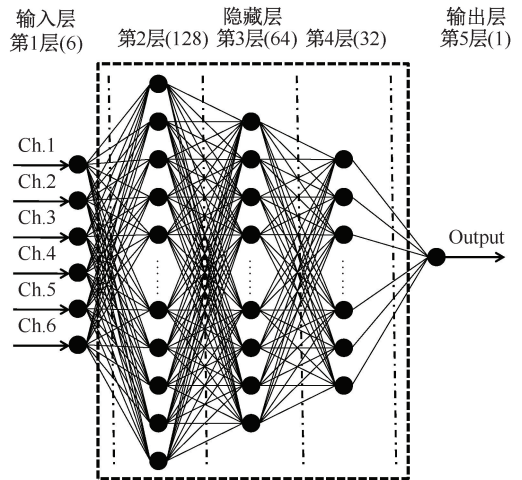


图 5 ANN 算法网络结构

Fig. 5 Network structure of ANN algorithm

## 4 实验结果

### 4.1 手势识别

根据 6 通道 sEMG 信号的 iEMG 进行手势识别, 利用测试集上的混淆矩阵阐述最终的识别精度。结果表明, 测试集上, AdaBoost 算法的总体预测准确率可达 96.5%; ANN 算法的总体预测准确率可达 97.9% (见图 6)。两种分类算法在测试集上的预测准确率均大于 96%, 证明 Adaboost 和 ANN 算法在 sEMG 信号手势识别均具有良好的性能。ANN 算法的识别性能略优于 Adaboost 算法。

同时, 为验证 Adaboost 和 ANN 算法性能, 本文将两种算法与经典分类器进行对比, 选用的经典分类器包括 K-最近邻 (K-nearest neighbor, KNN)、支持

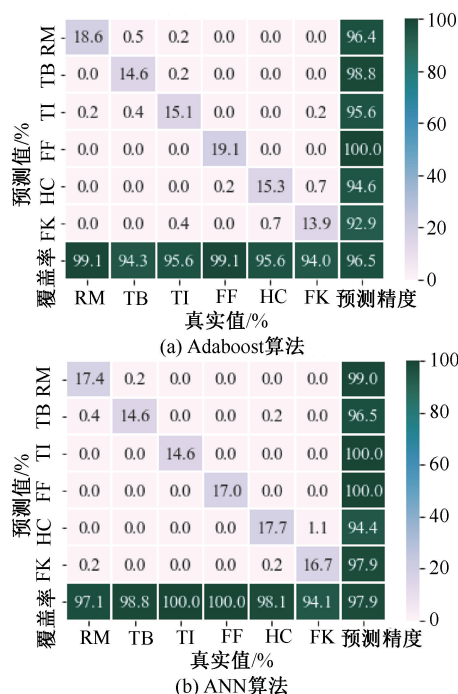


图6 不同算法测试集上的混淆矩阵

Fig. 6 Confusion matrix on the test set of different algorithms

(a) Adaboost algorithm, (b) ANN algorithm

注:RM、TB、TI、FF、HC和FK分别为滚动鼠标、拇指内扣、拇食指捏合、4指弯曲、握杯和5指捏合。

向量机(support vector machine, SVM)、决策树(decision tree, DT)、随机森林(random forest, RF)、梯度提

表3 不同手势拇指、食指关节角度

Tab. 3 Thumb and index finger joint angles for 6 hand gestures

单位:(°)

手势	拇指近端关节	拇指远端关节	食指近端关节	食指中端关节	食指远端关节
RM	156.9±5.7	168.3±8.1	158.3±16.2	134.0±7.8	135.3±9.0
TB	130.3±9.7	140.1±8.5	162.0±6.3	167.6±2.9	172.3±4.8
TI	160.8±6.2	169.4±8.0	132.1±18.8	142.8±24.5	146.0±24.2
FF	148.6±7.3	167.2±11.6	165.5±11.8	109.3±19.4	105.2±16.6
HC	172.4±4.2	147.8±16.4	153.6±7.2	140.9±3.3	140.2±11.2
FK	164.9±8.4	169.5±7.6	116.4±20.0	153.4±19.2	153.9±16.4

同时运用SPSS 23.0,进行6种手势下拇指、食指关节角度之间的相关性分析。结果表明,拇指、食指关节角度之间的相关系数绝对值大于0.5,存在较强相关性。RM和FF手势、TB和FK手势、TI和FK手势之间具有显著相关性(见表4)。对比图6 Adaboost算法测试集和ANN算法测试集上的混淆矩阵,不同手势拇指、食指关节角度之间存在较强相关性,易产生分类预测误判,Adaboost算法表现较为明显。

升树(gradient boosting decision tree, GBDT)、极端梯度增强(extreme gradient boosting, XGBoost)算法等。结果表明,Adaboost和ANN算法在训练集和测试集的预测效果优于KNN、SVM、DT、RF、GBDT和XGBoost几种经典分类器。在几种分类器中,ANN分类器的分类预测性能最好,训练集的预测精度为100.0%,测试集的预测精度为97.9%,Kappa系数为0.975,具有几乎完全一致的分类预测结果(见表2)。

表2 各分类器分类效果对比

Tab. 2 Comparison of classification results by each classifier

机器学习算法	训练集预测精度/%	测试集预测精度/%	Kappa系数
ANN	100.0	97.9	0.975
Adaboost	100.0	96.5	0.958
KNN	100.0	92.8	0.913
SVM	98.2	94.0	0.928
DT	100.0	89.3	0.865
RF	100.0	95.4	0.945
GBDT	94.3	94.2	0.928
XGBoost	100.0	94.9	0.939

## 4.2 关节角度统计

根据20位受试者右手拇指、食指运动学数据,计算6种手势下拇指近端、拇指远端、食指近端、食指中端和食指远端的关节角度(见表3)。本文将手势映射到具体的拇指、食指关节角度,为后续的外骨骼手设计提供依据。

表4 不同手势下拇指、食指关节角度之间相关性矩阵

Tab. 4 Correlation matrix between thumb and index finger joint angles under different hand gestures

手势	RM	TB	TI	FF	HC	FK
RM	1	-0.556	0.038	0.998*	0.448	0.256
TB	-0.556	1	-0.686	-0.549	-0.655	-0.885*
TI	0.038	-0.686	1	0.003	0.038	0.945*
FF	0.998*	-0.549	0.003	1	0.478	-0.231
HC	0.448	-0.655	0.038	0.478	1	0.279
FK	0.256	-0.885*	0.945*	-0.231	0.279	1

注:\* $P < 0.05$ ,具有显著相关性。

## 5 讨论

本文通过采集 20 名成年健康受试者做 6 个精细手部运动时右侧前臂及手部 sEMG 信号,进行时域特征值提取、特征选择和手势模式识别,并进行受试者右手拇指、食指运动轨迹捕捉和拇指、食指关节角度计算,探讨预测误判率与动作关节角度的关系。

本文基于 sEMG 信号的手势识别,以 iEMG 时域特征值作为输入,对比 ANN 和 Adaboost 分类器与传统分类器的分类预测性能。结果表明,ANN 和 Adaboost 分类器的预测性能优于传统分类器,其中 ANN 分类器具有最优的分类预测性能。ANN 分类器合理的网络结构和庞大数据量的支撑,使得 6 种手势下不同受试者数据混合识别效果依然较好。相较于国内外现有的手势识别研究结果<sup>[15-17]</sup>,本文仅使用 6 通道 sEMG 信号的 iEMG 特征值作为机器学习的输入,ANN 分类器的测试集预测精度可达 97.9%,较少的通道选择和仅 iEMG 的特征值选取得到了较高的预测精度。本文结果验证了基于 6 通道 sEMG 信号的 iEMG 进行手势识别的可行性,相较于多通道、多特征值的手势识别算法,简化了外骨骼手控制系统的运算复杂度。此外,相较于先前研究中对不同的单个或两个手指弯屈进行分类<sup>[15-17]</sup>,本文选择的 6 种手势均为模拟日常生活活动的手部精细动作,更具有实际意义。

本文在进行基于 sEMG 信号手势识别分析的同时,采集并分析受试者的手部运动学数据,统计拇指、食指在做不同手势时的关节角度,为外骨骼手的设计提供运动学依据。结果表明,不同手势下拇指、食指关节角度之间存在较强相关性,与手势分类预测误判有一定的关系。然而,由于未考虑中指、无名指和小拇指的关节角度,本文中手部运动学数据统计和不同手势手部关节角度的相关性分析具有一定局限性。在后续研究中,会继续探讨不同手势下 5 指的运动轨迹与关节角度,为外骨骼的设计提供更全面的运动学依据。

## 6 结论

本文对基于 sEMG 信号的手势识别进行研究,实现了根据离线的 6 通道 sEMG 信号 iEMG 进行手

部 6 种精细动作(滚动鼠标、拇指内扣、拇食指捏合、4 指弯曲、握杯、5 指捏合)的识别。对比多种经典分类器,确定分类效果最优的分类器为 ANN 分类器,测试集预测精度可达 97.9%,Kappa 系数可达 0.975,具有几乎完全一致的分类预测结果,证明了外骨骼手基于 6 通道 sEMG 信号的 iEMG 进行手势识别的可行性。此外,手势运动学实验结果也为外骨骼手的设计提供运动学依据,具有实际意义。在后续的工作中,将进一步研究实时的基于 sEMG 信号控制外骨骼手。

### 参考文献:

- [1] LAWRENCE ES, COSHALL C, DUNDAS R, *et al.* Estimates of the prevalence of acute stroke impairments and disability in a multiethnic population [J]. *Stroke*, 2001, 32(6): 1279-1284.
- [2] LAMBERCY O, RANZANI R, GASSERT R. Robot-assisted rehabilitation of hand function [M]//*Rehabilitation Robotics*. London: Academic Press, 2018: 205-225.
- [3] CHANG WH, KIM YH. Robot-assisted therapy in stroke rehabilitation [J]. *J Stroke*, 2013, 15(3): 174-181.
- [4] KWAKKEL G, KOLLEN BJ, KREBS HI. Effects of robot-assisted therapy on upper limb recovery after stroke: A systematic review [J]. *Neurorehabil Neural Repair*, 2008, 22(2): 111-121.
- [5] TUROLLA A. An overall framework for neurorehabilitation robotics: Implications for recovery [M]//London: Academic Press, 2018: 15-27.
- [6] ARTEAGA MV, CASTIBLANCO JC, MONDRAGON IF, *et al.* EMG-driven hand model based on the classification of individual finger movements [J]. *Biomed Signal Process Control*, 2020, 58: 101834.
- [7] LENZI T, DE ROSSI SMM, VITIELLO N, *et al.* Intention-based EMG control for powered exoskeletons [J]. *IEEE Trans Biomed Eng*, 2012, 59(8): 2180-2190.
- [8] PULLIAM CL, LAMBRECHT JM, KIRSCH RF. EMG-based neural network control of transhumeral prostheses [J]. *J Rehabil Res Dev*, 2011, 48(6): 739-754.
- [9] HAYASHI H, FURUI A, KURITA Y, *et al.* A variance distribution model of surface EMG signals based on inverse gamma distribution [J]. *IEEE Trans Biomed Eng*, 2017, 64(11): 2672-2681.
- [10] 牛文鑫. 主动健康中的生物力学 [J]. *医用生物力学*, 2021, 36(5): 676-678.
- NIU WX. Biomechanics in active health [J]. *J Med Biomech*, 2021, 36(5): 676-678.

- [11] PHINYOMARK A, PHUKPATTARANONT P, LIMSAKUL C. Feature reduction and selection for EMG signal classification [J]. *Expert Syst Appl*, 2012, 39(8): 7420-7431.
- [12] NAIK GR, AL-TIMEMY AH, NGUYEN HT. Transradial amputee gesture classification using an optimal number of sEMG sensors: An approach using ICA clustering [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2016, 24(8): 837-846.
- [13] 张腾宇, 樊瑜波. 大腿截肢患者的残肢肌电运动识别 [J]. *医用生物力学*, 2016, 31(6): 478-482.  
ZHANG TY, FAN YB. Motion recognition based on EMG signals of residual limb in transfemoral amputee [J]. *J Med Biomech*, 2016, 31(6): 478-482.
- [14] ROBINSON CP, LI BH, MENG QG, *et al.* Pattern classification of hand movements using time domain features of electromyography [C]//*Proceedings of the 4<sup>th</sup> International Conference on Movement and Computing (MOCO)*. London: Association Computing Machinery, 2015.
- [15] AL-TIMEMY AH, BUGMANN G, ESCUDERO J, *et al.* Classification of finger movements for the dexterous hand prosthesis control with surface electromyography [J]. *IEEE J Biomed Health Inform*, 2013, 17(3): 608-618.
- [16] AL-TIMEMY AH, BUGMANN G, ESCUDERO J, *et al.* Classification of finger movements for the dexterous hand prosthesis control with surface electromyography [J]. *IEEE J Biomed Health Inform*, 2013, 17(3): 608-618.
- [17] ARIYANTO M, CAESARENDRA W, MUSTAQIM KA, *et al.* Finger movement pattern recognition method using artificial neural network based on electromyography (EMG) sensor [C]//*Proceedings of 2015 International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT)*. Bandung: IEEE, 2016.
- [18] 王新亭, 伊国富, 张峻霞, 等. 基于表面肌电分析老年人负重跨障行走跌倒风险 [J]. *医用生物力学*, 2020, 35(5): 483-489.  
WANG XT, YIN GF, ZHANG JX, *et al.* Fall risk analysis of elderly people with different load distributions during obstacle crossing based on surface electromyography [J]. *J Med Biomech*, 2020, 35(5): 483-489.