

基于时频点密度的肌电信号起止点自适应检测^{*}

盛春华 王 强

(南通大学信息科学技术学院 江苏 南通 226000)

摘 要: 针对传统方法使用经验阈值检测表面肌电信号活动段起止点的不足,提出了一种基于时频点密度的表面肌电信号起止点自适应检测方法,该方法创新地使用时频点密度作为表面肌电信号的特征参数。首先利用巴特沃斯带通滤波和小波阈值去噪对 Ninapro DB8 数据集中的表面肌电信号进行预处理;利用短时傅里叶变换进行时频分析;接着将表面肌电信号分割成多个连续的单位时频窗口,统计窗口内频率点的数量,提取时频点密度特征参数;最后对特征提取结果进行区间 $[-1,1]$ 的自适应归一化,并利用基于滑动窗口的双值判断法检测表面肌电信号的起始与结束。实验结果表明:该方法能实现在 0.5 s 内准实时检测 sEMG 信号活动段的开始和结束,准确率近乎 100%,较之于其他常见的算法具有更好的准确性;通过归一化后的正值和非正值可以消除个体差异性影响,自适应性强;此外,该方法在手势识别系统中具有较强的实用性。

关键词: 肌电信号;起止点检测;时频点密度;归一化;自适应

中图分类号: TP391.4;TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.4030

An adaptive detection method for start and end of sEMG signal
based on time-frequency point density

Sheng Chunhua Wang Qiang

(School of Information Science and Technology, Nantong University, Nantong 226000, China)

Abstract: Aiming at the deficiency of using empirical threshold to detect the starting and ending points of active segment of surface electromyography (sEMG) signal in traditional methods, an adaptive detection method of sEMG starting and ending points based on time-frequency point density is proposed. Time-frequency point density is innovatively proposed as the characteristic parameter of surface EMG signal in this method. Firstly, butterworth bandpass filtering and wavelet threshold denoising are used to preprocess the sEMG signals in Ninapro DB8 dataset. Short-time Fourier transform is used for time-frequency analysis of signals. Secondly, the sEMG signal is divided into several continuous unit time-frequency windows, the number of frequency points in the windows is counted, and the time-frequency point density (TFPD) characteristic parameters are extracted. Finally, the TFPD results are adaptively normalized in the interval $[-1,1]$, and the start and end of EMG signals are detected by using the binary judgment method based on sliding window. The experimental results show that this method can detect the start and end of sEMG signal activity segment in quasi-real time within 0.5 s, and the accuracy is nearly 100%. Compared with other common algorithms, the proposed method has better accuracy. The influence of individual differences can be eliminated through normalized positive and non-positive values, and the adaptability is strong. In addition, the proposed method has strong practicability in gesture recognition system.

Keywords: electromyography signal; starting and ending point detection; time-frequency point density; normalization; self-adaption

0 引 言

近年来,表面肌电(surface electromyography, sEMG)生物

反馈疗法结合镜像疗法成为医疗康复的一大研究热点^[1-2],该项技术借助平面镜成像的原理,将健侧肌肉动作发出的电信号转换为视觉信号反馈给大脑,再刺激患侧肌肉进行对称运

收稿日期:2024-06-18

* 基金项目:江苏省高等学校自然科学研究重大项目(19KJ320004)、江苏省产学研前瞻性联合研究项目(BY2016053-10)、江苏特聘教授研究资金(06210061007)项目资助

动,这就对 sEMG 信号的实时检测提出了更高的要求,准确检测 sEMG 信号活动段的开始和结束变得至关重要。

sEMG 信号起止点检测的本质是根据肌肉收缩和放松时的特征参数差异,利用检测方法分割出有效的运动电位和无用的静息噪声。针对特征参数的选择,Nikolic 等^[3]利用方差分割信号,发现它优于基于振幅、斜率+最大振幅的方法。成娟等^[4]对比基于样本熵、平均值和 TK 能量算子的活动段检测结果,发现基于样本熵的检测算法总体性能更好。刘声中等^[5]基于短时能量和短时过零率提出了一种改进的活动段检测方法,这些基于时域特征提取的方法受幅值波动性影响较大。因此杨铮借鉴语音信号端点检测的方法,提取了 sEMG 信号的倒谱熵、子带谱熵、频谱值等相对稳定的频域参数进行分割^[6],为了不影响实时性,检测窗口长度较短,检测效果并不理想。

sEMG 信号活动段的检测大致可以分为两种:滑动窗口结合阈值法和模型法。滑动窗口结合阈值法^[7-9]的检测原理是将信号分成若干个固定长度的连续窗口,通过比较每个窗口中的特征参数与预设阈值之间的大小,检测出活动段的开始和结束。有一些研究使用双阈值代替单阈值^[10-11],以提高检测的准确率。但是这种方法无法避免经验阈值的设定,不具有自适应性。模型法是对 sEMG 信号构建检测模型,或者利用算法模型进行检测。李钊等^[12]创建 sEMG 信号极值点空间,计算运动信号激活特征分数进行检测。李瑞辉等^[13]利用能量高斯分布的模型,只能检测重复动作的起止点。Herle 等^[14]先利用低阶的自回归模型提取特征系数,再利用神经网络检测运动信号。周丙涛等^[15]对信号构建几何标签模型,并使用长短期记忆网络和希尔伯特包络线求解标签,检测准确率为 93.11%。Zhang 等^[16]利用马尔科夫链模型检测活动段的起始和结束,准确率分别为 96.25%和 88.13%。张守先^[17]将多种特征参数作为高斯混合模型的输入,对于信噪比为 10 dB 的信号检测准确率为 92.6%,对于信噪比为 20 dB 的信号检测准确率为 94.36%。模型法计算复杂,不仅准确率没有得到较大的提高,而且会影响检测的实时性。

因此,本文围绕现有 sEMG 信号起止点检测研究中准确率低、人为设置经验阈值、受个体差异性影响、检测复杂等问题,提出了一种基于时频点密度特征的自适应检测方法,用于提高检测的性能。

1 sEMG 信号数据处理

1.1 数据集介绍

Ninapro DB8 数据集^[18]是一个基于稀疏多通道的采集方法,用于对手指运动进行估计的公开数据集,动作及对应标签如图 1 所示,包含了 10 名健康受试者右手进行重复动作时的 sEMG 信号,共有 16 个通道,每次动作持续时间为 6 s 左右,共重复 10 次,每次动作间休息 3 s,信号的采样频率为 2 000 Hz。




图 1 Ninapro DB8 数据集动作

Fig. 1 Ninapro DB8 dataset action

1.2 sEMG 信号预处理

sEMG 信号是一种频率较低的生物电信号,主要能量集中在 20~150 Hz 内^[19]。同时由于人体运行机制的复杂性以及日常实验过程中外部环境的不稳定性,在 sEMG 信号的采集往往会混入各种类型的噪声信号,因此本文利用 MATLAB 中的工具箱,对信号进行 20~150 Hz 巴特沃斯带通滤波^[20]和小波阈值去噪^[21]的预处理。

小波阈值去噪的过程包括多尺度小波分解、阈值处理过程和小波重构。为得到良好的去噪信号,需要合理选择小波基函数、分解层数、阈值和阈值函数。本文选择 Sym8 小波基函数,因为该小波基的尺度函数波形与 sEMG 信号波形近似;由于 sEMG 信号的采样频率为 2 000 Hz,根据奈奎斯特采样定理,分解层数选择 5 层;阈值选择基于 Stein 无偏似然估计的 Rigrsure 自适应阈值;阈值函数选择软阈值,即当小波系数的绝对值小于阈值时,将该系数置为零;当小波系数的绝对值大于等于阈值时,将小波系数减去阈值。样本标签“1”的 sEMG 信号预处理前后对比如图 2 所示,从第 10 s 开始,手指运动产生 sEMG 信号。经过预处理之后,毛刺信号得到了有效抑制,小波阈值去噪还有利于抑制心电信号的干扰^[22]。




图 2 预处理前后 sEMG 信号对比

Fig. 2 Comparison of sEMG before and after preprocess

1.3 短时傅里叶变换

柏文展等^[23]利用短时傅里叶变换绘制了语音信号的时频图,从中可以看到频率点及频率功率变化导致语音信号和噪声信号之间存在清晰的分界线。sEMG 信号和语音

信号类似,都是非平稳信号^[24],因此本文使用短时傅里叶变换绘制 sEMG 信号的时频图进行分析。短时傅里叶变换利用加窗的思想将时序信号分割成多个短时段,然后对每个短时段进行傅里叶变换,计算公式为:

$$STFT(t, f) = \int_{-\infty}^{\infty} f(\tau) \omega^*(\tau - t) e^{-j2\pi f\tau} d\tau \quad (1)$$

其中, $f(\tau)$ 表示原始信号, $\omega(t)$ 表示窗函数, $\omega^*(\tau - t)$ 表示复共轭函数, $STFT(t, f)$ 表示信号在时间 t 和频率 f 上的投影。

本文选择汉明窗进行短时傅里叶变换,以提供更准确的频率信息,计算方法如下:

$$\omega(\tau) = 0.54 - 0.46\cos\left(\frac{2\pi\tau}{L-1}\right), 0 \leq \tau \leq L-1 \quad (2)$$

其中, $\omega(\tau)$ 表示窗函数 ω 在样本点 τ 处的值, L 表示窗口长度。窗口长度 L 的设置会影响信号的时间分辨率和频率分辨率。通过改变窗口长度 L 的大小研究窗口长度对时间分辨率和频率分辨率的影响。对图 2 中预处理后的 sEMG 信号无重叠的短时傅里叶变换并绘制时频图,六种窗口长度的结果对比如图 3 所示。




图 3 6 种 L 设置下的时频图

Fig. 3 Time-frequency diagram under six L

当窗口长度从 4 000 向 200 减小时,时频图上的频率点变得更多、更模糊,频率分辨率相应减小,但是时间分辨率增加。当窗口长度为 4 000 和 2 000 时,频率开始的时间延后,消失的时间提前,影响 sEMG 信号起止点的检测。但是无论窗口长度大还是小,当有手指动作发生时,频率点数量和频率功率的增加,手指放松状态和运动状态之间也存在清晰的分界线。

2 基于时频点密度的自适应检测方法

2.1 基于时频点密度的特征提取方法

1) 特征提取原理

基于对 sEMG 信号时频图的发现,本文对时频图划分

单位时频窗口。如图 4 所示,将时间窗口等距离划分成长度为 m 的时间间隔单元,将频率窗口划分为宽度为 n 的频率通带范围。取放松和运动时相同大小的单位窗口,手指运动时产生了更多的频率点数量和频率功率。倒谱熵、频谱方差等参数本质上都是对频率进行不同的数学计算,用平均值表示信号的频域特征,而本文则对窗口内所有因运动导致功率大小发生改变的频率点进行数量 i 统计。将单位时频窗口内的频率点看作图像的像素点,借助点密度聚类^[25]的思想,创新地提出用时频点密度 (time-frequency point density, TFPD) 作为描述 sEMG 信号的特征参数。时频点密度 TFPD 的定义为单位时频窗口面积内发生改变的频率点总量,即:

$$TFPD = \sum_{i=1}^n i / (m \times n) \quad (3)$$




图 4 基于 TFPD 的特征提取原理

Fig. 4 Principle of feature extraction based on TFPD

2) 时间间隔单元选择


王贝贝等^[26-28]使用传统的滑动窗口法进行运动信号窗口分割时,滑动窗口长度的最优设置在 300 ms 左右。较大的滑动窗口长度虽然能捕捉更多的信号特征,有利于提高检测的准确率,但是无法满足检测的实时性。反之,较小的滑动窗口长度虽然能提高检测的时间精度,但是窗口内包含的特征过少会使得参数失去统计意义。因此,本文分别选择时间间隔单元为 $t_1 = 0.5$ s、 $t_2 = 0.25$ s、 $t_3 = 0.2$ s,研究时间间隔单元 t 大小对 TFPD 特征提取结果的影响。时间间隔单元 t 和无重叠短时傅里叶变换时窗口长度 L 的关系如下:

$$\text{时间间隔单元 } t = \frac{\text{窗口长度 } L}{\text{采样频率 } f_s} \quad (4)$$

3) 频率通带宽度选择

对经过预处理后的 sEMG 信号进一步使用等深分箱法统计信号 5 s 静息噪声内的频率信息,确定一个相对稳定和可靠的基准频带范围。等深分箱的深度设为 10 Hz 由于信号的主要频率范围为 20~150 Hz,因此等深分箱的结果中有 13 个频率带,3 种时间间隔单元下的等深分箱结果如图 5 所示。

式(4)表明时间间隔单元和窗口长度呈线性关系,当时时间间隔单元从 0.5 s 向 0.2 s 减小时,频率分辨率变低,静息状态下包含的高频噪声更多,而在 20~70 Hz 低频范围内

图 5 3 种 t 设置下等深分箱结果Fig. 5 Results of equal depth boxing under three t


相对稳定,因此本文选择 20~70 Hz 作为 $TFPD$ 提取的频率通带宽度。

4) $TFPD$ 特征提取方法

基于 $TFPD$ 的特征提取算法的具体流程如图 6 所示,包括初始化、频率记录和频率点密度计算。

步骤 1) 定义初始值 σ 。将初始状态下第 1 个时间间隔单元和第 2 个时间间隔单元内所有频率功率的平均值定义为初始值 σ , 初始值 σ 的计算方法如式(5)所示。初始值的定义是为后续频率的提取提供一个基准值,突出手指运动时的主要频率密度特征,减少不必要的的数据,提高处理效率。

$$\sigma = \sum_{ts=1}^2 E_{(ts)} / 2 \quad (5)$$

图 6 $TFPD$ 特征提取流程图Fig. 6 $TFPD$ feature extraction flow chart

其中, ts 表示时间间隔单元的位置, $\sum_{ts=1}^2 E_{(ts)}$ 表示前两个时间间隔单元内所有频率功率的和。

步骤 2) 输入单个时间间隔单元 t 内的所有频率, 对每个频率进行功率计算, 若该频率功率大于 σ , 则记录该频率功率对应的频率值 f 并返回计算下一个频率功率, 否则直接返回计算下一个频率功率。

步骤 3) 对步骤 2) 中被记录下来的频率进行时频点密度 $TFPD_{(ts)}$ 计算, 计算方法如式(6)所示。

$$TFPD_{(ts)} = \frac{\sum_{ts=1}^n F_{(ts)}}{(f_{\max} - f_{\min}) \times t} \quad (6)$$

其中, $f_{\max}$ 表示频滤通带宽度最大值, $f_{\min}$ 表示频滤通带宽度最小值, t 表示时间间隔单元长度, ts 表示时间间隔单元 t 的位置, $\sum_{ts=1}^n F_{(ts)}$ 表示频率通带宽度内步骤 2) 中记录的单个时间间隔单元内所有频率点之和。

3 种时间间隔单元 t 选择下的 $TFPD$ 特征提取结果如图 7 所示。当手指放松时, $TFPD$ 值较小, 当手指放松时, $TFPD$ 值较大。但是当时间间隔单元过小时, 特征频率出现的概率和噪声频率接近, 手指运动前后的 $TFPD$ 值没有明显区别。

2.2 基于改进归一化的自适应检测方法

线性归一化又称为最小值-最大值归一化法, 是一种常用的数据处理方法, 计算方法如下:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (7)$$

其中, x 表示原始数据, x' 表示归一化后的数据。

因为 $TFPD$ 数据具有时变特性, 在进行最小值-最大



 图 7 3 种 t 设置下 TFPD 特征提取结果

 Fig. 7 TFPD feature extraction results under three t

值归一化处理时,必须考虑到最小值和最大值是动态变化的,以适应随时间和人体运动状态变化而产生的波动,从而更准确地反映数据的实际分布情况。因此,本文对线性归一化法进行改进,提出一种 sEMG 信号起止点的自适应检测算法,算法的流程如图 8 所示。




图 8 改进归一化算法流程图

Fig. 8 Improved normalization algorithm flow chart

步骤 1) 初始化最小值和最大值。为了防止系统引入的错误,舍弃第一个时间间隔单元的 TFPD 值,并将第二个 TFPD 值放大 2 倍,以补偿短时傅里叶变化时频率分辨率降低带来的影响。

$$\alpha = \beta = 2 \times TFPD(ts), ts = 2 \quad (8)$$

其中, α 表示最小值, β 表示最大值, ts 表示时间间隔单元的位置, $TFPD_{(ts)}$ 表示时频点密度值。

步骤 2) 动态更新最大值和最小值,以响应时间的变化,实现实时检测的目的。

$$\begin{aligned} \alpha &= \min(\alpha, TFPD_{(ts)}), ts > 2 \\ \beta &= \max(\beta, TFPD_{(ts)}), ts > 2 \end{aligned} \quad (9)$$

步骤 3) 最小值-最大值归一化,将时频点密度值

$TFPD_{(ts)}$ 归一化到区间 $[-1, 1]$, 得到归一化后的时频点密度 $TFPDN_{(ts)}$ 。

$$TFPDN_{(ts)} = -1, ts = 1, 2$$

$$TFPDN_{(ts)} = \frac{2 \times (TFPD_{(ts)} - \alpha)}{\beta - \alpha} - 1, ts > 2 \quad (10)$$

依次输入 TFPD, 舍弃第 1 个值并给出归一化结果 TFPDN 为 -1, 将第 2 个值扩大 2 倍作为初始的最小值和最大值, 并给出归一化结果为 -1。当出现第 3 个及以后的 TFPD 值时, 通过迭代比较该 TFPD 值与初始值的大小。如果小于初始最小值, 则将该 TFPD 值设为最新最小值, 并进入归一化计算步骤, 否则与初始最大值进行比较。如果大于初始最大值, 则将该 TFPD 值设为最新最大值, 并进入归一化计算步骤, 否则直接进入归一化计算步骤。动态更新最小值和最大值后, 再通过式(10)的归一化计算, 得到归一化后的 TFPDN 结果。

3 结 果

3.1 自适应检测结果

三种时间间隔单元 t 下归一化后的 TFPD 如图 9 所示。当归一化到区间 $[-1, 1]$ 后, sEMG 信号的 TFPD 分布出现一个基本规律: 手指放松时的 TFPD 为非正值, 手指弯曲时的 TFPD 为正值。这种规律与肌肉活动状态下的信号特性相关, 手指放松肌肉舒张时, 频率点数量和功率较少, 归一化后 TFPD 变为非正值。相反, 手指弯曲肌肉收缩时, 频率点数量和功率显著增加, 归一化后 TFPD 变为正值。如果手指放松和弯曲状态下的原始 TFPD 差异较大, 则归一化后的手指弯曲时的正值更大, 手指放松时的非正值更小。如果原值差异较小, 则归一化后手指弯曲时的正值较小, 与零值接近。



 图 9 3 种 t 设置下归一化 TFPDN 结果

 Fig. 9 Result of normalized TFPDN under three t

滑动窗口结合阈值检测法因其过程简单, 更能满足本文对实时检测的要求。如图 10 所示, 检测时的阈值选择为

“正值”和“非正值”。当 $TFPD$ 为正值时,检测为 sEMG 信号活动段开始;当 $TFPD$ 为非正值时,检测为 sEMG 信号活动段结束。由于 sEMG 信号采集过程中的环境因素以及短时傅里叶变换时的加窗影响,若滑动窗口长度 w 设为 1,滑动步长 s 设为 1,则会导致异常检测结果的出现。为了提高检测的准确性,将滑动窗口长度 w 设为 2,用双值判断法进行检测。即相邻两个 $TFPD$ 均为正值,则检测为 sEMG 信号开始;相邻两个 $TFPD$ 均为非正值,则检测为 sEMG 信号结束;相邻两个 $TFPD$ 一个为正值,一个为非正值,则保持前一个检测状态。




图 10 基于滑动窗口的双值判断法原理

Fig. 10 Principle of double-value judgment method based on sliding window

当时间间隔单元 t 为 0.5 s 时,异常值较少,利用双值判断法会增加系统检测的时长,实时性较差。而当时间间隔单元 t 为 0.2 s 时,出现多处异常值,时间间隔单元 t 过小,检测失效。出现异常值的可能原因有:1)受到短时傅里叶变换时频率分辨率降低的影响,噪声频率与主要频率的数量接近;2)高密度阵列的放置,导致电极之间存在相互干扰,随机选择的通道不能完全代表该动作发生的 sEMG 信号。因此本文选择时间间隔单元为 0.25 s,以同时满足检测准确性和实时性的要求。

3.2 普适性验证

随机选择 Ninapro 数据集中不同性别、不同动作、不同通道的 sEMG 信号对本文的算法进行验证,结果如图 11 所示。因为本文基于 $TFPD$ 的自适应检测方法以不同性别、年龄、状态的受试者初始状态下的频率功率均值作为特征提取条件,所以检测结果不受个体差异性影响,具有普适性。




图 11 Ninapro DB8 数据集检测结果

Fig. 11 Detection results of Ninapro DB8 dataset

3.3 检测方法对比

为验证本文方法具有较强的自适应性和较高的准确性,选择常用的短时能量、样本熵、倒谱熵、频谱方差^[29]算法,以及滑动窗口结合最大值-最小值阈值法^[30]对 Ninapro DB8 数据库中 500 个样本信号进行对比检测,参数设置和检测结果如表 1 所示。

表 1 参数设置和检测结果


Table 1 Parameter settings and detection results

参数类型	滑动长度/ms	滑动步长/ms	阈值系数/阈值	检测准确率/%
短时能量	250	125	0.018	91.45
样本熵	300	150	0.045	93.50
倒谱熵	600	300	0.61	95.60
频谱方差	600	300	3.4	95.28
时频点密度	500	250	$>0, \leq 0$	99.97

短时能量和样本熵属于时域参数,受幅值波动影响较大,导致检测准确率较低。相比于时域参数,频域特征具有相对稳定性^[31]。倒谱熵和频谱方差都是计算窗口内的平均频率, $TFPD$ 则是对窗口内所有符合条件的频率进行统计,更能全面表征信号的变化特点。传统方法不仅需要不断调整合适的窗口长度和阈值大小,而且检测准确率的提高需要牺牲检测的时间尺度。本文利用“ >0 ”和“ ≤ 0 ”代替经验阈值设定,可以在 0.5 s 内完成一次准确检测。虽然时间尺度相较于其他方法较大,但是有研究表明,在皮肤表面检测到的肌电信号比肌肉实际收缩超前 30 ~ 200 ms^[32],该方法存在的较少延时在实际应用中可以忽略不计。

3.4 检测方法系统验证

sEMG 信号的起止点检测相当于手指的“开/关”,因此将基于 $TFPD$ 的 sEMG 信号端点检测方法应用于手势识别系统中,借助假手模拟镜像的效果,可以识别握拳、比“耶”、比数字“6”、比数字“8”等基本动作,如图 12 所示,说明该方法在医疗康复领域具有一定的实用性。



(a) 握拳
(a) Fist

(b) 比“耶”
(b) “Victory”




图 12 手势识别结果

Fig. 12 Result of gesture recognition

4 结 论

本文对短时傅里叶变换后的时频图进行分析,创新地提出了一种时频特征参数:时频点密度。时频点密度是一种统计量,对运动时发生变化的频率进行统计,而非找出单一的特征频率,因此对噪声的鲁棒性更好,改进了传统特征参数稳定性差的缺点。并且根据特征提取结果提出了基于改进归一化的自适应检测算法,用正值和非正值代替传统依赖大量已采集数据得到的经验阈值,具有自适应性。经大量数据验证,利用双值判断法可以有效提高 sEMG 信号活动段起止点检测的准确率,实现了在 0.5 s 内准确率近乎 100% 的准实时检测。最后将该方法应用于手势识别系统中,为基于 sEMG 信号的医疗康复技术提供方案。

参考文献

- [1] 王耀霆,姚佳琴,王红雨,等. 肌电生物反馈疗法结合镜像疗法对脑卒中患者下肢运动和平衡功能的影响[J]. 中国康复医学杂志, 2024, 39(3): 375-381.
WANG Y T, YAO J Q, WANG H Y, et al. Effects of electromyographic biofeedback therapy combined with mirror therapy on lower limb motor and balance function in stroke patients [J]. Chinese Journal of Rehabilitation Medicine, 2024, 39(3): 375-381.
- [2] AMIN F, WARIS A, IQBAL J, et al. Maximizing stroke recovery with advanced technologies: A comprehensive assessment of robot-assisted, EMG-controlled robotics, virtual reality, and mirror therapy interventions [J]. Results in Engineering, 2024, 21(3): 101725.
- [3] NIKOLIC M, KRARUP C. EMGTools, an adaptive and versatile tool for detailed EMG analysis[J]. IEEE Transactions on Bio-medical Engineering, 2011, 58(10): 2707.
- [4] 成娟,陈勋,彭虎. 基于样本熵的肌电信号起始点检测研究[J]. 电子学报, 2016, 44(2): 479-484.

CHENG J, CHEN X, PENG H. An onset detection method for action surface electromyography based on sample entropy [J]. Acta Electronica Sinica, 2016, 44(2): 479-484.

- [5] 刘声中,许德章. 一种基于改进 sEMG 活动段检测的手部运动意图识别新方法[J]. 嘉兴学院学报, 2022, 34(6): 105-112.
LIU SH ZH, XU D ZH. A new method for hand motion intent recognition based on improved sEMG signal active segment detection[J]. Journal of Jiaxing University, 2022, 34(6): 105-112.
- [6] 杨铮. 基于肌肉活动段检测表面肌电信号灵敏性研究[D]. 保定:河北大学, 2018.
YANG ZH. The study of surface electromyography signal sensitivity based on muscle activity segment detection[D]. Baoding: Hebei University, 2018.
- [7] 杨庆华,金圣权,都明宇,等. 基于表面肌电和位姿信息融合的手势动作识别[J]. 高技术通讯, 2023, 33(12): 1295-1302.
YANG Q H, JIN SH Q, DU M Y, et al. Gesture action recognition based on fusion of surface electromyography and pose information[J]. Chinese High Technology Letters, 2023, 33(12): 1295-1302.
- [8] 孙晓强,于旭东. 下肢外骨骼机器人步态识别系统综述[J]. 人工智能, 2024(1): 66-80.
SUN X Q, YU X D. Overview of gait recognition system of lower limb exoskeleton robot[J]. Artificial Intelligence View, 2024(1): 66-80.
- [9] 孔冬荣,朱杰. 基于表面肌电和加速度信息融合的手势识别[J]. 电子测量技术, 2019, 42(5): 85-89.
KONG D R, ZHU J. Gesture recognition based on fusion of surface electromyography and acceleration information[J]. Electronic Measurement Technology, 2019, 42(5): 85-89.
- [10] ZHANG CH, WU Q, MA ZH J. Detection of active segments of lower limbs EMG signal based on time-domain variance combined with short-term energy[J]. Journal of Physics: Conference Series, 2022, 2395(1): 012049.
- [11] MENDES JUNIOR J J A, FREITAS M L B, Campos D P, et al. Analysis of influence of segmentation, features, and classification in sEMG processing: A case study of recognition of brazilian sign language alphabet [J]. Sensors, 2020, 20(16): 4359.
- [12] 李钊,马斌,李海,等. 表面肌电信号的自适应激活特征提取算法[J]. 传感器与微系统, 2023, 42(8): 114-118.
LI ZH, MA B, LI H, et al. Self-adaptive activation feature extraction algorithm for sEMG signal [J].

- Transducer and Microsystem Technologies, 2023, 42(8): 114-118.
- [13] 李瑞辉, 范志坚, 赵翠莲, 等. 利用 sEMG 能量高斯分布特性提取动作信号的方法[J]. 中国医疗器械杂志, 2014, 38(3): 177-180.
- LI R H, FAN ZH J, ZHAO C L, et al. Motion signal extraction method based on sEMG energy gauss distribution characteristics [J]. Chinese Journal of Medical Instrumentation, 2014, 38(3): 177-180.
- [14] HERLE S, MAN S, LAZEA G, et al. Myoelectrical signal classification for the hierarchical control of a human hand prosthesis [C]. IEEE International Conference on Automation Quality and Testing Robotics, 2010.
- [15] 周丙涛, 朱黎, 向勉. 基于标签几何化与特征融合的 sEMG 手势分割分类[J]. 传感技术学报, 2023, 36(10): 1628-1634.
- ZHOU B T, ZHU L, XIANG M. Research on sEMG gesture segmentation and classification algorithm based on geometrical label and feature fusion[J]. Journal of Transduction Technology, 2023, 36(10): 1628-1634.
- [16] ZHANG H W, XU L S, CHEN G. Active movements intention recognition for upper limb rehabilitation robots based on EMG signals [C]. 2023 IEEE International Conference on Real-time Computing and Robotics(RCAR), 2023.
- [17] 张守先. 基于小波分析表面肌电信号的上肢肌肉力估计[D]. 沈阳:沈阳工业大学, 2017.
- ZHANG SH X. Estimation of muscle force for upper limb based on wavelet analysis of sEMG signals[D]. Shenyang:Shenyang University of Technology, 2017.
- [18] XIONG D ZH, ZHANG D H, ZHAO X G, et al. Deep learning for EMG-based human-machine interaction: A review [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(3): 512-533.
- [19] 崔冰艳, 邓嘉, 张祥. 基于表面肌电信号的手势识别方法[J]. 科学技术与工程, 2023, 23(35): 15133-15141.
- CUI B Y, DENG J, ZHANG X. Hand gesture recognition based on surface electromyography [J]. Science Technology and Engineering, 2023, 23(35): 15133-15141.
- [20] 张鑫, 李婉婷, 陈岩, 等. 基于递归神经网络的人体下肢运动意图识别方法[J]. 机器人外科学杂志(中英文), 2024, 5(2): 121-129.
- ZHANG X, LI W T, CHEN Y, et al. A motion intention recognition method of human lower limbs based on recurrent neural network[J]. Chinese Journal of Robotic Surgery, 2024, 5(2): 121-129.
- [21] 张锐浩, 李昀泽, 党立志, 等. 基于 AD8232 的表面肌电信号采集系统设计[J]. 电子测量技术, 2023, 46(6): 173-177.
- ZHANG R H, LI Y Z, DANG L ZH, et al. Design of surface EMG signal acquisition system based on AD8232 [J]. Electronic Measurement Technology, 2023, 46(6): 173-177.
- [22] 张恒玮, 徐林森, 陈根, 等. 基于迁移学习和表面肌电信号的上肢动作识别[J]. 计算机工程与应用, 2024, 60(20):124-132.
- ZHANG H W, XU L S, CHEN G, et al. Upper limb action recognition based on transfer learning and sEMG[J]. Computer Engineering and Applications, 2024, 60(20):124-132.
- [23] 柏文展, 程汪鑫. 汉语方言语音信号的语谱图分析[J]. 电声技术, 2022, 46(4): 41-46.
- BAI W ZH, CHENG W X. Speech spectrogram analysis of Chinese idiom [J]. Audio Engineering, 2022, 46(4): 41-46.
- [24] LIAO SH CH, LI G F, LI J H, et al. Multi-object intergroup gesture recognition combined with fusion feature and KNN algorithm[J]. Journal of Intelligent and Fuzzy Systems, 2020, 38(3): 2725-2735.
- [25] 李愚, 柴国钟, 卢纯福, 等. 基于增量自适应学习的在线肌电手势识别[J]. 计算机科学, 2019, 46(4): 274-279.
- LI Y, CHAI G ZH, LU CH F, et al. On-line sEMG hand gesture recognition based on incremental adaptive learning [J]. Computer Science, 2019, 46(4): 274-279.
- [26] 王贝贝. 基于表面肌电信号的手势识别及交互控制研究[D]. 杭州:浙江科技学院, 2022.
- WANG B B. Gesture recognition and interactive control based on surface electromyography [D]. Hangzhou: Zhejiang University of Science and Technology, 2022.
- [27] 来金宝, 陶庆, 胡玉舫, 等. 基于人工鱼群算法-极限学习机的多手势精准识别[J]. 工程设计学报, 2021, 28(6): 671-678.
- LAI Q B, TAO Q, HU Y G, et al. Multi-gesture accurate recognition based on artificial fish swarm algorithmextreme learning machine [J]. Chinese Journal of Engineering Design, 2021, 28(6): 671-678.
- [28] CHO G Y, YANG W, LEE D H, et al. Characterization of signal features for real-time sEMG onset detection[J]. Biomedical signal processing and control, 2023(84): 104774.
- [29] LU D Y, TIAN G Y, LU X SH, et al. Improved

- speech enhancement algorithm based on bark bands noise-estimation for non-stationary environment[J]. Applied Mechanics and Materials, 2013, 2601 (385-386): 1398-1401.
- [30] 胡学政, 陶庆, 赵暮超, 等. 采用迁移学习的表面肌电信号手势识别方法[J]. 科学技术与工程, 2024, 24(12): 5044-5050.
- HU X ZH, TAO Q, ZHAO M CH, et al. sEMG gesture recognition method using transfer learning[J]. Science Technology and Engineering, 2024, 24(12): 5044-5050.
- [31] GAO F R, TIAN T X, YAO T, et al. Human gait recognition based on multiple feature combination and parameter optimization algorithms[J]. Computational Intelligence and Neuroscience, 2021(2): 1-14.
- [32] 周国良, 张道辉, 郭小萍. 基于 TiCNN-DRSN 模型的 sEMG 手势识别算法的研究[J]. 电子测量技术, 2024, 47(6): 190-196.
- ZHOU G L, ZHANG D H, GUO X P. Research on sEMG gesture recognition algorithm based on TiCNN-DRSN model[J]. Electronic Measurement Technology 2024, 47(6): 190-196.

作者简介

王强(通信作者), 博士, 教授, 主要研究方向为人工智能和传感器及信号处理等。

E-mail: wang_q@ntu.edu.cn