

DOI: 10.19650/j.cnki.cjsi.J2412468

基于下肢 sEMG 的疲劳模糊增量熵表征方法研究*

石欣¹, 余可祺¹, 敖钰民¹, 秦鹏杰², 张杰毅³

(1. 重庆大学自动化学院 重庆 400044; 2. 中国科学院深圳先进技术研究院 深圳 518055;
3. 四川电力职业技术学院 成都 611133)

摘要:连续运动中,基于表面肌电信号(sEMG)外骨骼机器人与人进行协同运动控制,肌肉产生疲劳将影响人机协同控制的柔顺性及鲁棒性。本文创新性地提出模糊增量熵(EIFEn)用以表征肌肉疲劳程度,并对肌肉疲劳阶段的较为客观划分;采集人体连续抬腿运动中下肢12块肌肉的表面肌电信号,提出基于变异性敏感系数SVR肌肉疲劳敏感度判断方式,实现有效肌肉选取,提出基于均模积的自适应阈值动作切分法,将完整信号切分并提取单个动作信号序列,通过分析计算,对疲劳趋势进行表征。实验结果表明,本文模型相比时域频域算法具有较为明显的肌肉疲劳表征梯度特征,与fApEn及FFDispEn相比具有较好的疲劳表征能力,用于疲劳等级聚类的戴维森堡丁指数(DBI)为0.39,可提高外骨骼人机协同控制,为实现疲劳分阶段补偿助力提供参考。

关键词: sEMG; 肌肉疲劳; 动作切分; 模糊增量熵; 特征提取; 聚类

中图分类号: TH70 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on entropy of incremental fuzzy entropy representation model for lower limb fatigue based on sEMG

Shi Xin¹, Yu Keqi¹, Ao Yumin¹, Qin Pengjie², Zhang Jieyi³

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China; 3. Sichuan Electric Vocation and Technical College, Chengdu 611133, China)

Abstract: In continuous motion, based on surface electromyography (sEMG) signals, exoskeleton robots and humans collaborate in motion control. Muscle fatigue will affect the flexibility and robustness of human-machine collaborative control. This article innovatively proposes the use of Entropy of Incremental Fuzzy Entropy and constructs a fatigue characterization model, and objectively divides the stages of muscle fatigue; Collect sEMG signals of twelve muscles in the lower limbs during repeated continuous leg lifting movements, propose a method based on the variability sensitivity coefficient SVR to determine muscle fatigue sensitivity, achieve effective muscle selection for this movement, reduce data dimensions, propose an adaptive threshold action segmentation method based on mean squared product, segment the complete signal and extract a single action signal sequence, and analyze and calculate the fatigue trend through this model. The experimental results of the subjects show that the model proposed in this paper has a more obvious gradient feature for muscle fatigue characterization compared to time-domain and frequency-domain algorithms, and has better fatigue characterization ability compared to fApEn and FFDispEn. Davies Bouldin Index for fatigue level clustering is 0.39. This provides a reference for improving the collaborative control of exoskeletons and achieving phased compensation assistance for fatigue.

Keywords: sEMG; muscle fatigue; action segmentation; entropy of incremental fuzzy entropy; feature extraction; clustering

0 引言

目前,大量科研团队将肌电信号用于外骨骼的控制中,通过解析人体下肢表面肌电信号来识别运动意图,然后将运动意图转化为外骨骼的控制指令。由于肌电信号提前于人体产生的特性^[1],可以在人体动作前解析运动意图^[2],以柔顺控制外骨骼。

外骨骼在军用或民用等使用环境中,穿戴者为健康人群,且处于需要助力的高强度运动环境中,因此会极易产生肌肉疲劳现象。

肌肉疲劳是一种可逆的肌肉发力减少表现^[3],肌肉疲劳引起的肌电信号变化规律也是众多学者研究和关注的对象。在对下肢疲劳过程的研究中,将肌肉的收缩方式分为等长收缩以及等张收缩,即静态收缩及动态收缩。前者的收缩模式中,导致肌电信号功率谱变化的因素主要是肌肉内生代谢产物的积累^[4],后者在产生代谢物的同时也受生物力学的影响。由于受影响因素相对等张收缩更少,目前多数学者采用等长收缩的方式进行疲劳表征研究。但为了扩大研究在人体工学以及临床的适用性,且更贴近助力外骨骼在实际生产生活中的使用场景,本文在肌肉等张收缩的条件下对肌肉疲劳表征进行研究。

目前针对疲劳表征的研究表明,在肌肉持续收缩并达到疲劳的过程中,时域指标伴随肌力的增加和疲劳的产生而增加^[5]。而频域指标随肌力的增加而增加,但却随疲劳的发生而降低^[6]。综上,肌电信号特征值存在随肌肉疲劳进行变化的性质,这给在疲劳状态下的外骨骼控制带来了极大的难度。通过对肌电信号特征值在疲劳过程中的变化进行分析,可以对肌肉疲劳进行表征,从而客观地对肌肉疲劳程度进行描述。在此过程中,肌电信号的非平稳性和复杂性以及个体疲劳的耐受度不一成为了利用肌电信号特征进行疲劳表征的难点^[7]。

目前常用于肌肉疲劳表征的时域指标主要有平均绝对值(mean absolute value, MAV)、均方根(root mean square, RMS)^[8]、肌电积分值(integral of EMG, IEMG)^[9]以及近似熵(approximate entropy, ApEn)^[10]等特征,并且同时许多学者也采用时域特征判断肌肉激活度。由于频域指标更不易受噪声影响^[11],更多学者采用频域指标对肌肉疲劳进行表征,其中被使用较多的是中值频率(median frequency, MDF)、平均频率(mean frequency, MNF)^[12-13]以及功率谱密度(power spectral density, PSD)^[14]等。

尽管近年来针对肌肉疲劳状态的检测和预测的研究取得了良好的效果,但是,利用自主系统实现疲劳检测和预测的研究较少^[15]。

近两年,一些学者通过探索新的肌肉疲劳特征值对疲劳进行表征。Wang等^[16]提出快速精细复合多尺度样本熵进行疲劳分析,可以在不同信号长度下将肌肉疲劳分为非疲劳及疲劳两种类别。Hu等^[17]提出一种新的分数阶模糊色散熵,在色散熵的基础上加入模糊集和分数微积分的概念,将疲劳阶段有效分为疲劳及非疲劳。Sasidharan等^[18]提出的基于马尔可夫转换场的动态表面肌电信号可视化肌肉疲劳分析方法,该方法可对肌肉非疲劳和疲劳状态进行区分。但是多数研究仅能将肌肉疲劳划分为疲劳及非疲劳两种状态,且由于疲劳阶段划分的模糊性,通过分类器进行疲劳分类的方式仅能判断非疲劳和最终疲劳状态的差别,无法对整个疲劳过程的疲劳情况进行检测。

为将疲劳划分为更多等级,便于在外骨骼控制中输入代表疲劳状态的离散信号,2023年中国科学院机器人与智能制造创新研究院采用Hammerstein模型中的动态线性部分参数对疲劳进行表征,通过层次聚类法划分出了3个疲劳阶段^[19]。

为实现客观准确划分多个疲劳阶段的目的,本文提出了模糊增量熵的新疲劳表征方法,用于表征信号模糊熵的混乱程度变化情况。通过本文后续实验发现,人体下肢肌肉疲劳过程中,肌电信号在模糊增量熵的表征下呈现明显的分段现象,相比于其他特征值有更强的疲劳阶段区分能力,可以借助聚类方法达到对疲劳程度进行客观划分的效果。

故本文采用肌电信号的模糊增量熵作为特征值进行肌肉疲劳表征,并且根据表征结果对肌肉疲劳程度进行聚类分析,将整个疲劳过程分为3种疲劳程度类别,以便于在外骨骼控制中根据不同疲劳阶段提供相应的补偿信号,以更好地达到人机融合的目的。

1 模糊增量熵表示方法

1.1 标准模糊熵表示方法

由近似熵改进为模糊熵方式如下:

对于包含 N 个数据点 $\{u(i):1 \leq i \leq N\}$ 的时间序列,其中的一个向量序列 X_i^m 可表示为以下表达式:

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} \\ 1 \leq i \leq N-m+1 \quad (1)$$

其中, X_i^m 即为从第 i 个点开始的 m 个连续的向量 u 组成的向量序列。将 X_i^m 与 X_j^m 之间的距离定义为 d_{ij}^m ,其表达式如下:

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} |u(i+k) - u(j+k)| \quad (2)$$

将向量 X_i^m 与 X_j^m 之间的相似度定义为 $C_r^m(i)$, 其表达式如下:

$$C_r^m(i) = \frac{1}{N - m + 1} \cdot \sum_{j=1, j \neq i}^{N-m+1} \Theta(d_{ij}^m - r) \quad (3)$$

式中的 Θ 为 Heaviside 函数, 表达式如下:

$$\Theta(z) = \begin{cases} 1, & z \leq 0 \\ 0, & z > 0 \end{cases} \quad (4)$$

式(3)中的 r 代表定容差值, 表达式如下:

$$r = k \cdot std(T) \quad (5)$$

式中: k 为大于 0 的常数, 而函数 $std(\cdot)$ 代表时间序列的标准差。

对于每个 $C_r^m(i)$, 计算其对数值, 再求出其对数平均值, 如下式所示:

$$\phi^m(r) = \frac{1}{N - m + 1} \cdot \sum_{i=1}^{N-m+1} \ln[C_r^m(i)] \quad (6)$$

由此可得出时间序列的近似熵表达式为:

$$ApEn(m, r) = \lim_{N \rightarrow \infty} [\phi^m(r) - \phi^{m+1}(r)] \quad (7)$$

在实际应用中, 使用由 N 个数点组成的有限时间序列来估计该时间序列的 ApEn 值, 定义为:

$$ApEn(m, r, N) = \phi^m(r) - \phi^{m+1}(r) \quad (8)$$

式中: m 即为模式维数, 用于代表近似熵时间序列的窗口长度, 一般在 1~3 的自然数中选取。

近似熵的定义式中的 Heaviside 函数是不连续的。导致对于不同的输入信号, 该函数会形成一个二分类器。但在处理肌电信号的过程中, 类与类的界限是模糊的, 故 Zadeh 通过引入模糊集的概念来解决此问题^[20]。引入了一个模糊隶属度函数 $u_z(x)$ 来实现模糊集的建立, 其中 x 为 $[0, 1]$ 范围内的实数。由此引入了模糊熵 (fApEn) 的概念, 在模糊熵的表示中, 利用模糊隶属度函数 $u(d_{ij}^m, r)$, 根据 X_i^m 与 X_j^m 的形状可以得出对它们之间相似度的模糊度量。

基于模糊隶属度函数的相似度新指标 $u(d_{ij}^m, r)$, 随着 Heaviside 函数使边界模糊化, 采样点变得更加接近, 更加相似。

通过上述新的相似度指标, 可以得出模糊熵的表示方法: X_i^m 采用与式(1)相同的向量表达式, 通过去基线 $u0(i)$ 的方式将 X_i^m 一般化, 其中 $u0(i)$ 由向量 X_i^m 均值定义:

$$u0(i) = \frac{1}{m} \sum_{l=0}^{m-1} u(i+l) \quad (9)$$

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m+1)\} - u0(i) \quad (i=1, \dots, N-m+1) \quad (10)$$

X_i^m 与 X_j^m 之间的距离 d_{ij}^m 可以表示为:

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} |u(i+k) - u0(i) - (u(j+k) - u0(j))| \quad (i, j = 1 \sim N - m + 1, j \neq i) \quad (11)$$

给定一个 r , 则 X_i^m 与 X_j^m 之间的相似度 D_{ij}^m 可以由模糊隶属度函数确定:

$$D_{ij}^m = u(d_{ij}^m, r) \quad (12)$$

函数 B_r^m 由下式决定:

$$C_r^m(i) = \frac{1}{N - m + 1} \sum_{j=1, j \neq i}^{N-m+1} D_{ij}^m \quad (13)$$

$$\phi^m(r) = \frac{1}{N - m + 1} \cdot \sum_{i=1}^{N-m+1} \ln[C_r^m(i)] \quad (14)$$

通过向量序列 $\{X_i^{m+1}\}$ 以及函数 $\phi^{m+1}(r)$, 可以将时间序列的 $fApEn(m, r)$ 定义为:

$$fApEn(m, r) = \lim_{N \rightarrow \infty} [\phi^m(r) - \phi^{m+1}(r)] \quad (15)$$

同样的, 在实际应用中, 以有限时间序列估计的 $fApEn$ 可写为:

$$fApEn(m, r, N) = \phi^m(r) - \phi^{m+1}(r) \quad (16)$$

采用高斯函数作为模糊隶属度函数来计算 $fApEn$ 的结果:

$$u(d_{ij}^m, r) = \exp(-d_{ij}^2/r) \quad (17)$$

1.2 肌电信号模糊增量熵的表示方法

通过实验发现, 疲劳过程中, 肌电信号的模糊熵自身也存在复杂度变化情况, 并且随着疲劳程度的加深, 这种复杂度变化也随之变大。故本文引入模糊增量熵的概念, 对模糊熵的复杂度变化程度进行表征。

在由非疲劳状态到力竭的过程中, 由于本文采用等张收缩的方式诱导疲劳, 故可将整个疲劳过程的肌电性划分为 n 个等张收缩的动作段, 每个动作的肌电图形状大致相似, 通过按照单次动作时间无重叠等距离滑窗的方法可将完整的肌电信号进行切分。

将第一个动作信号段视为单独的时间序列 $\{u_1(i) : 1 \leq i \leq N_1\}$, 按照上述步骤进行时间序列估计 $fApEn$, 得到 f_1 值, 将其输入有 n 个 0 值的时间序列中, 可表示为:

$$X_1 = \{f_1, 0, \dots, 0\} \quad (18)$$

此时 0 值的个数为 $n - 1$ 。

对时间序列 X_1 估计 $fApEn$ 值, 得出模糊增量熵特征序列的第一个值 h_1 。在对疲劳过程中肌电信号的研究中, 由于该序列只有一个非零值, 熵的大小可近似为 0, 故以此作为疲劳过程的起始点, 且设定该状态为非疲劳状态。

以此类推, 对每个信号段重复该步骤, 直至产生输入第 n 个动作的 $fApEn$ 值的时间序列 X_n , 可表示为:

$$X_n = \{f_1, f_2, \dots, f_n\} \quad (19)$$

对时间序列 X_n 估计 $fApEn$ 值, 得出模糊增量熵特征序列的最后一个值 h_n 。此时可得出由 n 个模糊近似熵组成的新序列 h_1, h_2, \dots, h_n , 即为该信号的模糊增量熵序列。

计算肌电信号模糊增量熵流程图如图 1 所示。

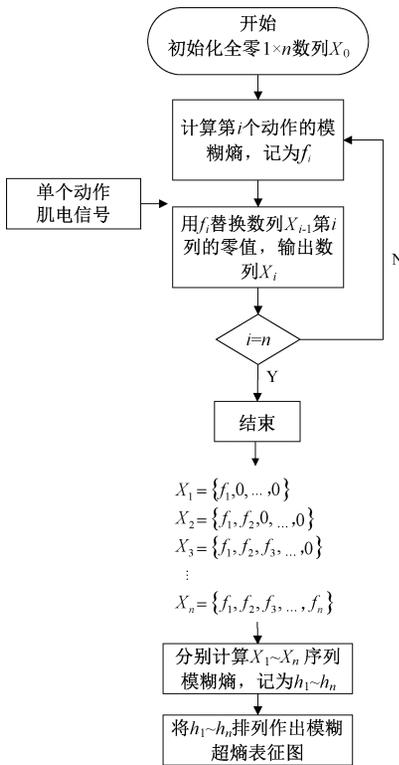


图1 模糊增量熵计算流程示意图

Fig. 1 Diagram of entropy of fApEn calculation process

由于在计算过程中采用的是向序列中逐步添值的方法,故将该值命名为模糊增量熵。模糊增量熵计算序列中的非零值随输入的动作增加而增加,因此在序列所剩零值较多时,即模糊增量熵的靠前区域,具有单调递增的特性,在研究疲劳变化的过程中具有更加明显的变化特征以便于观察疲劳变化的趋势。同时,采用这种下采样的方式可使特征分布更加集中,便于对疲劳阶段进行聚类处理。

2 基于均模积的自适应阈值动作切分方法

由于计算模糊增量熵时输入的为单个动作信号序列,故在进行计算前需进行动作切分。

本文提出一种基于均模积的自适应软阈值动作切分方法,可将包含信息最多抬腿动作段实时准确切分。

RMS 可以很好地反映出每个抬腿动作的包络线,许多学者采用 RMS 进行阈值检测从而识别动作段肌电信号。

首先计算表面肌电信号的 RMS 值,对其进行重叠滑窗,信号的总长度为 N ,设置窗长为 T ,窗移为 M ,可将第 i 帧的第 n 个采样点的肌电信号表示为:

$$x(i, n) = x((i-1) \times M + T) \quad (20)$$

使用下式计算第 i 帧信号的 RMS 值:

$$RMS(i) = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(i, n)} \quad (21)$$

使用 RMS 进行动作切分存在以下两个缺点:

1) RMS 对信号毛刺识别较敏感,易将毛刺段判断为动作段。

2) 由图 6 所示的原始信号可看出,由于本文需识别的连续动作幅值随疲劳明显增大,导致信号整体前端的 RMS 值较小,后端值较大,故使用基于全局的阈值进行动作切分会带来较大误差。

针对上述问题 1), 本文提出了均模积(the product of RMS and fApEn, RFP) 的概念,将 RMS 与 fApEn 相乘再用于阈值计算,由于 fApEn 在信号毛刺段的值通常较小,可通过缩小毛刺信号达到准确识别动作段的目的。针对问题 2), 本文基于疲劳分段提出了自适应阈值计算方法,减少肌电信号幅值变化带来的误差。

对滑窗的每一帧计算均模积与模糊增量熵,其中均模积用于阈值计算,模糊增量熵用于判断疲劳状态。

根据下式计算第 i 帧的均模积:

$$RFP_i = RMS(i) \times fApEn(m, r, i) \quad (22)$$

首先根据历史数据计算第一个疲劳阶段所对应的阈值,确定初始的阈值:

$$th = b \frac{\sum_{i=1}^l h_i}{l} \quad (23)$$

其中, b 为根据经验确定的参数,本文取 0.1, l 为历史数据中第一个疲劳阶段的动作个数,根据聚类结果取为 50。

判断处于非动作段时,根据前一动作段的模糊增量熵进行疲劳阶段判断,设疲劳阶段 n 的第 k 个动作为 A_n^k , 设定一个膨胀系数 α , 其表达式为:

$$\alpha = \frac{h_{A_{n+1}^1}}{h_{A_n^1}} \quad (24)$$

更新阈值的计算方式为:

$$th_{new} = \alpha \times th \quad (25)$$

对于从第 d 帧开始的信号,基于均模积的自适应阈值动作切分方法流程图如图 2 所示。

3 相关工作

3.1 原始数据采集

利用英国 Biometrics 公司研发生产的 Biometrics Ltd. 表面肌电采集系统对 5 位受试者进行表面肌电信号的采集,采样频率为 1 000 Hz。受试者由身体健康的 4 位男性以及 1 位女性组成,年龄在 21~25 岁之间,体脂率为 $26\% \pm 3\%$, 男性身高为 170 ± 5 cm, 女性身高为 160 cm。

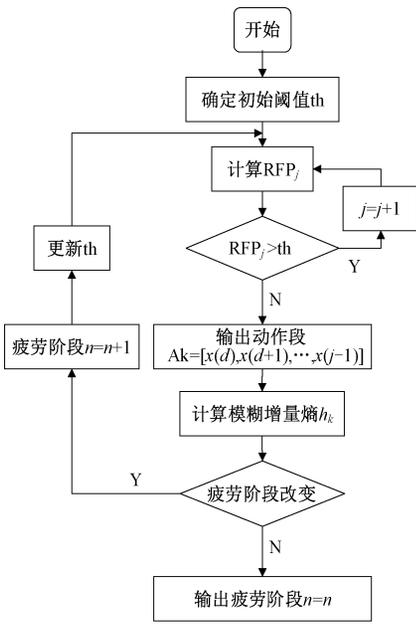


图 2 基于均模积的自适应阈值动作切分流程图

Fig. 2 Adaptive threshold action segmentation method based on RFP

在对不同受试者,不同日期采集的相同肌肉块肌电信号数据进行比较时,先对信号进行归一化处理。

对于 5 名受试者进行了相同的疲劳诱导实验。首先保证受试者处于非疲劳的放松状态,通过进行不间断的抬腿动作,达到以等张收缩使受试者进入疲劳状态的目的。首次抬腿时,以右腿膝盖作为参照点,记录该受试者能够抬起的最大高度并以此规定标准线。此后每次抬腿,受试者膝盖处需达到标准线位置以控制受试者在疲劳过程中动作幅度不变,即始终为等张收缩状态。最后抬腿至受试者力竭,即无法再抬腿到标准高度时停止实验。根据实验结果,平均实验时常通常为一分钟,即通过不间断抬腿的等张收缩方式,受试者由非疲劳状态至力竭状态需要约一分钟的时间。

该实验皆以受试者右腿为肌电信号采集对象,每名受试者采集 10 组数据,一共采集 50 组数据,每组数据采集时均保持一定时间间隔,以确保受试者在每个疲劳诱导实验中的开始时刻是处于非疲劳状态的。

实验中抬腿姿势如图 3 所示。

3.2 有效肌肉块的选取

实验采集下肢 12 块肌肉肌电信号作为研究对象,分别为股薄肌(gracilis, GC)、股直肌(rectus femoris, RF)、阔筋膜张肌(tensor fascia latae, TFL)、股外侧肌(vastuslateralis, VL)、股内侧肌(vastus medialis, VM)、胫骨前肌(anterior tibialis, AT)、半腱肌(semi-tendinosus, ST)、股二头肌(biceps femoris, BF)、半膜肌(semi-membranous, SM)、



图 3 实验动作示意图

Fig. 3 Actions in the experiment

内侧腓肠肌(medial gastrocnemius, MG)、外侧腓肠肌(lateral gastrocnemius, LG)、比目鱼肌(soleus, SOL),肌电信号传感器粘贴在对应肌肉块的皮肤上,如图 4 所示。

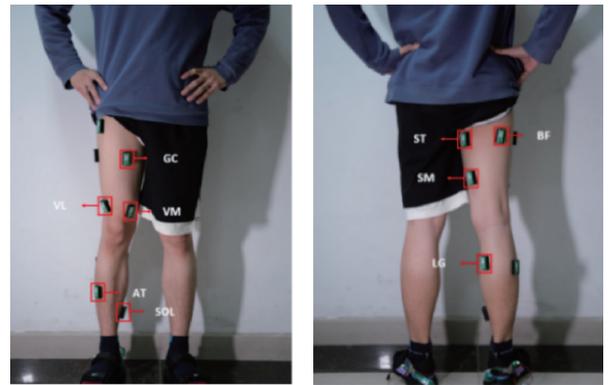


图 4 表面肌电传感器粘贴位置

Fig. 4 The surface EMG signal sensor positions

虽然实验首先采集了 12 块肌肉块的肌电信号,但若将这些肌肉的肌电信号同时进行特征提取,既降低了肌电信号采集的效率,也影响了信号处理的时间,不利于外骨骼的实时控制。并且由于参与动作的位置不同,不同肌肉块对疲劳的反应趋势也不同,无法将所有可采集的肌肉块同时作为研究对象。故针对本文研究肌肉疲劳变化情况的目的,本文以对疲劳的敏感程度作为评价指标进行有效肌肉块的选取,即判断该肌肉块特征值在疲劳加深的过程中是否变化最为明显。在正式实验以及实际工程应用时选择对疲劳最敏感的肌肉块作为采集肌电信号的肌肉块。

本文引入变异性敏感度(sensitivity to variability ratio, SVR)指数对肌肉块的疲劳敏感度进行评估。该参数被定义为:

$$SVR = \frac{R}{E} = \frac{\max(\hat{I}) - \min(\hat{I})}{\sqrt{\frac{1}{N} \sum_{n=1}^N (I_n - \hat{I}_n)^2}} \quad (26)$$

其中, N 表示肌电信号的长度, \hat{I}_n 是真实值 I 的拟合结果, 在本实验中采用的一阶拟合。

该参数原被 Rogers 采用作为评价特征参数表征肌肉疲劳灵敏度与集中性的一个标准^[21], SVR 的值越大, 特征参数的肌肉疲劳程度表征效果就越好。本文中控制特征值不变, 对不同肌肉块的肌电信号 SVR 值比较, 这种情况下, SVR 值最大的肌肉块为对疲劳程度变化最敏感的肌肉块。

首先对 12 块肌肉块进行模糊熵特征提取, 即得到 \hat{I}_n 值, 带入式 (19) 中得到每个肌肉块在疲劳变化过程中的 SVR 值, 对每个肌肉块以 SVR 从大到小进行排名。由于进行了多次实验, 将 50 次实验中疲劳敏感度排名第一的肌肉块进行统计, 整理结果如图 5 所示。

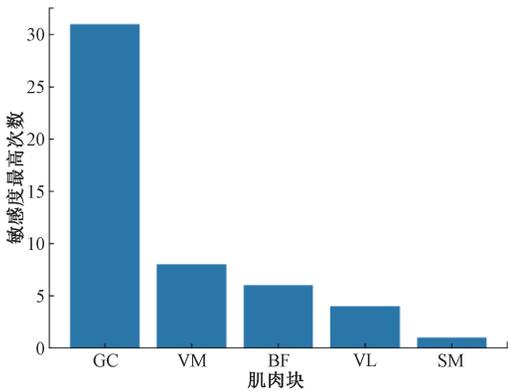


图 5 50 组实验数据中各肌肉灵敏度最高次数的排名
Fig. 5 Ranking of the highest sensitivity times per muscle in 50 groups of experiments

根据对 50 组数据的分析结果, 由于股薄肌在 5 位受试者中对疲劳敏感性排名第一的次数最多, 故选择股薄肌作为有效肌肉块, 并成为后续实验的研究对象。

4 实验

4.1 实验准备

为对疲劳分级的效果进行评判, 本文引入了 Borg 自觉疲劳量表。该疲劳量表将对疲劳程度的主观描述对应为了疲劳分数, 量化了受试者的疲劳感受。实验前要求受试者熟读疲劳量表, 并在实验过程中对自身感受的疲劳情况进行打分。

本文中, 采集股内侧肌肌电信号, 在采集过程中会不可避免地出现噪声, 所以在正式实验前首先要进行肌电信号的预处理工作, 包括滤波及降噪处理。

采集肌电信号过程中存在不可避免的工频干扰, 频率一般为 50 Hz, 又因为肌电信号的频率主要分布在 0~500 Hz 范围内, 故采用巴特沃斯带通滤波器进行

20~450 Hz 的带通滤波, 即可获得满足实验要求的降噪滤波后信号。

此时的肌电信号为由非疲劳到力竭过程中的约 80~120 个连续的抬腿动作的连续信号。由于在疲劳表征过程中首先以单个动作的肌电信号为研究对象进行特征提取, 故需依照肌肉活动段将连续的肌电信号切分为单个动作的信号。

在 50 次实验中, 受试者单次动作的平均时长为 800 ms, 故以 800 ms 为窗长对原始肌电信号进行滑窗, 从而切割出单独的动作信号。

本文中使用的处理软件为 PyCharm2022. 3. 3。

4.2 模糊增量熵疲劳表征效果

按照原始数据采集步骤得到由非疲劳状态至力竭状态时受试者股内侧肌原始肌电信号图, 如图 6 所示。

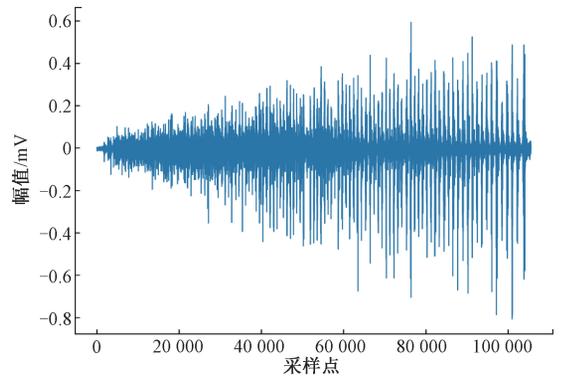


图 6 原始肌电信号图

Fig. 6 Original EMG signal

由图 6 可验证, 随着受试者肌肉疲劳的加深, 完成相同动作时所需要的肌力增大, 原始肌电信号肌电图幅值呈明显的上升趋势。

将原始肌电信号预处理后, 通过基于均模积的自适应软阈值动作切分方法进行动作切分, 输出单个动作信号组成的序列, 动作切分效果如图 7 所示。

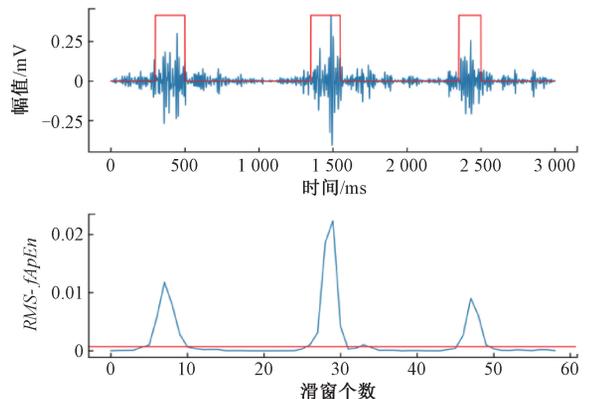


图 7 动作切分效果图

Fig. 7 The effect of action segmentation rendering

本文采用 Hu 等^[17]在 2024 年提出的分数阶模糊色散熵(fractional fuzzy dispersion entropy, FFDispEn),进行肌肉疲劳表征效果对比,其中 $FFDispEn(x, m, c, d, q)$ 所需的 4 个参数 m, c, d, q 分别设置为 2, 4, 1, 0.2, 结果进行归一化处理。

分别提取目前使用较多的时域特征 RMS、频域特征值 MDF、模糊熵、分数阶模糊色散熵及本文提出的模糊增量熵对受试者 1 肌肉疲劳情况进行表征,对比表征效果。

由图 8 所示可得,在肌肉疲劳的过程中,肌电信号模糊熵首先呈上升趋势,代表着肌电信号的复杂度升高。在疲劳前期模糊熵上升趋势明显,后期在 0.2~1.4 区间内振荡,最后呈下降趋势,代表肌肉在疲劳过程中进行了调节。由于图中随着肌肉疲劳程度的加深,模糊熵自身的复杂度也呈现明显增大的趋势,故印证了使用模糊增量熵对模糊熵的复杂程度进行表征可以更直观地表达肌肉疲劳程度。

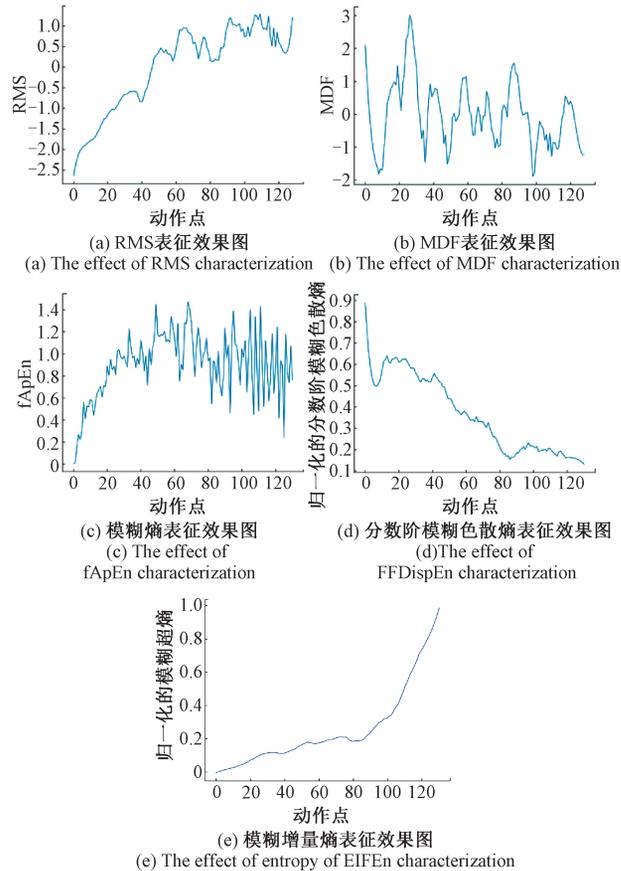


图 8 各特征值对肌肉疲劳表征效果图

Fig. 8 Effect diagram of various characteristic values on muscle fatigue characterization

通过图 8 还可以看出 RMS 与模糊增量熵在疲劳程度加深过程中具有显著的上升趋势,而 MDF 与 FFDispEn

具有下降的趋势,但是 MDF 单调性过低,变化幅度不明显。RMS 值在疲劳开始出现时大幅上升,后进入平台阶段,变化幅度减小。模糊增量熵特征与其他特征值相比较,更具有明显的梯度,更能够反应疲劳的阶段性变化趋势。

4.3 模糊增量熵聚类效果

为了评估模糊增量熵特征值在疲劳阶段分类中的效果,在 50 组实验数据中选择长短相近的数据,采用 DBSCAN 算法对疲劳表征后的结果进行聚类。选择的数据均来自同一受试者。使用 DBSCAN 算法可在未知类别数的情况下进行聚类^[22],能够更客观地体现出受试者在疲劳过程中所经历的疲劳程度变化。

由于 MDF 表征的疲劳的效果不佳,无法用于聚类,故使用时域中常用于表征疲劳的特征值 RMS、模糊熵、分阶模糊色散熵以及本文中所提出的模糊增量熵,对同一受试者的 5 组长短相近的数据进行聚类,聚类前将五组数据进行归一化处理。最后将四种特征值的聚类结果进行比较,结果如图 9 所示。

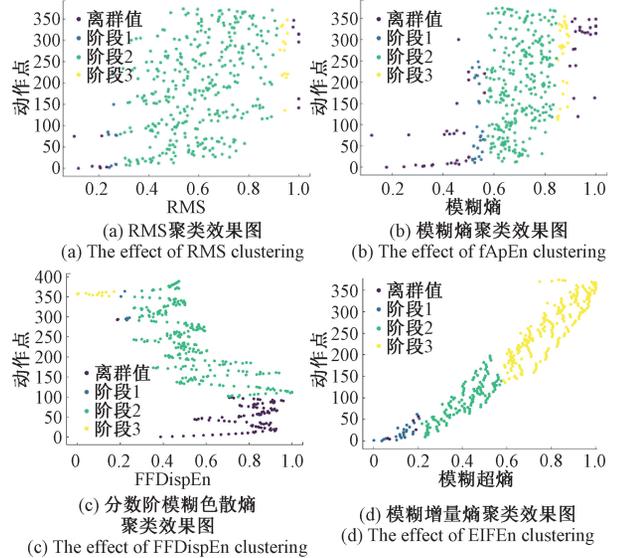


图 9 RMS、模糊熵、分数阶模糊色散熵及模糊增量熵聚类效果对比图

Fig. 9 Comparison of RMS, fApEn, FFDispEn and Entropy of fApEn clustering effects

由图 9 可看出,使用模糊增量熵的聚类效果最好,而 RMS 与模糊熵的聚类效果较差,几乎不能划分出疲劳的阶段,分数阶模糊色散熵具有一定的分类效果,但存在离群值较多,难以进行疲劳程度划分。

采用 DBI 作为指标进一步对聚类效果进行比较,计算采用上述四种特征值进行 DBSCAN 聚类的 DBI 值,越小代表聚类效果越好,计算结果如表 1 所示。

表1 各特征值 DBI 指数表

Table 1 DBI index table for each characteristic value

特征值	DBI 指数
RMS	2.11
fApEn	1.36
FFDispEn	0.66
模糊增量熵	0.39

根据聚类结果可知,在新的特征值模糊增量熵的表征下,DBI 指数最低,聚类效果最好,且该受试者在当前实验环境下由非疲劳到力竭过程可被明显分为3个疲劳阶段。

最后,引入受试者打分情况,对模糊增量熵疲劳表征及分级结果进行检验。为了与主观疲劳等级的横坐标对应,本文将聚类结果图的横纵坐标进行翻转,选取另一位受试者的实验结果,如图10所示。

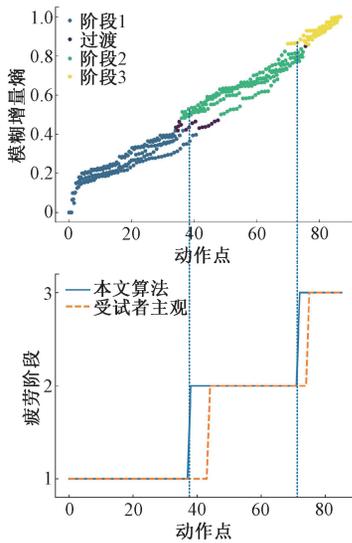


图10 模糊增量熵疲劳等级划分与受试者主观疲劳感受对比
Fig. 10 Comparison of fatigue level classification using Entropy of Incremental Fuzzy Entropy and subjective fatigue perception of subjects

从图10可直观看出,将本文提出的算法所划分的疲劳等级与受试者主观划分的疲劳等级进行对比,结果趋于一致。从图中还可以看出,本文算法所划分的疲劳变化提前于受试者所感受到的疲劳变化,应证了人体实际肌肉状态变化相较于感受到的疲劳程度变化有一定的提前量。

5 结论

本文以下肢单腿12块肌肉为研究对象,对疲劳的敏

感程度以及12块肌肉在疲劳过程中的有效性进行了排名,选择股薄肌作为有效肌肉,减少了肌电信号采集时间,提升模型运算的效率。针对传统阈值检测动作切分法对毛刺敏感且易受疲劳影响的缺点,提出了基于均模积的自适应阈值动作切分方法。并在模糊熵的基础上,提出模糊增量熵作为特征值对肌肉疲劳进行表征,与其他特征值比较分析研究,该特征值能够更好地体现疲劳变化的阶段性,可作为疲劳阶段划分的参照标准,通过实验对提取特征值后的结果进行了聚类处理,得出模糊增量熵表征后聚类效果比RMS、MDF、模糊熵、分数阶模糊色散熵好,可将整个疲劳过程划分为3个阶段。

本文后续的研究工作,将对模糊增量熵特征进行进一步优化,使其呈现更加明显的随疲劳变化趋势提高特征提取速率,以提高外骨骼控制的实时性。

参考文献

- [1] DHINDSA IS, AGARWAL R, RYAIT HS. Performance evaluation of various classifiers for predicting knee angle from electromyography signals [J]. *Expert Systems*, 2019, 36(3): e12381.
- [2] 张松,李江涛,别东洋,等.一种基于单通道sEMG分解与LSTM神经网络相结合的手势识别方法[J]. *仪器仪表学报*, 2021, 42(4): 228-235.
ZHANG S, LI J T, BIE D Y, et al. Gesture recognition by single-channel sEMG decomposition and LSTM network [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(4): 228-235.
- [3] EMILIANO C, STEFANO L, ELOISA L, et al. Peripheral fatigue: New mechanistic insights from recent technologies [J]. *European Journal of Applied Physiology*, 2020, 120(1): 17-39.
- [4] HARRISON M J A. Muscles alive: Their functions revealed by electromyography [J]. *The British Journal of Psychiatry*, 2018, 135(2): 188-188.
- [5] KNOWLTON, CLINTON G, BENNETT, et al. Electromyography of fatigue [J]. *Archives of Physical Medicine & Rehabilitation*, 1952, 32(10): 648.
- [6] LUTTMANN A, SÖKELAND J, LAURIG W. Electromyographical study on surgeons in urology. Influence of the operating technique on muscular strain [J]. *Ergonomics*, 1996, 39(2): 285-297.
- [7] 石欣,朱家庆,秦鹏杰,等.基于改进能量核的下肢表面肌电信号特征提取方法[J]. *仪器仪表学报*, 2020, 41(1): 121-128.

- SHI X, ZHU J J, QIN P J, et al. Feature extraction method of lower limb surface EMG signal based on improved energy nucleus [J]. Chinese Journal of Scientific Instrument, 2020, 41(1):121-128.
- [8] SHANKHWAR, VISHWAJEET, SINGH, et al. Characterization of electromyographical signals from biceps and rectus femoris muscles to evaluate the performance of squats coupled with countermeasure gravitational load modulating bodygear[J]. Microgravity Science and Technology, 2021(4):1-11.
- [9] RAJ, RETHEEP, RAMAKRISHNA, et al. A real time surface electromyography signal driven prosthetic hand model using PID controlled DC motor [J]. Biomedical Engineering Letters, 2016(4):276-286.
- [10] AHMAD, SITI A, CHAPPELL, et al. Moving approximate entropy applied to surface electromyographic signals[J]. Biomedical Signal Processing and Control, 2008, 3(1): 88-93.
- [11] FARINA D, MERLETTI R. Methods for estimating muscle fibre conduction velocity from surface electromyographic signals [J]. Medical & Biological Engineering & Computing, 2004, 42(5):732-732.
- [12] SAFI U, KAMRAN I. Characterization of muscle fatigue in diabetic patients with peripheral neuropathy [M]. International Conf on Electrical and Electronic Engineering (ICEEE), 2022:335-338.
- [13] BONATO, PAOLO, ROY, et al. Time-frequency parameters of the surface myoelectric signal for assessing muscle fatigue during cyclic dynamic contractions [C]. IEEE Transactions on Biomedical Engineering, 2001.
- [14] SUN D, KOUTSOS E, Georgiou P. A neuromorphic based median frequency tracker for muscle fatigue monitoring[C]. IEEE Biomedical Circuits and Systems Conference, Shanghai, China:IEEE, 2016:232-235.
- [15] AL-MULLA M R, SEPULVEDA F. Novel feature modelling the prediction and detection of sEMG muscle fatigue towards an automated wearable system [J]. Sensors, 2010, 10(5):4838-4854.
- [16] WANG S, TANG H, WANG B, et al. Analysis of fatigue in the biceps brachii by using rapid refined composite multiscale sample entropy [J]. Biomedical Signal Processing and Control, 2021, 67: 102510.
- [17] HU B, WANG Y, MU J. A new fractional fuzzy dispersion entropy and its application in muscle fatigue detection [J]. Mathematical Biosciences and Engineering, 2024, 21(1): 144-169.
- [18] SASIDHARAN D, VENUGOPAI G, RAMAKRISHNAN S. Muscle fatigue analysis by visualization of dynamic surface EMG signals using Markov transition field [C]. 2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 2022: 3611-3614.
- [19] 牛惠祺, 张弼, 刘丽刚, 等. 人体肌肉状态疲劳监测及其在外骨骼交互控制中的应用 [J]. 生物医学工程学杂志, 2023, 40(4): 654.
- NIU H Q, ZHANG B, LIU L G, et al, Human muscle fatigue monitoring method and its application for exoskeleton interactive control [j]. Journal of Biomedical Engineering, 2023, 40(4): 654.
- [20] ZADEH L A. Fuzzy sets, information and control [J]. Information & Control, 1965, DOI:10.1016/S0019-9958(65)90241-X.
- [21] ROGERS D R, MACISAAC D T. A comparison of EMG-based muscle fatigue assessments during dynamic contractions [J]. Electromyography and Kinesiology, 2013, 23(5):1004-1011.
- [22] OU Y, TING H, SHEN X. Online structural clustering based on DBSCAN extension with granular descriptors [J]. Information Sciences, 2022: 688-704.

作者简介



石欣(通信作者),2003年和2010年于重庆大学分别获得硕士学位和博士学位。现为重庆大学教授、博士生导师,主要研究方向为智能控制、无线传感网络。

E-mail: meetshixin@gmail.com

Shi Xin (Corresponding author) received his M. Sc. degree and Ph. D. degree both from Chongqing University in 2003 and 2010, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His main research interests include intelligent control and wireless sensor network.



余可祺,2021年于重庆大学获得学士学位。现于重庆大学攻读硕士学位,主要研究方向为传感控制与信号处理。

E-mail: yuminiao@foxmail.com

Yu Keqi received her B. Sc. degree from Chongqing University in 2021. She is currently a M. Sc. candidate at Chongqing University. Her main research

interests include sensing control and signal processing.



秦鹏杰, 2015 年于重庆科技大学获得学士学位。2023 年于重庆大学获得博士学位。现为中国科学院深圳先进技术研究院助理研究员, 主要研究方向为模式识别与智能系统。

E-mail: pj.qin@siat.ac.cn

Qin Pengjie received his B.Sc. degree from Chongqing University of Science and Technology in 2015, received a Ph. D. degree from Chongqing University in 2023. He is currently an assistant researcher at Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences. His main research

interests include pattern recognition and intelligent systems.



张杰毅, 2018 年于西南石油大学获得学士学位。2023 年于重庆大学获得硕士学位。现为四川电力职业技术学院教师, 主要研究方向为感知控制与信号处理。

E-mail: 139199611@qq.com

Zhang Jieyi received his B. Sc. degree from Southwest Petroleum University in 2018, received a M. Sc. degree from Chongqing University in 2023. He is currently a teacher at Sichuan Electric Power Vocational and Technical College. His main research interests include perception control and signal processing.