

# 基于多路 sEMG 时序分析的人体运动模式识别方法

佟丽娜<sup>1,2</sup> 侯增广<sup>1</sup> 彭亮<sup>1</sup> 王卫群<sup>1</sup> 陈翼雄<sup>1</sup> 谭民<sup>1</sup>

**摘要** 针对主动康复训练中人体运动识别问题,提出了一种基于多路表面肌电 (Surface electromyogram, sEMG) 时序特征的人体运动模式识别方法. 设计评估类周期 sEMG 信号波形相似度的方法来对多路 sEMG 信号进行特征选择; 以二维科荷伦自组织竞争网络 (Self-organization mapping net, SOM) 对多路信息进行编码; 最后, 建立描述各运动过程多路 sEMG 时序特征的隐马尔科夫模型 (Hidden Markov model, HMM), 基于最大似然估计法对多模型匹配进行综合判决获取识别结果. 并在对下肢踏车、椭圆、步行运动模式的识别实验中, 相对于经典线性及非线性算法, 识别率由 72.5% 和 88.33% 提高到 91.67%, 验证了本文方法的有效性.

**关键词** 康复训练, 表面肌电, 人体运动意图识别, 自组织神经网络, 隐马尔科夫模型

**引用格式** 佟丽娜, 侯增广, 彭亮, 王卫群, 陈翼雄, 谭民. 基于多路 sEMG 时序分析的人体运动模式识别方法. 自动化学报, 2014, 40(5): 810–821

**DOI** 10.3724/SP.J.1004.2014.00810

## Multi-channel sEMG Time Series Analysis Based Human Motion Recognition Method

TONG Li-Na<sup>1,2</sup> HOU Zeng-Guang<sup>1</sup> PENG Liang<sup>1</sup> WANG Wei-Qun<sup>1</sup> CHEN Yi-Xiong<sup>1</sup> TAN Min<sup>1</sup>

**Abstract** Towards human motion intention recognition during active rehabilitation, a multi-channel surface electromyogram (sEMG) time series based human motion pattern recognition method is proposed. An evaluation method for sEMG signal waveform similarity is designed to select the features, which are coded by a 2D Kohonen self-organization mapping net (SOM) net to get feature series. At last, hidden Markov models (HMM) are built to describe the multi-channel sEMG time series features during each motion process, and then get recognition results based on maximum likelihood estimation method for multi-model synthesis decision. This method showed a good performance on real time and accuracy in the experiment: the treadmill, elliptical and walk training modes are identified by an accuracy of 91.67%, while the classical linear and nonlinear methods showed accuracies of 72.5% and 88.33%.

**Key words** Rehabilitation, surface electromyogram (sEMG), human motion intention recognition, self-organization mapping net (SOM), hidden Markov model (HMM)

**Citation** Tong Li-Na, Hou Zeng-Guang, Peng Liang, Wang Wei-Qun, Chen Yi-Xiong, Tan Min. Multi-channel sEMG time series analysis based human motion recognition method. *Acta Automatica Sinica*, 2014, 40(5): 810–821

中风是急性脑血管疾病的统称, 它不但可以造成永久性中枢神经损伤, 还可以引起多种并发症, 甚至死亡. 由于中风发病率高、致残率高、复发率高、死亡率高、并发症多, 是目前世界范围内成人致残的最主要原因以及致死的第二大原因, 世界医学界已

经把它列为威胁人类健康的三大疾病之一<sup>[1]</sup>. 超过 80% 的中风发病于 65 岁以上的老年人群体<sup>[2]</sup>, 并且有近 75% 的幸存者致残<sup>[3]</sup>. 随着世界人口老龄化进程加剧, 中风造成的神经损伤性残疾已经给家庭和社会带来了沉重的经济和劳动力负担. 医学研究表明, 中枢神经系统的功能性康复依赖于其运动功能的频繁使用, 可以由长期的人体主动运动激励而来, 康复训练对中风后神经系统的恢复以及防止二次中风及其他后遗症具有非常积极的作用<sup>[4–5]</sup>, 尤其是结合人体运动意图的主动康复训练<sup>[6–7]</sup>. 因此, 准确、实时、可靠的人体运动意图识别方法的研究对实现基于患者主动意图的康复训练是十分必要的.

人体运动依赖于骨骼肌伸缩, 其过程中微伏级的生物电压在肌纤维细胞中产生并且可以在皮肤表面测得. 这种从皮肤表面、以非入侵方式测得的神经理肌肉系统活动过程中的微弱电信号被称为表面肌

收稿日期 2013-03-26 录用日期 2013-11-05  
Manuscript received March 26, 2013; accepted November 05, 2013

国家自然科学基金 (61305140, 61225017, 61175076, 61203342), 国家国际科技合作专项 (2011DFG13390) 资助

Supported by National Natural Science Foundation of China (61305140, 61225017, 61175076, 61203342) and the International S & T Cooperation Project of China (2011DFG13390)

本文责任编辑 周杰

Recommended by Associate Editor ZHOU Jie

1. 中国科学院自动化研究所复杂系统与管理国家重点实验室 北京 100190 2. 中国矿业大学 (北京) 机电与信息工程学院 北京 100083

1. State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences, Beijing 100190 2. School of Mechanical Electronic and Information Engineering, China University of Mining and Technology, Beijing 100083

电 (Surface electromyogram, sEMG)<sup>[8-9]</sup> 信号。由于 sEMG 实时客观地反映着神经肌肉系统的运动功能指令信息, 因此, 可以被用来评估骨骼肌的运动状态从而实现对人体主动运动过程的解析<sup>[10]</sup>。在主动康复训练研究中, 训练模式及功能是根据人体主动运动意图来规划的; 因而 sEMG 成为获取人体运动意图最主要的研究对象之一, 例如获取肢体姿势及运动模式<sup>[11-15]</sup>、实时肌肉力/力矩<sup>[16-18]</sup>、关节运动状态<sup>[19-21]</sup> 等。根据识别对象的不同, 康复训练系统的功能规划也不同。第一类, 使用 sEMG 用来识别肢体正在进行和即将进行的运动模式并规划训练系统完成一个特定的运动轨迹<sup>[13]</sup>, 因此, 还可以用于假肢控制<sup>[14]</sup>。例如 Naik 等使用来源于 4 块前臂肌肉的 sEMG 和孪生支持向量机 (Twin support vector machine, Twin SVM) 方法成功对 7 种手指及腕部弯曲动作进行了分类, 得到了平均 84.83% 的敏感性和 88.1% 的特异性<sup>[11]</sup>。Momen 等使用模糊 C-means 聚类法对前臂 sEMG 特征空间进行分割<sup>[12]</sup>, 对 4 类及 5 类手势的平均识别准确率分别达到  $92.7 \pm 3.2\%$  和  $79.9 \pm 16.8\%$ 。Khushaba 等采用贝叶斯方法分析腕部的 2 路 sEMG 信号识别右手哪根手指处于弯曲状态, 达到近 90% 的准确率<sup>[13]</sup>。根据人体不同部位生理环境的差异, 对运动模式识别的效果的也不同, 通常来说, 上臂 sEMG 受脂肪、毛发等生理环境影响相对较小, 识别率通常高于其他部位。人体躯干及下肢 sEMG 受较厚脂肪层、突出的皮肤表层及发毛等影响, 通常干扰较大, 目前少有研究对下肢相似运动模式进行识别。例如 Miljković 等使用欧氏空间临近法对左右两块腰骶椎旁肌进行分析, 识别不同姿势下的坐、立两种过程, 仅获得了 60%~70% 的准确率<sup>[14]</sup>。

sEMG-肌肉力/力矩的数学模型通常较为复杂<sup>[16-18]</sup>, 某些参数随生理条件和环境变化 (例如肌肉萎缩程度、疲劳程度、皮下脂肪含量、皮肤性质等) 并且不易测量, 因此, 较难投入实际应用。通过 sEMG 实时估算肢体运动状态实时规划系统的运动轨迹是实现主动康复训练的另一个途径。例如, Shrirao 等建立了手指屈伸过程中的伸趾浅肌 sEMG 与指关节角度的神经网络模型, 实验获得了较小的均方根误差及 200 ms 的延迟<sup>[20]</sup>。我们的研究队伍分别建立了踏车和蹬踏运动过程下肢 7 块主要肌群 sEMG 和髋、膝、踝关节角度的 20 阶 BP (Back propagation) 神经网络模型, 在角度估算准确度上获得了平均  $5^\circ \sim 6^\circ$  的均方根误差<sup>[21]</sup>。然而, 由于传感器实际测得的 sEMG 受到生理、环境等多方干扰, 信噪比很低; 因此, 此类 sEMG-肢体运动状态实时识别方法通常需要设定具体运动过程模式, 缺乏普适性; 所以目前尚需要配合运动过程模式识别方法共同使用<sup>[19-21]</sup>。综上可知, 对运动过程模式

的识别是实现主动康复训练系统的基础性必要条件, 而目前研究中的识别准确度尚需改善, 对相似运动过程的识别还存在较大的误判。

本文利用多路 sEMG 信息为主动康复训练系统提供一个可靠快速的人体肢体运动意图识别方法, 以下肢运动过程为例, 提出了一种基于多路 sEMG 时序特征分析法的人体下肢运动过程模式识别方法。首先, 通过实验获取了来自 4 位健康个体的单侧下肢 8 块主要肌群在踏车、行走和椭圆运动 (可模拟步态) 三类相似运动过程中的多路 sEMG 数据样本, 使用了一种滑动巴特沃斯滤波法来减小 sEMG 数据处理的时间延迟; 并设计了一种针对 sEMG 与人体运动关系特点的类周期信号相似度评估方法对多路 sEMG 信号进行特征选择以减小计算的时间和空间复杂度。其次, 使用自组织神经网络 (Self-organization mapping net, SOM) 对多路 sEMG 信号进行时序编码, 并建立描述不同运动过程中 sEMG 时序变化特点的隐马尔科夫模型 (Hidden Markov models, HMM)。最后, 通过实验验证了本方法可以实时、有效地区分人体相似运动模式。

本文章节安排如下: 第 1 节描述了实验数据样本获取过程及多路 sEMG 信号处理方法等; 第 2 节描述了多路 sEMG 特征选择及对其进行时序特征编码的方法; 第 3 节描述了使用隐马尔科夫模型建立描述不同运动过程中多路 sEMG 时序变化特征数学模型的方法; 第 4 节描述了实验过程并对结果进行讨论; 第 5 节总结全文。

## 1 多路 sEMG 信息获取与处理

医学研究表明, 相对于其他运动训练方式, 踏车、行走和椭圆运动对人体下肢行走能力的恢复具有较为显著的积极作用<sup>[22-23]</sup>, 是目前康复训练中医师推荐的较为普遍的基本训练模式, 但是, 其运动过程中下肢主要肌群 sEMG 特征较为相似, 难以区分。因此, 本文以踏车、行走和椭圆运动过程为例对人体下肢运动过程模式进行分类, 并且为改善时效性、减少计算复杂度对多路 sEMG 采用时域分析法。

### 1.1 信息获取

为获取人体下肢多路 sEMG 数据样本, 本文使用加拿大 Thought Technology 公司研制的 Flex-Comp Infiniti 表面肌电采集设备 (10 通道, 敏感度:  $< 0.1 \mu\text{V}_{\text{RMS}}$ , 准确度:  $\pm 0.3 \mu\text{V}_{\text{RMS}} \pm 4\%$ , 内置低通滤波器, 原始数据采样频率: 2048 Hz) 来同步采集运动过程中单侧下肢多路 sEMG 信号。

sEMG 传感器贴片电极的配置位置对人体运动模式识别的影响是至关重要的<sup>[24]</sup>。为充分分析人体下肢多路 sEMG 与踏车、行走及椭圆运动过程的影响, 本文将左侧下肢浅层主要肌群列入实验范围, 如表 1 所示。为获取最佳传感数据, 本文实验使用

Ag-AgCl 电极并放置于肌腹中心位置, 如图 1 所示(原图出自文献 [25]), 并使正极与负极电极平行于肌纤维. 4 名健康志愿者参与了实验, 包括 3 名男性, 1 名女性, 年龄  $27 \pm 4$  岁, 身高  $173 \pm 13$  cm, 体重  $57.5 \pm 12.5$  kg, 脂肪含量均为中等. 为增强本文方法的实用性, 实验中并没有去除皮肤表面的毛发、角质, 期望可以获得一个不受人体皮肤表面状况干扰的多路 sEMG—运动模式识别方法. 实验于健身房利用踏车训练机、跑步机及椭圆机进行数据采集, 如图 2 所示; 并选取人体较为舒适的中等速度(踏车  $43 \pm 2$  圈/min, 行走  $43 \pm 2$  步/min, 椭圆运动  $43 \pm 2$  圈/min); 为不失普适性, 选取来自每个实验个体分别在踏车、行走、椭圆运动过程中完整的 10 个连续运动周期数据作为实验样本. 部分数据示例如图 3 所示, 已经经过放大.

表 1 选取的肌群及其功能描述<sup>[26]</sup>

Table 1 Description for selected muscles and their motion functions<sup>[26]</sup>

浅层肌群	主要运动功能
股直肌 (Vastus rectus, VR)	伸小腿、屈大腿
大腿外侧肌 (Vastus lateralis, VL)	伸小腿
腿大腿二头肌 (Biceps muscle of thigh, BM)	屈小腿、伸大腿、使小腿外旋
半腱肌 (Semitendinosus, ST)	伸大腿、屈小腿、使大腿内旋
胫骨前肌 (Tibialis anterior, TA)	使足背屈、内翻和内收
腓骨长肌 (Peroneus longus, PL)	使足外翻及跖屈
小腿内侧腓肠肌 (Gastrocnemius medial, GM)	屈小腿、提起足跟、固定膝关节、防止身体前倾 (由于内侧与外侧腓肠肌的运动功能相似, 因此只选择了内侧腓肠肌作为研究对象)
比目鱼肌 (Soleus muscle, SM)	屈小腿、提起足跟、固定膝关节、防止身体前倾




图 1 sEMG 电极位置

Fig. 1 The location of sEMG sensor electrodes

## 1.2 信号欠采样

人体运动呈现较为明显的低频性, 因此, 在对运动模式进行识别研究前, 应对采集的多路 sEMG 信号进行欠采样. 较为常用的时域欠采样方法有

直接欠采样、积分欠采样法和均方根 (Root mean square, RMS) 欠采样法等<sup>[27]</sup>. 对比前两者, RMS 欠采样法不但可以反映信号幅值在时域上的变化特点, 还取决于肌肉复合性因素和肌肉本身的生理、生化过程之间的内在联系, 可以实时反映肌肉活动状态<sup>[27]</sup>. 因此, 本文选用 RMS 欠采样法.



图 2 椭圆运动过程中多路 sEMG 信息获取

Fig. 2 Multi-channel sEMG signal acquisition during elliptical training exercise

sEMG 信号的 RMS 表示为

$$\text{RMS}_{\text{sEMG}} = \left[ \frac{1}{T} \int_t^{t+T} \text{sEMG}^2(t) dt \right]^{\frac{1}{2}} \quad (1)$$

其中, sEMG(t) 为单路 sEMG 信号, T 为欠采样后的信号周期. 结合人体肢体运动的低频性特点, 本文实验中设定欠采样后信号的频率为 32 Hz, 即:  $T = 64 \times (1/2048) \text{ s} = 31.25 \text{ ms}$ . 然而, 由于采集到的 sEMG 信号通常会受到较强干扰, 欠采样后的信号仍然振动较为剧烈, 如图 4 所示.

## 1.3 信号滤波

传感器采集到的 sEMG 信号是一种低信噪比的微弱信号, 它不只包含 sEMG, 还包含多种噪声: 不仅有毛发、皮肤、脂肪层以及其他生理因素产生的噪声, 还有工频干扰、直流基线噪声等. 尤其是人体下肢相对于上肢来说, 脂肪层、皮肤和毛发等方面的干扰更为强烈. 因此, 欠采样后的 sEMG 信号仍然很不平稳, 需要尽可能平稳地滤波. 然而经过滤波后的信号不可避免地会在时域范围内延迟于原信号. 为提高识别结果的实时性, 本文针对 sEMG 信号的特点使用了一种滑动巴特沃斯滤波法<sup>[28]</sup>. 巴特沃斯 (Butterworth) 滤波器是一种能够使得通频带的频率响应曲线平滑致最大限度的滤波器. n 阶巴特沃斯低通滤波器的传递函数为

$$G^2(\omega) = |H(j\omega)|^2 = \frac{G_0^2}{1 + \left(\frac{\omega}{\omega_C}\right)^{2n}} \quad (2)$$




图 3 2 个连续周期踏板实验中 8 路 sEMG 原始信号

Fig. 3 Two periods of amplified sEMG raw data samples (8 channels)




图 4 欠采样后的 VR 数据曲线示例

Fig. 4 VR data sample curve example after sub-sampling

其中,  $n$  为滤波器的阶数,  $\omega_C$  为截止频率,  $G_0$  为直流增益.

尽管这是一种可以最大限度地平滑原信号的滤波方法, 但是也会像其他滤波器一样在实际应用中对有限离散信号的滤波造成时间延迟. 滤波器的阶数  $n$  越高, 延迟越严重; 反之, 则信号平滑性变差. 为获得更平滑信号的同时减小时间延迟, 本研究组

设计了一种滑动巴特沃斯滤波法. 其核心思想是通过当前时刻前的数据段信息获得当前时刻的滤波后信息元素, 进而减小信号滤波产生的时间延迟. 记当前时刻为  $t$ , 则本方法过程如图 5 表示, 可以通过 4 个步骤实现:

**步骤 1.** 使用滑动时间窗口 (长度为  $L$ , 且  $L \geq n$ ) 获取一段从时刻  $t - L + 1$  到  $t$  的原信

号;

**步骤 2.** 使用巴特沃斯滤波器对其进行滤波, 获得滤波后的信号段;

**步骤 3.** 取该滤波后的信号段尾部最后一个元素作为当前时刻  $t$  的滤波结果元素, 以获得无时间延迟的滤波结果;

**步骤 4.** 滑动时间窗口前移一步.

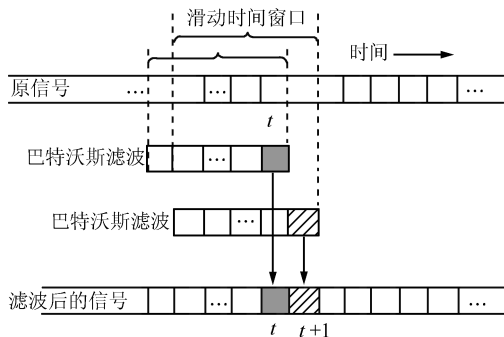


图 5 滑动巴特沃斯滤波法

Fig. 5 Moving Butterworth filtering method

该方法的滤波效果如图 6 所示, 该方法不但可以很好地平滑信号, 还可以有效地减少信号滤波过程产生的延时.

## 2 多路 sEMG 特征提取与时序编码

### 2.1 多路 sEMG 特征选择方法

为提高计算效率及识别准确率, 对滤波后的多路 sEMG 信号进行分析以减少冗余特征是必要的. 在运动过程中采集到的 sEMG 信号除包含反映完成该运动过程所必需的运动功能指令信息之外, 还有诸多噪声、生理因素 (例如偶尔的肌肉抖动)、实验者主观因素影响下产生的和该运动无关的肌电信号等. 但是对于同一实验者而言, 在重复完成同种运动模式下的多次完整运动过程中, 反映完成该运动过程所必需的运动功能指令信息的 sEMG 分量之间应具有良好的重复性和周期性. 信号在多次类周期运

动中的波形相似度越高, 则其与该种运动的关联性越强, 反映完成该种运动所需的运动功能指令信息分量越大, 干扰分量越小; 反之, 则关联性越差, 或者干扰信号的分量越大.

但是由于人体运动的随机性, 使得同种运动模式下各完整运动过程的完成时间之间不具备明确的关联关系, 因此, 类周期的 sEMG 信号波形的周期长度相似性<sup>[29]</sup> 并不能作为多路 sEMG 特征选择的依据. 由于 sEMG 波形幅值反映了肌肉力的大小, 并且其变化趋势反映了肌肉力的变化过程, 是决定运动模式类别的直接因素, 本文提出采用类周期 sEMG 信号波形的幅值相似度<sup>[29]</sup> 与变化趋势相似度相结合的 sEMG 波形相似度评估方法.

首先, 将待分析的单路 sEMG 序列划分为  $n$  个连续的类周期信号序列  $\{S_1, S_2, \dots, S_n\}$ . 在对序列  $S_i, S_j$  进行分析的时候, 为解决类周期信号的周期不一致性问题, 对周期较长的信号序列进行线性压缩<sup>[29]</sup> 以获得与周期较短序列同周期的新序列; 记周期为  $T_c$  (单位: 采样点数量), 经过压缩处理的两序列为  $S'_i = \{s_{i,1}, s_{i,2}, \dots, s_{i,T_c}\}$ ,  $S'_j = \{s_{j,1}, s_{j,2}, \dots, s_{j,T_c}\}$ . 具体评估方法如下:

1) 评估类周期 sEMG 信号序列  $\{S_1, S_2, \dots, S_n\}$  的波形幅值相似度  $A$ .

序列  $S'_i$  和  $S'_j$  的波形幅值平均误差为

$$e_{ij} = \frac{\sum_{k=1}^{T_c} |s_{i,k} - s_{j,k}|}{T_c} \quad (3)$$

由此可得所有子序列  $\{S_i\}$  ( $i = 1, 2, \dots, n$ ) 之间的波形幅值误差矩阵:  $E = \{e_{ij}\}$ ,  $i, j = 1, 2, \dots, n$ . 子序列  $S_i$  相对其他子序列的平均波形幅值误差为

$$\bar{e}_i = \frac{1}{n-1} \sum_{j=1, j \neq i}^n e_{ij} \quad (4)$$

以上为幅值的绝对差异, 为评价波形幅值相似度, 应考虑其与波形整体的相对差异程度. 取各子序列幅




图 6 巴特沃斯滤波法与滑动巴特沃斯滤波法的实验结果对比图

Fig. 6 The experiment results of Butterworth filtered signal and moving Butterworth filtered signal

值最大波动的均值:

$$e_{\max} = \frac{1}{n} \sum_{i=1}^n (\max\{S'_i\} - \min\{S'_i\}) \quad (5)$$

对于整段类周期 sEMG 信号序列  $\{S_1, S_2, \dots, S_n\}$ , 针对 sEMG 易受干扰的特点, 为选取周期性较好的 sEMG 来源, 本文选取平均波形幅值误差最大的子序列作为评估相似性的标准, 即: 波形幅值相似度为

$$A = 1 - \frac{\max\{\bar{e}_i\}}{e_{\max}}, \quad i = 1, 2, \dots, n \quad (6)$$

2) 评估类周期 sEMG 信号序列  $\{S_1, S_2, \dots, S_n\}$  的波形变化趋势相似度  $V$

对于子序列  $S'_i$  和  $S'_j$ , 其线性相关度反映了两序列变化趋势的相似性, 记其线性相关度为

$$\omega_{i,j} = \frac{\sum_{k=1}^{T_c} (s_{i,k} - \bar{s}_i)(s_{j,k} - \bar{s}_j)}{\sqrt{\sum_{k=1}^{T_c} (s_{i,k} - \bar{s}_i)^2 \sum_{k=1}^{T_c} (s_{j,k} - \bar{s}_j)^2}} \quad (7)$$

其中,  $\bar{s}_i = \sum_{k=1}^{T_c} s_{i,k}$  为子序列  $S'_i$  的均值,  $\bar{s}_j = \sum_{k=1}^{T_c} s_{j,k}$  为子序列  $S'_j$  的均值. 由此可得所有子序列  $\{S_i\}$  ( $i = 1, 2, \dots, n$ ) 之间的波形趋势相关度矩阵:  $\Omega = \{\omega_{i,j}\}$ ,  $i, j = 1, 2, \dots, n$ . 子序列  $S_i$  相对其他子序列的平均波形变化趋势相关度为

$$\bar{\omega}_i = \frac{1}{n-1} \sum_{j=1, j \neq i}^n \omega_{i,j} \quad (8)$$

此处定义整段类周期 sEMG 信号序列  $\{S_1, S_2, \dots, S_n\}$  的波形变化趋势相似度:

$$V = \sum_{i=1}^n \bar{\omega}_i \quad (9)$$

3) 评估类周期 sEMG 信号序列  $\{S_1, S_2, \dots, S_n\}$  的总体波形相似度  $W$

结合类周期 sEMG 信号波形的幅值相似度  $A$  与变化趋势相似度  $V$ , 定义总体相似度为

$$W = \rho A + (1 - \rho)V \quad (10)$$

其中,  $\rho \in [0, 1]$ , 表征幅值相似度  $A$  与变化趋势相似度  $V$  在总体相似度  $W$  中所占的权重, 可以根据实际需要适当调整. 在本文实验中, 选取  $\rho = 0.5$ . 总体波形相似度  $W$  越大, 表示该路信号中包含的有用分量越大, 干扰分量越小, 可以依此来对多路 sEMG 信号进行特征选择.

本文对每个实验个体在踏车、行走和椭圆运动中的 8 路下肢 sEMG 信号分别进行了波形相似性分析, 求取 4 个实验个体的各路信号的平均相似度及标准差, 如表 2 所示, 并由此去除冗余特征, 选取用于运动过程识别研究的肌群种类.

踏车、行走及椭圆运动需要整条下肢完成, 因此, 选取 sEMG 信号种类时, 应包括来自大腿部和小腿部的信号. 在选取周期运动中信号波形相似度较高的信号的同时, 还应考虑其针对不同实验个体产生的差异, 计算标准差, 以选取受生理环境干扰较小的信号, 提高识别准确率和普适性: 标准差越大, 表明该路信号在不同实验个体 (生理环境) 间的差异越大. 因此, 本文选取了来自大腿部的 VR、VL 及小腿部的 SM 肌群的 sEMG 信号作为进一步提取特征的对象.

值得注意的是: 以上 sEMG 分析对象的选取方法是基于本文的信号处理方法的; 当信号处理方法不同时, 计算所得的相似度的值也会有所不同, 因此, 在选择信号时, 应将相似度进行排序, 按照排序结果进行选取, 而不能使用相似度的阈值作为选择的标准.

表 2 三种运动过程中多路 sEMG 波形相似性分析

Table 2 Waveform similarity analysis of multi-channel sEMG signals during 3 kinds of motion process

波形相似度		大腿部				小腿部			
		VR	VL	BM	ST	TA	PL	GM	SM
踏车	平均值	0.7987	0.7074	0.7110	0.3773	0.7367	0.5703	0.7813	0.8063
	标准差	0.0757	0.0687	0.0734	0.6331	0.0710	0.1532	0.0518	0.0862
椭圆	平均值	0.7558	0.7968	0.7168	0.6729	0.7294	0.7088	0.7158	0.8076
	标准差	0.0513	0.0343	0.1182	0.1587	0.1092	0.1549	0.1043	0.0413
行走	平均值	0.8333	0.8112	0.6722	0.4819	0.7690	0.8583	0.8224	0.8172
	标准差	0.0571	0.0820	0.2497	0.4416	0.1306	0.0262	0.0583	0.0847

## 2.2 基于 SOM 的多路 sEMG 时序特征编码方法

为识别经信号处理后的 3 路 sEMG 信号序列 VR、VL、SM 的变化特点与运动过程的内在联系, 需要对其进行信息融合及编码. 由于人体运动具有过程性的特点, 单路 sEMG 时序变化特征反映了相应的肌肉力在运动过程中的时序变化, 多路 sEMG 时序则可以反映各肌群协调工作特点; 因此, 本文采用时序编码的方式将 3 路 sEMG 时序信息融合为一维时序码字, 用于表述人体运动过程中多路 sEMG 信息的时序特征.

通常实际采集到的 sEMG 幅值精度较高、值域范围较大, 因此, 对各时间点的 sEMG 幅值进行直接编码是不现实的, 需要对幅值的分布状况进行划分. 自组织神经网络 (Self-organization mapping net, SOM) 是基于无监督学习方法的神经网络的一种重要类型, 它可以通过其输入样本学会检测其规律性和输入样本相互之间的关系, 从而自适应地调整网络, 使其以后的响应与输入样本相适应<sup>[30-31]</sup>. 二维科荷伦 (Kohonen) 网络是 SOM 的一种形式, 它可以模拟细胞聚类的功能柱, 使输入样本通过竞争学习后, 功能相同的输入靠得较近, 不同的分得比较开, 由此将一些无规则的输入自动排开, 最后, 使权矢量的分布与输入样本的概率密度分布相似. 因此, 二维科荷伦网络能够表现出输入矢量在二维平面上的分布特性, 使 3 路 sEMG 信号投影到二维数据空间的某个区域上, 完成数据融合, 并通过二维输出层节点的编码信息完成对三维特征的编码. 可见, 这种方法不需要人为地对各路 sEMG 的幅值范围进行划分便可反映其分布情况, 在多路 sEMG 编码问题上简便而实用. 根据研究目标, 本文采用图 7 所示的二维科荷伦网络拓扑结构, 共分为两层:




图 7 二维科荷伦 SOM 网络结构

Fig. 7 Structure of 2D Kohonen SOM net

1) 输入层: 有  $r$  个输入矢量, 即  $r$  个节点; 此处输入向量为经过信号处理后的 VR、VL、SM 信息, 因此  $r=3$ .

2) 输出层: 也称为竞争层, 为公平反映  $r=3$  路 sEMG 输入的影响并降低识别算法的复杂度, 输出层采用  $3 \times 3$  二维方阵型网络组成, 可输出 9 种编码码字, 即输出节点数量为  $s=9$ , 记编码值集合

$V = \{v_1, v_2, \dots, v_s\}$ ; 所有的输入节点到输出节点之间均有权值链接; 按照竞争网络的特点其激活函数为二值型函数, 为更加接近实际神经细胞的特点, 兴奋区域采用获胜节点周围的六角形区域, 因此, 输出节点之间为六角形连接方式.

由此, 以 SOM 对 3 路滤波后的 sEMG 信号进行编码, 结合滑动巴特沃斯滤波法, 采用与滤波同频率的滑动时间窗口的方法即可实时生成 sEMG 时序特征序列.

## 3 基于隐马尔科夫模型的运动意图识别方法

人体运动是各种复杂随机过程的有机组合, 各运动过程具有过程性, 可由时序信息描述其特征, 进而达到对不同运动过程识别的目的. 隐马尔科夫模型 (Hidden Markov model, HMM) 具有很好的统计特性, 是一种根据随机过程的特点建立描述其时序信息特征的概率模型<sup>[32-33]</sup>, 目前已成功地应用于手势、语音、手写识别等领域<sup>[33]</sup>. 本文使用一阶 HMM 建立描述人体下肢运动过程 (踏车、行走及椭圆运动) 中多路 sEMG 信息的时序特征的数学模型, 并以此来对运动模式进行分类.

一阶 HMM 是一个双重随机过程, 此处, 它由一个描述下肢运动过程中各运动状态转移关系的、不能被 sEMG 传感器检测到的一阶马尔科夫链, 和一个用于描述运动状态与多路 sEMG 信息之间关系的一般随机过程组成, 即: 通过观测到的 sEMG 时序信息间接地分析隐含运动状态的转移. 结合本文研究, 定义人体下肢踏车、行走及椭圆运动过程中通过多路 sEMG 信息采集、处理后得到的编码码字时间序列为长  $L$  的观测值序列  $O = \{O_1, O_2, \dots, O_t, \dots, O_L\}$ , 其对应的隐含运动状态序列为  $Q = \{Q_1, Q_2, \dots, Q_t, \dots, Q_L\}$ , 其中  $O_t$  为  $t$  时刻的编码值,  $Q_t$  为  $t$  时刻的运动状态. 描述踏车、行走及椭圆运动的一阶 HMM 均可由一个 5 元组  $\lambda = \{M, N, \pi, A, B\}$  来表述, 如表 3 所示.

记描述踏车、行走及椭圆运动过程中多路 sEMG 信息时序特征的 HMM 分别为  $\lambda_T$ 、 $\lambda_W$ 、 $\lambda_O$ . 以踏车运动为例, 以给定的该运动过程中多路 sEMG 时序特征信息作为 HMM 的观测值序列  $O$ , 通过调整  $\lambda_T$  的参数使  $P(O|\lambda_T)$  局部极大可训练得描述踏车运动过程多路 sEMG 时序特征的 HMM  $\lambda_T$ . 同理可得  $\lambda_W$  和  $\lambda_O$ . 实际应用中, 对于给定的模型  $\lambda_T$ 、 $\lambda_W$  及  $\lambda_O$ , 计算各自产生某个观测值序列  $O$  (待识别运动过程中多路 sEMG 时序特征信息) 的输出概率  $P(O|\lambda_T)$ 、 $P(O|\lambda_W)$  及  $P(O|\lambda_O)$ , 便可估计  $O$  与模型  $\lambda_T$ 、 $\lambda_W$ 、 $\lambda_O$  的匹配程度, 基于最大似然估计法做出识别决策.

本文使用 Baum-Welch (B-W) 算法<sup>[32]</sup> 实现模型的训练和观测值输出概率的计算以提高时效性,

降低计算复杂度; B-W 算法是一种广义期望最大化算法, 其核心思想是通过递归过程更新参数权重 ( $\pi, A, B$ ), 进而得到可以更符合训练样本序列的模型参数. 为计算序列  $O$  在模型  $\lambda$  上的输出概率  $P(O|\lambda)$  需要定义两个变量:

1) 前向变量  $\alpha_t(i)$ : 给定参数  $\lambda$ ,  $t$  时刻人体运动处于状态  $u_i$ , 此时已观测到部分经信号处理及编码后的多路 sEMG 信息特征序列  $\{O_1, O_2, \dots, O_t\}$  的概率,  $\alpha_t(i) = P(O_1, O_2, \dots, O_t, Q_t = u_i|\lambda)$ ;

2) 后向变量  $\beta_t(i)$ : 给定参数  $\lambda$ ,  $t$  时刻人体运动处于状态  $u_i$ ,  $t$  时刻之后观测到的经信号处理及编码后的多路 sEMG 信息特征序列  $\{O_{t+1}, O_{t+2}, \dots, O_L\}$  的概率,  $\beta_t(i) = P(O_{t+1}, O_{t+2}, \dots, O_L, Q_t = u_i|\lambda)$ .

即: 由递归方式可计算得:

$$P(O|\lambda) = \sum_{i=1}^M \alpha_i(i)\beta_i(i) = \sum_{i=1}^M \sum_{j=1}^M \alpha_i(i)a_{ij}b_{j,t+1}\beta_{t+1}(i) = \sum_{i=1}^M \alpha_L(i) \quad (11)$$

使用 B-W 算法训练模型  $\lambda$  时, 还需再定义两个变量:

1)  $\gamma_t(i, j)$ : 给定踏板、行走或椭圆运动过程中多路 sEMG 时序特征训练样本序列  $O$  和模型  $\lambda$ , 人体在  $t$  时刻处于状态  $u_i$ , 并于  $t+1$  时刻转移 (运动) 到状态  $u_j$  的概率,

$$\gamma_t(i, j) = P(Q_t = u_i, Q_{t+1} = u_j|O, \lambda) = \frac{\alpha_t(i)a_{ij}b_{j,t+1}\beta_{t+1}(i)}{P(O|\lambda)} \quad (12)$$

2)  $\delta_t(i)$ : 给定踏板、行走或椭圆运动过程中多路 sEMG 时序特征训练样本序列  $O$  和模型  $\lambda$ , 人体在  $t$  时刻处于状态  $u_i$  的概率,

$$\delta_t(i) = P(Q_t = u_i|O, \lambda) = \frac{\alpha_t(i)\beta_t(i)}{P(O|\lambda)} \quad (13)$$

由以上定义可知,  $\sum_{i=1}^{L-1} \delta_t(i)$  为状态从  $u_i$  转移出去的次数的期望,  $\sum_{t=1}^{L-1} \gamma_t(i, j)$  为状态从  $u_i$  运动到  $u_j$  的次数的期望, 结合可得模型参数重估公式:

$$\tilde{\pi}_i = \delta_1(i) \quad (14)$$

$$\tilde{a}_{ij} = \frac{\sum_{t=1}^{L-1} \gamma_t(i, j)}{\sum_{t=1}^{L-1} \delta_t(i)} \quad (15)$$

$$\tilde{b}_{jk} = \frac{\sum_{t=1, O_k=v_k}^L \delta_t(j)}{\sum_{t=1}^L \delta_t(j)} \quad (16)$$

为尽快获得识别结果来改善控制效果, 本文针对各运动过程中的前半周期建立模型, 即在踏板、行走及椭圆运动过程进行到其周期的一半时做出识别结果. 由此, 尽管踏板、行走及椭圆康复训练过程均为周期运动过程, 所建立的 HMM 的马尔科夫链却不再具备周期性, 且半周期过程的运动是不可逆转的, 即: 某运动状态的转移只能停留在自身或者向下个状态转移. 因此, 本文提出使用图 8 所示的马尔科夫链形式来描述踏板、行走和椭圆运动过程中前半周期的过程段.




图 8 运动过程马尔科夫状态链转移图

Fig. 8 Markov chain states transfer diagram during motion process

为降低计算复杂度, 结合人体左侧下肢在踏板、行走及椭圆运动过程中的运动特点, 选取大腿及小腿的抬起、落下状态的组合作为 3 种待识别运动隐状态的集合  $U$ , 即: 隐状态集合  $U = \{u_1, u_2, u_3, u_4\}$ , 其中  $u_1 = \{\text{抬大腿并抬小腿}\}$ ,

表 3 一阶 HMM 参数描述

Table 3 Parameters description for first-order HMM

参数	描述
隐含运动状态数 $M$	某运动模式中的隐含运动状态有限集 $U = \{u_1, u_2, \dots, u_M\}$
观测值种类总数 $N$	观测值种类, 即多路 sEMG 编码码字有限集 $V = \{v_1, v_2, \dots, v_N\}$
初始概率分布 $\pi$	$\pi = \{\pi_i\}$ , $\pi_i = P(Q_1 = u_i)$ , $\sum_{i=1}^M \pi_i = 1$ , 其中, $i = 1, 2, \dots, M$
一阶马尔科夫模型链转移概率矩阵 $A$ , 描述运动状态间的转移关系	$A = \{a_{ij}\}$ , $a_{ij} = P(Q_{t+1} = u_j Q_t = u_i)$ , $\sum_{j=1}^M a_{ij} = 1$ , 其中, $j = 1, 2, \dots, M$
输出概率矩阵 $B$ , 描述运动状态与多路 sEMG 特征之间的关系	$B = \{b_{jk}\}$ , $b_{jk} = P(O_t = v_k Q_t = u_j)$ , $\sum_{k=1}^N b_{jk} = 1$ , 其中, $k = 1, 2, \dots, N$

$u_2 = \{\text{抬大腿并落小腿}\}$ ,  $u_3 = \{\text{落大腿并抬小腿}\}$ ,  $u_4 = \{\text{落大腿并落小腿}\}$ .

结合状态转移图, 模型  $\lambda_T$ 、 $\lambda_W$  和  $\lambda_O$  参数的训练初值设置如下:

1) 隐状态数  $M$ : 由前方叙述知, 3 模型采取同样的隐状态数  $M = 4$ .

2) 观测值种类总数  $N$ : 因对多路 sEMG 信息采用统一特征提取及 SOM 编码方法, 3 模型均采取观测值种类总数  $N = 9$ .

3) 初始概率分布  $\pi$ : 不失一般性, 设置各隐状态作为初始状态的概率相同, 即:  $\pi_i = 1/M$ ,  $\forall i = 1, 2, \dots, M$ .

4) 状态转移矩阵  $A$ : 由马尔科夫链的形状决定,  $a_{ij} = 1/(M - i + 1)$ ,  $\forall i \leq j$ ;  $a_{ij} = 0$ ,  $\forall i > j$ ;  $i, j = 1, 2, \dots, M$ .

5) 输出概率矩阵  $B$ : 不失一般性, 选取均匀分布, 即:  $b_{jk} = 1/N$ ,  $\forall j = 1, 2, \dots, M$ ,  $k = 1, 2, \dots, N$ .

图 9 为模型训练过程与实际运动模式识别过程示意图. 通过实验采集踏板、行走及椭圆运动过程中的多路 sEMG 信息, 通过滑动时间窗口进行信号处理, 获取时序信息, 训练描述各自时序特征的 HMM  $\lambda_T$ 、 $\lambda_W$  及  $\lambda_O$ ; 继而计算待识别运动过程中多路 sEMG 时序特征信息  $O$  分别在模型  $\lambda_T$ 、 $\lambda_W$  及  $\lambda_O$  上的输出概率  $P(O|\lambda_T)$ 、 $P(O|\lambda_W)$  及  $P(O|\lambda_O)$ ; 由于  $P(O|\lambda_T)$ 、 $P(O|\lambda_W)$ 、 $P(O|\lambda_O)$  分别表征待识别运动与模型  $\lambda_T$ 、 $\lambda_W$ 、 $\lambda_O$  的匹配程度, 因此, 可以基于最大似然估计法做出多模型识别判决: 待识别过

程属于输出概率较大的运动模式.

### 4 实验与讨论

本文实验如图 9 所示共分为两部分: 表征踏板、行走及椭圆运动过程中, 多路 sEMG 时序特征的 HMM 建立; 以及待识别运动过程的识别, 即: 模型有效性的验证. 信号处理过程使用滑动时间窗口 (其周期同欠采样的周期) 的方法, 对采集到的来自 VR、VL、SM 肌群的 3 路 sEMG 分别进行欠采样及滑动巴特沃斯滤波, 得到经过信号处理的 VR、VL、SM 3 路 sEMG 时序信息, 最后, 通过建立描述各运动过程的 HMM 得到识别结果, 如图 10 所示.

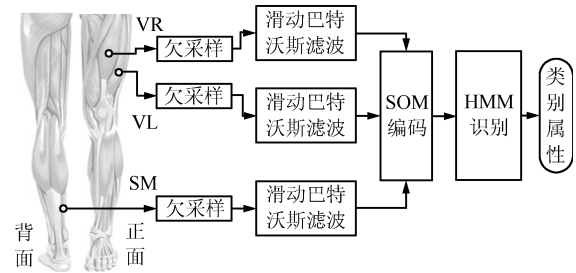


图 10 信号处理及运动识别过程

Fig. 10 Procedure of signal processing and motion recognition

为排除单一数据样本对实验结果的影响, 必须使来自 4 个实验个体、3 种运动模式的共 120 个运动周期的样本均有成为测试样本的机会. 因此, 本文

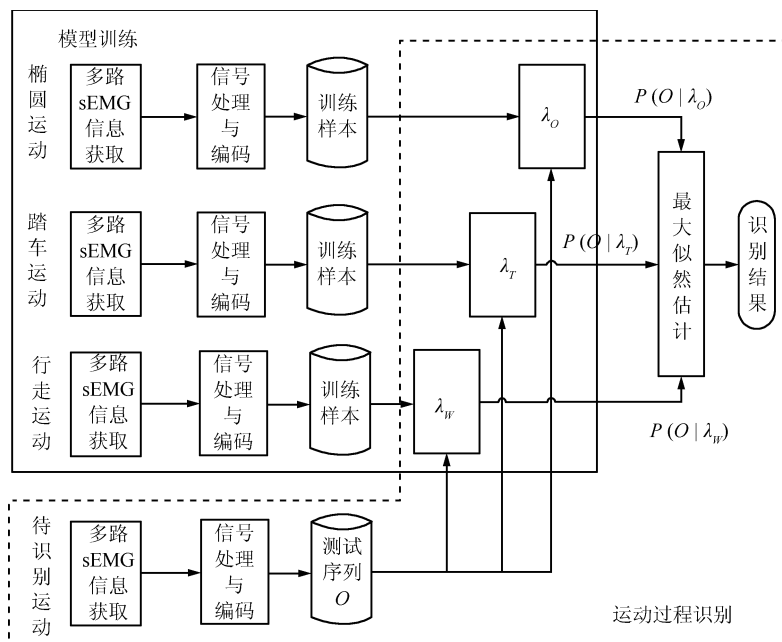


图 9 模型训练与运动过程识别

Fig. 9 Model training and motion process recognition

表 4 第  $r$  次实验的数据样本集划分  
Table 4 Division of data sample sets for the  $r$ -th test

样本集	样本 (数量单位: 运动周期)			
	踏车运动	椭圆运动	行走运动	总数
测试样本集 $\Phi_E$	每个体的第 $r$ 个	每个体的第 $r$ 个	每个体的第 $r$ 个	12
$\lambda_T$ 的训练样本集 $\Phi_T$	其余 9 个	0	0	36
$\lambda_O$ 的训练样本集 $\Phi_O$	0	其余 9 个	0	36
$\lambda_W$ 的训练样本集 $\Phi_W$	0	0	其余 9 个	36

对实验样本进行交叉验证: 每次实验使用全部实验个体在各类运动模式中的 1 个周期样本做测试样本, 其余作为训练样本, 直到所有的样本都做过测试样本. 由于实验采集了每人每种运动模式中 10 个周期的数据样本, 所以共有  $R=10$  组实验, 第  $r$  ( $r=1, 2, \dots, R$ ) 组实验的数据样本划分方法如表 4 所示.

在确定数据样本集的划分方法后, 按照标号  $r$  依次进行  $R$  组实验, 每组实验按照图 9 分为两部分: 模型训练及运动过程识别. 对于第  $r$  组实验, 首先, 进行模型训练过程: 将样本集  $\Phi_T$ 、 $\Phi_O$  及  $\Phi_W$  中的全部样本作为二维科荷伦 SOM 的训练样本, 再将 SOM 输出的一维时序码字 (多路 sEMG 时序特征序列) 按照样本集划分方法分别作为 HMM 模型 ( $\lambda_T$ 、 $\lambda_W$ 、 $\lambda_O$ ) 的训练样本, 分别得到描述踏车、行走及椭圆运动过程中多路 sEMG 时序特征的 HMM; 接下来以测试样本集  $\Phi_E$  对运动过程识别部分进行实验. 综合计算  $R$  组实验对踏车、行走及椭圆三类相似下肢康复运动模式的平均识别准确率为  $91.67 \pm 4.73\%$ .

以上  $R=10$  组实验的样本数量、模型训练及实验过程都是相同的, 不同的仅仅是样本划分方法使每组的测试样本之间均没有交集, 因此, 对比识别结果不尽相同, 这主要是因为 sEMG 易受生理环境的个体及时间差异的影响造成的. 1) 即使是同种运动模式, 由于不同个体的生理环境不同 (例如毛发、皮肤、脂肪层、肌纤维量等), 运动习惯不同, 使得采集到的 sEMG 样本出现差异; 2) 即使是同一个实验个体在同种运动模式之下, 由于生理影响 (例如肌肉疲劳程度、主观影响等) 和人体运动的随机性也使不同时间测得的 sEMG 各不相同. 所以, 本文方法的实际应用必须建立在大样本训练的基础上, 使模型能够反映更多的运动特征细节.

常用方法通常提取运动姿势或过程中多路 sEMG 的平均幅值、过零点、频率变化、波长特征等组成特征向量<sup>[28]</sup>, 继而进行分类. 本文在本实验的数据样本集上, 同样采用 VR、VL、SM 三路 sEMG, 使用以上常用特征向量提取方法, 并使用典型的线性分类器 Bayes 估计法和非线性分类器 BP 神经网络法分别进行了实验, 获得的实验准确率分

别为  $72.5 \pm 4.12\%$  和  $88.33 \pm 9.78\%$ , 可见本文方法更适合此类问题的识别.

本文使用滑动时间窗口法获取 sEMG 时序特征, 结合信号处理过程可知滑动时间窗口的周期为  $T=64 \times (1/2048 \text{ 秒})=31.25 \text{ ms}$ , 综合计算过程可得识别周期约为  $32 \sim 40 \text{ ms}$  (台式电脑或工控机).

## 5 结论

通过人体多路 sEMG 信息识别肢体运动模式是康复医疗、假肢控制、人机交互等领域获取人体运动意图信息的重要方法之一. 识别研究中需要综合考虑不同运动模式所关联的来源于不同分布区域的不同生理信息, 这也是生物信息分析和解释研究在实际应用中必须面对的问题. sEMG 易受生理环境等多方面的影响, 通过传感装置采集到的 sEMG 信号含多种干扰, 是一种低信噪比的微弱信号. 因此, 如何实时地提取有用信号, 分析多路 sEMG 信息不同运动模式之间的关系, 减小生理环境的影响, 进而提高相似运动过程识别的准确率和时效性是目前研究的一个难点.

本文从人体单侧下肢 8 块主要浅层肌群多路 sEMG 的分析及踏车、行走和椭圆运动三种相似的康复训练运动的识别研究出发, 首先, 使用一种可以显著减小时间延迟并有效平滑信号的滑动巴特沃斯滤波法对多路 sEMG 进行滤波; 其次, 分析重复运动过程中同种 sEMG 信号之间的关联关系, 并提出设计了一种评价类周期 sEMG 信号波形相似度的方法, 以此为据分析来自不同分布区域的多路 sEMG 信息对不同运动模式的影响, 确定来自股直肌 (VR)、股外侧肌 (VL), 比目鱼肌 (SM) 的 sEMG 作为各运动模式识别的特征; 接下来使用二维科荷伦 SOM 对经过信号处理的多路 sEMG 进行时序特征编码, 并分别建立了描述踏车、行走及椭圆运动过程多路 sEMG 时序特征信息的 HMM 模型, 基于最大似然估计方法对待识别运动模式与多模型的匹配进行综合判决, 确定识别结果. 为验证本文方法的有效性, 4 名健康实验者志愿参与了下肢踏车、行走及椭圆运动模式的识别; 并取得了平均  $91.67\%$  的识别准确率, 识别周期约为  $32 \sim 40 \text{ ms}$ , 为基于 sEMG

的人体运动模式识别提供了一种可行的新方法。

本文使用健康人的 sEMG 进行分析研究, 而中风患者由于运动神经肌肉系统受损使得其采集到的 sEMG 中的有用信号更加微弱。因此, 实际应用中应根据身体状况对患者进行分组, 采集大样本分别训练不同的模型参数。

## 致谢

感谢中国科学院自动化研究所复杂系统管理与控制国家重点实验室机器人研究小组的同学们参与本文实验。

## References

- Chen R L, Balami J S, Esiri M M, Chen L K, Buchan A M. Ischemic stroke in the elderly: an overview of evidence. *Nature Reviews Neurology*, 2010, **6**(5): 256–265
- Donnan G A, Fisher M, Macleod M, Davis S M. Stroke. *The Lancet*, 2008, **371**(9624): 1612–1623
- Coffey E C, Cummings J L, Starkstein S, Robinson R. *The American Psychiatric Press Textbook of Geriatric Neuropsychiatry* (Second Edition). Washington D. C.: American Psychiatric Press, 2000.
- Liepert J, Bauder H, Wolfgang H R, Miltner W H, Taub E, Weiller C. Treatment-induced cortical reorganization after stroke in humans. *Stroke*, 2000, **31**: 1210–1216
- Wang Xing-Yu, Jin Jing, Zhang Yu, Wang Bei. Brain control: human-computer integration control based on brain-computer interface. *Acta Automatica Sinica*, 2013, **39**(3): 208–221  
(王行愚, 金晶, 张宇, 王蓓. 脑控: 基于脑-机接口的人机融合控制. *自动化学报*, 2013, **39**(3): 208–221)
- Lotze M, Braun C, Birbaumer N, Anders S, Cohen L G. Motor learning elicited by voluntary drive. *Brain*, 2003, **126**(4): 866–872
- Rosati G, Gallina P, Masiero S. Design, implementation and clinical tests of a wire-based robot for neurorehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, **15**(4): 560–569
- Weiss L, Silver J K, Weiss J. *EASY EMG: A Guide to Performing Nerve Conduction Studies and Electromyography*. Singapore: Elsevier Pte Ltd., 2007
- Kamen G, Gabriel D. *Essentials of Electromyography*. USA: Human Kinetics Publishers, 2009
- Frigo C, Crenna P. Multichannel SEMG in clinical gait analysis: a review and state-of-the-art. *Clinical Biomechanics*, 2009, **24**(3): 236–245
- Naik G R, Kumar D K, Jayadeva. Twin SVM for gesture classification using the surface electromyogram. *IEEE Transactions on Information Technology in Biomedicine*, 2010, **14**(2): 301–308
- Momen K, Krishnan S, Chau T. Electromyographic signals corresponding to user-selected intentional movements for multifunction prosthesis control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, **15**(4): 535–542
- Khushaba R N, Kodagoda S, Takruri M, Dissanayake G. Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications*, 2012, **39**(12): 10731–10738
- Miljković N, Bijeli G, Garcia G A, Popovi M B. Independent component analysis of EMG for posture detection: sensitivity to variation of posture properties. In: *Proceedings of the 19th International Conference on Telecommunications Forum Telfor*. Belgrade: IEEE, 2011. 47–50
- Li Yang, Tian Yan-Tao, Chen Wan-Zhong. Modeling and classifying of sEMG based on FFT blind identification. *Acta Automatica Sinica*, 2012, **38**(1): 128–134  
(李阳, 田彦涛, 陈万忠. 基于 FFT 盲辨识的肌电信号建模及模式识别. *自动化学报*, 2012, **38**(1): 128–134)
- Clancy E A, Liu L K, Liu P, Moyer D V Z. Identification of constant-posture EMG-torque relationship about the elbow using nonlinear dynamic models. *IEEE Transactions on Biomedical Engineering*, 2012, **59**(1): 205–212
- Choi C, Kwon S, Park W, Lee H, Kim J. Real-time pinch force estimation by surface electromyography using an artificial neural network. *Medical Engineering & Physics*, 2010, **32**: 429–436
- Staudenmann D, Roeleveld K, Stegeman D F, Dieën van J H. Methodological aspects of SEMG recordings for force estimation — a tutorial and review. *Journal of Electromyography and Kinesiology*, 2010, **20**(3): 375–387
- Earp J E, Newton R U, Cormie P, Blazevich A J. Knee angle-specific EMG normalization: the use of polynomial based EMG-angle relationships. *Journal of Electromyography and Kinesiology*, 2013, **23**(1): 238–244
- Shrirao N A, Reddy N P, Kosuri D R. Neural network committees for finger joint angle estimation from surface EMG signals. *Biomedical Eng Online*, 2009, **8**(2): 1–14
- Zhang F, Li P F, Hou Z G, Lu Z, Chen Y X, Li Q L, Tan M. sEMG-based continuous estimation of joint angles of human legs by using BP neural network. *Neurocomputing*, 2012, **78**(1): 139–148
- Werner C, Bardeleben A, Mauritz K H, Kirker S, Hesse S. Treadmill training with partial body weight support and physiotherapy in stroke patients: a preliminary comparison. *European Journal of Neurology*, 2002, **9**(6): 639–644
- Eich H J, Mach H, Werner C, Hesse S. Aerobic treadmill plus bobath walking training improves walking in subacute stroke: a randomized controlled trial. *Clinical Rehabilitation*, 2004, **18**(6): 640–651
- Ryait H S, Arora A S, Agarwal R. Interpretations of Wrist/Grip operations from sEMG signals at different locations on arm. *IEEE Transactions on Biomedical Circuits and Systems*, 2010, **4**(2): 101–111
- Peter Konrad. The ABC of EMG, A Practical Introduction to Kinesiological Electromyography [Online], available: <http://www.noraxon.com>, January 1, 2013
- Gao Shi-Lian. *Lower Limb Atlas of Practical Anatomy (3rd Edition)*. Shanghai: Shanghai Century Publishing Co., Ltd., 2012  
(高士廉. 实用解剖图谱·下肢分册 (第3版). 上海: 上海世纪出版股份有限公司, 2012)
- Wang Jian. Some advances in the research of sEMG signal analysis and its application. *Sports Science*, 2000, **20**(4): 56–60  
(王健. sEMG 信号分析及其应用研究进展. *体育科学*, 2000, **20**(4): 56–60)
- Lv Jie, Cao Jin-Feng, Fang Lei, Fang Min, Yan Jun-Tao, Xu Shi-Xiong. A new approach to evaluate the similarity of approximate periodic signal and its application in uniform analysis of gun-rolling manipulation. *Acta Shanghai University of Traditional Chinese Medicine*, 2010, **24**(6): 54–57  
(吕杰, 曹金凤, 方磊, 房敏, 严隽陶, 许世雄. 一种评价近似周期信号相似度的新方法及其对中医法均匀性的分析. *上海中医药大学学报*, 2010, **24**(6): 54–57)

- 29 Zeng Feng, Zhong Zhi-Chu, Yang Tong, Yao Shan. Scattered point cloud normal vector calculation based on SOM. *Computer Engineering*, 2012, **38**(8): 287–290  
(曾锋, 钟治初, 杨通, 姚山. 基于 SOM 的散乱点云法矢计算. *计算机工程*, 2012, **38**(8): 287–290)
- 30 Zheng Hui-Cheng, Shen Wei. A localized linear manifold self-organizing map. *Acta Automatica Sinica*, 2008, **34**(10): 1298–1304  
(郑慧诚, 沈伟. 一种局部化的线性流形自组织映射. *自动化学报*, 2008, **34**(10): 1298–1304)
- 31 Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 1989, **77**(2): 257–286
- 32 Gomez R, Toda T, Saruwatari H, Shikano K. Techniques in rapid unsupervised speaker adaptation based on HMM-sufficient statistics. *Speech Communication*, 2009, **51**(1): 42–57
- 33 Englehart K, Hudgins B. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 2003, **50**(7): 848–854



**佟丽娜** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室控制科学与工程专业博士后, 中国矿业大学(北京)机电与信息工程学院讲师. 2011 年取得中国科学技术大学控制科学与工程博士学位. 主要研究方向为机器人与人机交互. E-mail: lina.tong@ia.ac.cn

(**TONG Li-Na** Postdoctor in control

science and engineering at the State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences, and a lecturer at the School of Mechanical Electronic and Information Engineering, China University of Mining and Technology, Beijing. She received her Ph.D. degree in control science and engineering from the University of Science and Technology of China. Her research interest covers robotics and human-machine interaction.)




**侯增广** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室研究员. 主要研究方向为机器人控制, 智能控制理论与方法, 嵌入式系统软硬件开发, 医学和健康自动化领域的康复与手术机器人. 本文通信作者.

E-mail: zengguang.hou@ia.ac.cn

(**HOU Zeng-Guang** Professor at

the State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences. His research interest covers robotics, intelligent control theory, rehabilitation and surgical robots for medical and health automation. Corresponding author of this paper.)



**彭亮** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室控制科学与工程专业博士研究生. 主要研究方向为先进机器人控制与系统.

E-mail: liang.peng@ia.ac.cn

(**PENG Liang** Ph.D. candidate in control science and engineering at the

State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences. His research interest covers advanced robotics control and system.)



**王为群** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室控制科学与工程专业博士研究生. 主要研究方向为先进机器人控制与系统.

E-mail: weiqun.wang@ia.ac.cn

(**WANG Wei-Qun** Ph.D. candidate in control science and engineering at the

State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences. His research interest covers advanced robotics control and system.)



**陈翼雄** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室控制科学与工程专业博士研究生. 主要研究方向为机器人控制, 生物信号处理, 功能性电刺激研究.

E-mail: yixiong.chen@ia.ac.cn

(**CHEN Yi-Xiong** Ph.D. candidate in control science and engineering at

the State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Sciences. His research interest covers robot control, biomedical signal processing, and functional electrical stimulation.)



**谭民** 中国科学院自动化研究所复杂系统管理与控制国家重点实验室研究员. 主要研究方向为先进机器人控制, 多机器人系统, 仿生机器人及制造系统.

E-mail: min.tan@ia.ac.cn

(**TAN Min** Professor at the State Key Laboratory of Management and Control for Complex Systems, Institute

of Automation, Chinese Academy of Sciences. His research interest covers advanced robot control, multi-robot systems, bio-mimetic robots, and manufacturing systems.)