

doi: 10.7690/bgzdh.2022.02.019

基于肌电信号和极限学习机的下肢关节运动预测

石永杰¹, 高学山^{1,2}, 罗定吉³, 吕佳乐¹, 吕鹏飞³, 刘欢³, 车红娟¹, 赵鹏¹, 牛军道³, 郝亮超³

(1. 广西科技大学电气与信息工程学院, 广西 柳州 545000; 2. 北京理工大学机电学院, 北京 100081;

3. 广西科技大学机械与交通工程学院, 广西 柳州 545000)

摘要: 为判断下肢障碍患者的运动意图, 通过外骨骼进行康复训练, 分析表面肌电信号与下肢关节运动的关系。提取表面肌电信号的均方根 (root mean square, RMS)、绝对值均值 (mean absolute value, MAV)、波形长度 (waveform length, WL) 和方差 (variance, VAR) 作为特征输入信号, 采用极限学习机 (extreme learning machine, ELM) 建立表面肌电信号与下肢关节角度之间的映射关系; 对输出结果进行优化滤波以降低模型的误差, 实现对下肢膝关节角度连续变化的预测。与传统的反向传播 (back propagation, BP) 神经网络、径向基神经网络预测结果进行对比, 结果证明: 极限学习机在通过表面肌电信号预测下肢关节角度变化中有更高的精度。

关键词: 表面肌电信号; 极限学习机; 多特征提取; 关节角度

中图分类号: TP242 **文献标志码:** A

Prediction of Lower Limb Joint Motion Based on Surface EMG Signal and Extreme Learning Machine

Shi Yongjie¹, Gao Xueshan^{1,2}, Luo Dingji³, LYU Jiale¹, LYU Pengfei³, Liu Huan³, Che Hongjuan¹, Zhao Peng¹, Niu Jundao³, Hao Liangchao³

(1. School of Electrical and Information Engineering, Guangxi University of Science and Technology, Liuzhou 545000, China;

2. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China;

3. School of Mechanical and Transportation Engineering, Guangxi University of Science and Technology, Liuzhou 545000, China)

Abstract: In order to judge the motor intention of patients with lower limb disorders, the relationship between surface electromyography (SEMG) signal and lower limb joint movement was analyzed through rehabilitation training of exoskeleton. The root mean square (RMS), mean absolute value (MAV), waveform length (WL) and variance (VAR) of SEMG signal are extracted as feature input signals, and the mapping relationship between SEMG signal and lower limb joint angle is established by using extreme learning machine (ELM); the output results are optimized and filtered to reduce the error of the model, and the continuous change of lower limb knee angle is predicted. Compared with the traditional back-propagation neural network and radial basis function neural network, the results show that the extreme learning machine has higher accuracy in predicting the change of lower limb joint angle through SEMG signal.

Keywords: SEMG signals; ELM; multi-feature extraction; joint angle

0 引言

我国老龄化问题日益严重, 脑卒中、偏瘫等疾病严重影响了老年人的日常生活^[1]。因中枢神经受损引起的运动障碍的恢复, 主要依靠患者下肢进行运动训练。利用外骨骼辅助患者进行运动训练可更好地调动患者的积极性, 是一种较为理想的康复方法。如何协调外骨骼与人体运动是外骨骼运动控制要解决的关键问题之一^[2]。人机交互可通过检测力、位置传感器或生理信号(脑电、肌电)等预测人体的运动意图^[3]。由于表面肌电信号与肌肉力的大小相关, 可以反映人体的肢体运动。表面肌电信号控制系统具有仿生性好、动作自然等优点, 表面肌

电信号已成为人-机交互系统最为理想的控制信号源^[4]; 因此, 将表面肌电信号作为输入信号预测人体运动意图, 其预测出的人体关节角度变化作为外骨骼康复机器人的输入信号, 外骨骼可按照患者的运动意图进行运动, 有利于使病人主动参与康复训练, 加快患者下肢肌肉力量的恢复^[5]。

肌电控制系统主要通过采集人体皮肤表面的表面肌电信号, 提取信号的特征值进行动作识别^[6], 将识别的结果作为外骨骼的输入信号, 使外骨骼按照患者的运动意图带动下肢运动^[7]。张琴等采集了 10 名测试者的数据进行滤波处理, 采用支持向量机建立了表面肌电信号与关节运动之间的映射关

收稿日期: 2021-10-23; 修回日期: 2021-11-20

基金项目: 中国老年失能预防与干预管理网络及技术研究(2020YFC2008503)

作者简介: 石永杰(1994—), 男, 山东人, 硕士, 从事人体下肢关节角度预测研究。E-mail: 1635001670@qq.com。

系^[8]。章亚男等采用反向传播(BP)神经网络基于表面肌电信号合理预测了下肢关节角度变化^[9]。针对传统神经模型构建的数学模型精度不高的问题,笔者采集下肢 4 块肌肉的表面肌电信号,并提取每组数据的 4 种特征向量,利用极限学习机(ELM)建立表面肌电信号特征值与关节角度之间的数学关系,对结果进行限幅滤波处理,并比较了与 BP 神经网络、径向基神经网络的均方根误差(root mean square error, RMSE)以评价模型的精度。

1 表面肌电信号的产生与采集

1.1 实验原理

当人体产生运动意图,大脑皮层会产生生物电信号,经过神经中枢传递给对应的肌肉^[10]。肌肉的收缩力与肌肉细胞产生的动作电位大小相关,肌电信号的产生比肌肉收缩提前约 100 ms^[11]。人体所有的关节都由相应的肌肉群驱动,所以表面肌电信号不仅能反映肌肉的收缩强度,还可体现关节的运动信息^[12]。

1.2 实验数据采集及处理

获取人体肌电信号的方法有侵入式采集和非侵入式采集^[13]。侵入式采集可检测肌肉深层的肌电信号,避免肌肉群之间的相互干扰,具有较好的信噪比和分辨率,但采集信号时需将肌电信号传感器刺入肌肉,易对肌肉造成伤害,不宜长期使用,另外传感器采集的区域太小,不能反映整块肌肉的特性^[14]。非侵入式采集将肌电传感器贴附在皮肤表面,采集人体的表面肌电信号,可反映出整块肌肉的运动特性且对人体几乎没有伤害,所以在肌电控制系统中非侵入式采集应用最为广泛。笔者采用非侵入式采集人体的表面肌电信号数据进行分析。下肢肌肉分布位置如图 1 所示。




图 1 下肢肌肉分布

实验采用 MiniSun 公司的 IDEEA 步态分析仪采集受试者在行走过程中的关节角度变化和表面肌电信号数据。表面肌电信号测量系统由 2 个电极片组成,根据 2 片电极的电压差分析表面肌电信号的大小。电极片的材料为 Ag/AgCl 与专用电极胶,可预防长时间与皮肤接触导致的皮肤过敏,同时具有很好的导电性与粘贴能力,避免了在实验采集过程中由于电极片的移动或脱落而导致表面肌电信号不准确或数据丢失。

表 1 测试者数据参数

序号	性别	年龄	身高/cm	体重/kg
1	男	26	172	60
2	男	24	176	68
3	男	25	170	52
4	女	24	168	55
5	男	27	180	80
平均值		25.2	173.2	63.0

按照步态分析仪采集系统的建议:正负电极放置在肌肉的肌腹位置,正负电极距离不超过 2 cm,参考电极放置膝关节位置。表面肌电信号非常微弱,幅值在 100~5 000 μV 之间,信噪比较低,易受周围噪声信号干扰;表面肌电信号采集过程中需采取措施以减少信号误差,采集信号前,用医用酒精擦洗要贴电极片的部位,保证电极片与皮肤接触良好以减小皮肤表面与电极片之间的阻抗,并使电极片固定以防止在实验过程中发生掉落或偏移。在数据采集过程中,测试者自由行走,对每个测试者采集 3 次数据,为防止长时间运动导致疲劳而引起的数据采集不准确,每名测试者在采集完数据之后休息 1 h,选取采集效果最好的 1 组作为最终数据。传感器放置位置如图 2 所示。




图 2 传感器位置分布

步态分析仪采用 4 通道肌电传感器同时采集股二头肌(biceps femoris, BF)、股外侧肌(vastus lateralis, VL)、股内侧肌(vastus medialis, VM)、

股直肌 (Frectus femoris, RF) 4 块肌肉的表面肌电信号。采用关节角度传感器同步采集膝关节角度变化。受试者参与测试前均熟悉测试流程, 步态分析仪采集到 4 块肌肉的表面肌电信号, 如图 3 所示。




图 3 表面肌电信号变化

1.3 数据处理

表面肌电信号的数据处理主要包括滤波和特征提取 2 部分。由于表面肌电信号的频率在 20~50 Hz, 采集数据后先滤除表面肌电信号有效频率之外的噪声干扰, 再对数据进行 50 Hz 的滤波, 以消除工频信号对表面肌电信号的干扰。常用的表面肌电信号特征提取方式为时域特征提取和频域特征提取。由于表面肌电信号在幅值上差别较大, 为使神经网络的训练速度更快, 减少模型误差, 对每组数据进行归一化处理。归一化后的数据为:

$$MVC = x/x_{\max} \quad (1)$$

式中: MVC 为归一化后的表面肌电信号; x 为实时测量的表面肌电信号值; x_{\max} 为表面肌电信号的最大值。

表面肌电信号的时域特征可体现表面肌电信号随时间变化的情况, 在表面肌电信号的研究中应用最为广泛。常用的时域分析特征提取方法有均方根值(RMS)、绝对值均值(MAV)、波形长度(WL)、方差(VAR)。笔者提取每块肌肉表面肌电信号的 4 种时域特征值作为模型的输入信号, 关节角度作为模型的输出信号。

表面肌电信号的均方根值为:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2)$$

表面肌电信号均方根特征值如图 4 所示。表面肌电信号的幅值上具有对称性, 幅值越大肌肉收缩力越大, 肌肉力大小与表面肌电信号的绝对值呈正相关关系。绝对值均值为:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3)$$

表面肌电信号在一段时间内的变化幅值用波形长度表示:

$$WL = \frac{1}{N} \sum_{i=1}^N |x_{i+1} - x_i| \quad (4)$$

由于表面肌电信号的均值为 0, 所以方差值为:

$$VAR = \frac{1}{N} \sum_{i=1}^N |x_i|^2 \quad (5)$$

式中: x_i 为时变的表面肌电信号值; N 为每次特征提取时间窗长度。




图 4 表面肌电信号均方根特征值

2 构建 ELM

ELM 相比传统的前馈性神经网络拥有更好的泛化性能。传统的神经网络采用梯度下降法优化模型参数, ELM 可随机分配隐藏层阈值和输入层权重; 因此, 其训练速度比传统的神经网络更快。其模型结构如图 5 所示。




图 5 ELM 模型结构

ELM 结构包含输入层、隐含层与输出层，相邻两层之间的每个神经元都与另一层的每个神经元所连接，但同一层内的每个神经元彼此不相连。图中： x_1 至 x_n 为表面肌电信号的特征值作为输入信号， w_{ji} 为输入层至隐含层的权值， b_1 至 b_l 为隐含层的阈值， β_j 为隐含层至输出层的权值， y 为关节角度为输出信号。输入信号用输入矩阵 \mathbf{X} 表示：

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1Q} \\ x_{21} & x_{22} & \cdots & x_{2Q} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nQ} \end{bmatrix} \quad (6)$$

式中： n 为输入数据的维数，在该模型中 n 取 16； Q 为输入数据的长度。

输出信号为关节角度变化值，输出矩阵为：

$$\mathbf{Y} = [y_1 \quad y_2 \quad \cdots \quad y_Q] \quad (7)$$

式中 Q 为输出数据的长度，与输入数据长度相等。输入层至隐含层的权值用 w 表示：

$$w = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots \\ w_{l1} & w_{l2} & \cdots & w_{ln} \end{bmatrix} \quad (8)$$

式中 w_{ij} 为输入层第 i 个神经元至隐含层第 j 个神经元之间的权值。在 ELM 结构中，隐含层的阈值用 b 表示：

$$b = [b_1 \quad b_2 \quad \cdots \quad b_l] \quad (9)$$

隐含层至输出层的连接权值用 β 表示，其表达式为

$$\beta = [\beta_1 \quad \beta_2 \quad \cdots \quad \beta_l] \quad (10)$$

式中 β_l 为隐含层第 l 个神经元到输出层神经元之间的连接权值。

假设隐含层的激活函数为 $g(x)$ ，ELM 输出矩阵计算如下：

$$\mathbf{Y} = \sum_{i=1}^l \beta_i g(w_i x_j + b_i) \quad (11)$$

为评判模型的准确性，采用均方根误差 (RMSE) 和皮尔逊相关系数作为指标进行判断。RMSE 表示预测值与测量值的偏差，能精确反映估计的精密度，计算如下：

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{k=1}^M (\theta_k - \theta'_k)^2} \quad (12)$$

式中：RMSE 为均方根误差； M 为数据数量； θ_k 为

测量关节角度值； θ'_k 为预测关节角度值。

皮尔逊相关系数表示表面肌电信号特征值数据与关节角度数据联系的紧密程度，公式如下：

$$\rho = \frac{\frac{1}{M} \sum_{k=1}^M (\theta'_k - \bar{\theta}')(\theta_k - \bar{\theta})}{\sqrt{\frac{1}{M} \sum_{k=1}^M (\theta'_k - \bar{\theta}')^2} \sqrt{\frac{1}{M} \sum_{k=1}^M (\theta_k - \bar{\theta})^2}} \quad (13)$$

式中： $\bar{\theta}'$ 为膝关节估计角度的均值； $\bar{\theta}$ 为测量关节角度的均值。

3 实验分析

3.1 优化 ELM 预测结果

将训练集输入上述网络模型，对式中的网络参数不断进行调整，减少网络模型的均方根误差。由训练集训练出神经网络，确定上述神经网络模型中的各个参数，将测试集带入训练好的神经网络，测试结果为均方根误差 8.039° ，股直肌、股内侧肌、股外侧肌、股二头肌 4 块肌肉的表面肌电信号组成的特征矩阵与膝关节角度的相关性为 0.914。预测结果如图 6 所示。




图 6 ELM 膝关节角度预测结果

由上图可看出：预测值曲线和测量值较为贴近，但存在一些高频抖动，原因可能是肌电信号噪声滤波效果不理想。消除高频抖动可选择优化肌电信号滤波方式或对输出结果进行优化以减少均方根误差 2 种方式。由于对表面肌电信号选择的几种滤波方式的预测效果皆不理想，考虑人体在正常行走中，步态不可能发生高频抖动；因此，将输出结果进行高频滤波以消除噪声，提高系统预测精度。高频滤波后均方根误差为 7.910° ，预测结果如图 7 所示。




图 7 滤波后膝关节角度预测结果

由上图可看出：虽然高频信号已被滤除，但由于膝关节拐点较陡，在高频滤波过程中仍被认为是高频信号，造成峰值数据失真，影响预测精度。为减少峰值损失，根据人体运动特点和模型预测结果对数据进行限幅滤波，即只对低于某一个值的部分数据进行滤波，对峰值数据不进行滤波。本实验只对低于 30° 的数据进行低通滤波处理。处理后的数据均方根误差分别为 7.087° ，比之前分别降低了 14.3%，结果如图 8 所示。




图 8 限幅滤波后膝关节角度预测结果

3.2 不同算法下膝关节角度运动预测值比较

比较不同神经网络下基于表面肌电信号进行关节角度连续变化预测的方法，通过采集 5 名受试者的数据，带入神经网络模型验证实验方法的有效性及其通用性。在训练阶段，分别从每个时间的 4 块肌肉、4 个特征值，提取出 16 维肌电特征值，应用 RBF, BP 神经网络及 3 种网络模型进行训练，采用网络搜索法优化网络模型的参数，找到最佳参数并带入网络模型。对神经网络模型计算出的关节角度均进行限幅滤波处理，以关节角度的测量值和 3 种神经网络的计算值的均方根误差来比较 3 种模型的精度。ELM 模型的计算结果同图 8 所示，RBF 神经

网络、BP 神经网络模型的计算结果分别如图 9、10 所示。




图 9 RBF 神经网络膝关节角度预测结果




图 10 BP 神经网络膝关节角度预测结果

ELM、RBF 神经网络、BP 神经网络 3 种模型的均方根误差分别为 7.086° ， 7.853° ， 8.023° ，从数据中可分析出 ELM 的均方根误差最小，可得知 ELM 在关节角度连续变化预测中的准确性高于 RBF 神经网络和 BP 神经网络。

4 结束语

笔者采集了受试者的股二头肌、股外侧肌、股内侧肌、股直肌 4 块肌肉的表面肌电信号，对信号滤波后提取每组信号的 4 种特征值作为输入信号。通过 ELM 建立了表面肌电信号与膝关节角度的映射关系，在模型的基础上对输出结果进行限幅滤波，有效优化了输出结果，降低了预测模型的均方根误差。同时与传统网络 BP, RBF 的训练方法进行比较，通过网络模型的输出结果分析，证明了 ELM 在表面肌电信号预测下肢关节角度连续变化中具有更好的精确性和稳定性。该分析为人体下肢外骨骼康复机器人控制系统的设计提供了理论依据，具有良好的应用前景。