

DOI:10.19344/j.cnki.issn1671-5276.2025.02.004

基于不同负载下 sEMG 的肩肘关节角度预测研究

陆浩琪, 郭佳乐, 陈劲舟, 殷正龙, 左敦稳

(南京航空航天大学 机电学院, 江苏 南京 210016)

摘要:为解决外骨骼自身质量对关节角度预测准确性影响的问题,探究不同负载对基于肌电信号的关节角度预测模型精度的影响并确定最佳负载大小。采集不同负载下的表面肌电信号,提取时域特征值作为特征输入信号,通过 BP 神经网络、支持向量机进行训练,实现对上肢肩关节和肘关节在矢状面内的连续运动预测。实验表明:在 10%1RM 的负载下,肩关节和肘关节的关节角度预测方均根误差最低,可以有效提高关节角度预测精度。

关键词:上肢负载;表面肌电信号;BP 神经网络;支持向量机;角度预测

中图分类号:TP183 **文献标志码:**A **文章编号:**1671-5276(2025)02-0022-05

Prediction of Shoulder and Elbow Joint Angles Based on sEMG under Different Loads

LU Haoqi, GUO Jiale, CHEN Jinzhou, YIN Zhenglong, ZUO Dunwen

(College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: To address the issue of the impact of exoskeleton weight on the accuracy of joint angle prediction, this paper explores the impact of different loads on the accuracy of joint angle prediction models based on electromyography signals, and determines the optimal load. Surface electromyographies are collected under different loads, and time-domain feature values are extracted as feature input signals, all of which are trained through BP neural network and support vector machine to achieve continuous motion prediction of the upper limb shoulder and elbow joints in the sagittal plane. Experiments show that under a load of 10% 1RM, the root mean square error of joint angle prediction for the shoulder and elbow joints is the lowest, which can effectively improve the accuracy of joint angle prediction.

Keywords: upper limb load; surface electromyography; BP neural network; support vector machine; angle prediction

0 引言

表面肌电信号 (surface electromyography, sEMG) 因其与肌肉活性、肢体运动的强相关性,且比肢体运动超前 30~150 ms,故常被用于外骨骼的运动意图识别。

国内外学者基于 sEMG 研究出多种方法来准确地预测关节转动角度。AUNG 等^[1]提出 BP 神经网络预测肩关节运动角度,并结合 VR 模型验证了该控制器的有效性。ZHANG 等^[2]应用 BP 神经网络模型估计下肢踝关节、膝关节、髋关节角度;实验表明该方法在角度估计的精度、实时性、动态性、平滑性和鲁棒性等方面都有了很大的提高。周楠等^[3]提出组建 5 阶新特征向量,并将所提取的 3 种特征向量输入 BP 神经网络。实验表明 BP 神经网络可以准确识别膝关节动作,且新向量输入时能有效提高训练效率。ZHAO 等^[4]构

建长短期记忆神经网络 (LSTM) 对肘关节进行连续运动估计,结果显示该方法检测准确率在 85% 以上。LI 等^[5]对比支持向量机 (SVM)、K 近邻 (KNN)、决策树 (DT)、多层感知器 (MLP) 和多通道卷积神经网络 (CNN) 5 种分类器的离线分类效果,结果显示 SVM 和 KNN 表现出卓越的准确率,达到 99%。但是,上述对肌电信号的研究都是在受试者无负载的情况下进行的,而在穿着外骨骼后,外骨骼的自身质量或是力反馈等都会产生一定量的负载,使得实际产生的肌电信号与实验不符,进而在一定程度上影响了模型预测精度。

基于此,为进一步提高关节角度预测模型的预测精度,本文提出通过探究不同负载对关节旋转角度预测的影响,从肌电信号的产生角度出发以确定获得最佳预测精度的负载大小,提高预测模型的预测精度。

基金项目:江苏省科研与实践创新计划项目 (SJ CX22_0097)

第一作者简介:陆浩琪 (1998—),男,江苏苏州人,硕士研究生,研究方向为外骨骼控制,572496599@qq.com。

1 肌电信号采集与预处理

肌电信号是一种能够反映肌肉活动的生理电信号,可以准确反映肌肉收缩状态并在一定程度上反映人的运动意图。然而,肌电信号具有微弱、低频的特性^[6],易受噪声干扰。如何正确采集并有效预处理对提高肌电信号的可分析性至关重要。

1.1 采集装置

选用 STM32 系列微控制器 STM32F103C8T6 作为主控器,以满足外骨骼控制及 sEMG 的通信需求。表面肌电信号由第 3 代 MyoWare 肌电传感器和肌电电极采集,通过四通道 ADC 模块进行模数转换。肩部及肘部关节角度数据则由 MPU6050 姿态传感器采集,通过两通道 ADC 模块转换。最终,数字化数据传输至 STM32 主控器,并通过串口通信与上位机进行数据交互。表面肌电信号采样频率为 1 000 Hz,姿态传感器采样频率为 1 250 Hz。

1.2 实验设置

选取 6 名成年健康男性作为受试者,记为 A、B、C、D、E 和 F,年龄 21~25 岁,体脂率(16±4)%,身高(170±10)cm。本研究重点为上肢托举运动。受试者首先保持大臂竖直向下,小臂水平向前,掌心向上的初始状态,接着慢速(一个周期约 3.5 s)抬起手臂至最高处,该动作涉及多个关键肌群,包括腕屈肌、肱桡肌、肱二头肌以及三角肌。为了准确测量肌电信号,传感器应垂直于肌肉纤维放置在肌肉腹部的中央位置。放置前需剃除受试者采集部位的皮肤汗毛,并使用酒精棉擦拭皮肤表面以去除有影响的油脂和死皮。除肌电传感器外还需要在肩、肘关节处用绑带固定姿态传感器。每次测试前,嘱咐受试者保证充分休息以确保肌肉处于最佳状态。试验前引导受试者从水平位置托举尽可能重的哑铃以单独测取每位受试者 1 次所能举起的最大质量(one-repetition maximum, 1RM)^[7]。试验过程中,首先让受试者进行无负载托举动作,接着以 1RM 的 10%、20%、30% 和 40% 所对应的质量依次托举,共 5 种不同负载的测试。每组托举 10 次为 1 轮,每位受试者进行 5 轮测试。每轮采集结束后,受试者休息 5 min 以排除肌肉疲劳对信号的影响。同时,利用采集装置同步记录受试者的 sEMG 信号及肩关节和肘关节旋转角度。

1.3 sEMG 预处理

原始 sEMG 在采集过程中容易受到多种干

扰,包括人体自身噪声、工频干扰、运动伪迹等。人体自身噪声主要来自相邻肌肉群及心电干扰,主要集中在 0~35 Hz。工频干扰噪声的频率则为 50 Hz,主要为信号采集设备固有频率以及周围电子设备产生的电磁干扰。同时,当上肢肌肉运动时皮肤与接触电极之间会产生相对位移,从而产生运动伪迹噪声,该噪声频率集中在 1~20 Hz。以上噪声均会干扰 sEMG 信号,影响后续的特征提取。

1) sEMG 去噪处理

sEMG 的有效信号集中于 20~350 Hz^[8]。因此,采用 Butterworth 带通滤波器去除高于 350 Hz 的高频噪声及低于 20 Hz 的低频噪声,即人体自身噪声和运动伪迹噪声。同时采用 50 Hz 陷波器滤除工频信号。滤波后的 sEMG 信号频谱如图 1 所示。




图 1 滤波后 sEMG 幅频图

2) 滑动窗口数据分割

本研究采用滑动窗口分割法对 sEMG 进行数据切割,获取 sEMG 的多个子数据段,以单位滑动步长对信号特征进行提取,确保信号的连续性。窗口个数的计算如式(1)所示。

$$N = \frac{L-l}{K} + 1 \quad (1)$$

式中: N 为窗口数量; L 为采样点个数; l 为窗口长度; K 为滑动步长。设定滑动窗口长度为 32 个采样点,对应的采样时间为 32 ms,滑动步长为 8 个采样点,对应的窗口间隔时间为 8 ms。图 2 为滑动窗口分割示意图。




图 2 滑动窗口示意图

2 基于 sEMG 的关节旋转角度预测

2.1 表面肌电信号特征值选取

表面肌电信号为一维电压信号,与常见的振动信号和声信号相比,具有非平稳性和随机性特征。目前还没有确切统一的特征表征方法,研究者们通常在时域、频域和时频域 3 个方面进行分析。频域分析与时频域分析需要较长的处理时间且分析效果欠佳,无法满足外骨骼对响应时间和控制精度的要求。相较之下,时域分析计算简单、快速,且具有更高的准确性,故本研究主要进行时域分析。

采用滑动时间窗的方法切割数据,提取信号特征,特征值包括平均绝对值(mean absolute value, MAV)、方均根(root mean square, RMS)、波形长度(waveform length, WL)。张琴等^[9]研究表明,上述 3 个特征值可以对关节角度进行有效预测,特征值可以用式(2)~式(4)说明。

$$MAV(h) = \frac{1}{N} \sum_{i=h-N+1}^h |X_i| \quad (2)$$

$$RMS(h) = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (3)$$

$$WL(h) = \sum_{i=h-N+2}^h |X_{i+1} - X_i| \quad (4)$$

式中: h 为当前的样本点; N 为用于计算平均值的窗口大小; X_i 为在时间点 i 的肌电信号值。

2.2 关节旋转角度预测模型构建

为减少预测模型对实验结果的影响,本文采用两种常用于 sEMG 非线性回归的预测模型:BP 神经网络、支持向量机(support vector machines, SVM)。

1) BP 神经网络结构与参数选择

BP 神经网络是一种用误差反向传播算法训练的多层前向神经网络,由输入层、隐藏层和输出层 3 个部分组成,上下层之间完全连接,同一层间无连接。本文用 3 层 BP 神经网络从肌电信号映射到肩关节角度和肘关节角度,模型如图 3 所示。




图 3 BP 神经网络结构图

隐藏层单元数量可以由经验公式(5)确定。

$$n_1 = \sqrt{n+m} + a \quad (5)$$

式中: n 是输入单元数; m 是输出神经元个数; a 是 1~10 之间的常数。

通过式(5)可以将隐藏层单元数量的值限制在[6,17]。然后,将隐藏层单元的数量从 6 个依次增加到 17 个,并根据式(6)计算对应的方均误差值(mean square error, MSE),通过枚举确定误差最小值,对应获得最佳隐藏层数和神经网络模型。经计算,本研究最终得到的最佳隐藏层节点数是 15。

$$M_{SE} = \frac{\sum_{i=1}^n (\tilde{\theta}_i - \theta_i)^2}{k} \quad (6)$$

式中: θ_i 是训练集角度数据的归一化值; $\tilde{\theta}_i$ 是使用训练好的模型模拟训练集每个通道上 sEMG 的标准化值的结果; k 是训练样本的采样点数。

2) SVM 算法与参数选择

SVM 是一种常用于模式分类和非线性回归的机器学习算法^[10],当解决非线性问题时,主要采用核映射的方法来实现。基本思想是:首先通过非线性变换将输入向量 $\mathbf{x}$ 映射到高维特征空间 Z ,在这个空间完成线性回归;通过在高维线性空间构造回归估计函数,并引入松弛变量($\varepsilon = 0.01$),以训练误差作为约束函数,得到最优化问题;然后,通过拉格朗日乘子法将其转化为对偶最优化问题。

$$\begin{cases} R_{\min}(\alpha_i, \alpha_i^*) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \cdot \\ K(\mathbf{x}_i, \mathbf{x}) + \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i(\alpha_i - \alpha_i^*) \\ \text{s.t. } \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, 0 \leq \alpha_i, \alpha_i^* \leq C \end{cases} \quad (7)$$

式中: $K(\mathbf{x}_i, \mathbf{x})$ 为核函数; C 为惩罚系数。本文采用的 RBF 核函数为

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2}\right) \quad (8)$$

该 SVM 包含两个参数:惩罚系数 C 和由 RBF 核函数产生的径向基函数参数 $g = -\frac{1}{2\sigma^2}$ 。参数选择采用网格寻优法,验证方式采用十折交叉验证,对训练集进行 10 次训练和验证划分,然后以 2 维网格形式对 (C, g) 参数进行搜索,每一

组(C, g)参数需要计算出十折交叉验证精度的最优值,以交叉验证精度最高的一组(C, g)作为最佳参数。

3 不同负载对训练结果的影响

为了分析负载对预测结果的影响,将采集到的样本的 80% 用于训练模型,剩余 20% 数据用于测试和预测实验结果。本文使用方均根误差(root mean square error, RMSE) 指标来评估不同负载的预测精度。方均根误差表示预测值与真实值偏差的平方和样本数 n 比值的平方,能较好地反映预测精度。评价指标值越小,此负载的预测精度越高。计算公式如下:

$$R_{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{\theta}_i - \theta_i)^2} \quad (9)$$

对于每位受试者,分别建立 BP 神经网络和 SVM 用于不同负载下托举运动的关节旋转角度预测。图 4 和图 5 为一位受试者在 5 种负载条件下的 BP 神经网络和 SVM 的肩关节和肘关节角度预测结果,其中实线为实际旋转角度,虚线为预测结果。




图 4 BP 关节角度预测结果




图 5 SVM 关节角度预测结果

由图 4 和图 5 可以看出,实际曲线与预测曲线趋势基本一致,BP 神经网络和 SVM 可以较好地预测肩关节和肘关节角度。在无负载情况下,

实际曲线与预测曲线出现较明显偏差,而在有负载情况下,实际曲线与预测曲线重叠部分增多,偏差减小。

为了直观对比负载大小对预测性能的影响,6 名受试者的实验数据通过不同的回归模型所得到的方均根误差平均值如图 6 所示。




图 6 不同负载的预测角度 RMSE 值

由图 6 可以看出,在以上两种预测模型中,负载质量为 10% 1RM 时的预测精度最高,而在无负载情况下的预测精度最低。相较于无负载,负载质量为 10% 1RM 时 BP 神经网络对肩关节和肘关节的预测精度分别提高了 22.8% 和 24.7%,支持向量机对肩关节和肘关节的预测精度分别提高了 22.5% 和 20.8%。随着负载的增加,预测精度略微降低。考虑到长时间高负载托举运动后,人体肌肉会产生疲劳影响预测精度,本文认为在这 5 种负载情况下,10% 1RM 负载下的肌电信号更适合用于角度预测。

表 1 和表 2 总结了 6 名受试者在不同负载托举运动下的肩关节和肘关节角度预测方均根误差。

表 1 基于 BP 神经网络的关节角度 RMSE 值

受试者		0	10% 1RM	20% 1RM	30% 1RM	40% 1RM
A	肩	6.49	4.61	5.42	5.83	5.04
	肘	6.41	5.60	6.66	6.76	5.36
B	肩	5.13	4.47	5.04	5.09	6.45
	肘	5.81	5.09	5.23	5.13	6.20
C	肩	5.46	4.36	4.72	5.03	5.41
	肘	7.27	5.37	5.17	6.46	5.68
D	肩	9.22	5.83	6.79	6.44	5.44
	肘	11.1	6.82	8.26	7.47	7.14
E	肩	4.30	3.67	3.96	3.67	4.00
	肘	6.34	5.23	5.60	5.37	6.13
F	肩	6.99	4.72	5.66	6.44	6.22
	肘	8.05	5.80	6.73	6.73	7.52

表 2 基于 SVM 的关节角度 RMSE 值

受试者		0	10%1RM	20%1RM	30%1RM	40%1RM
A	肩	7.25	5.15	5.74	6.32	5.79
	肘	7.78	5.81	6.47	6.68	5.83
B	肩	6.18	5.82	5.84	7.31	7.58
	肘	7.11	6.53	6.20	7.50	7.73
C	肩	7.10	5.86	6.84	6.50	7.26
	肘	9.57	6.86	7.15	8.29	7.15
D	肩	9.91	6.80	7.23	6.34	6.39
	肘	12.4	7.66	8.84	8.22	9.00
E	肩	5.49	4.33	4.92	5.15	6.08
	肘	8.09	6.67	7.12	7.02	7.36
F	肩	8.92	6.68	8.41	8.96	6.62
	肘	10.4	8.15	10.2	9.20	7.88

6 名健康受试者的 RMSE 值结果各不相同,这和每个人自身的条件以及采集 sEMG 的环境等因素有关。从表中数据可以看出,在负载为 10% 1RM 时,所有受试者的方均根误差均处于相对较低值,且与最低值之间差距不大(例如在 BP 神经网络预测结果中,受试者 D 的肩关节预测 RMSE 最小值在 30% 1RM 时产生,大小为 6.44,与 10% 1RM 的 RMSE 差值小于 0.5)。由此可以得出,10%1RM 负载对单独受试者的实验数据同样适用,并且可以在达到很好预测效果的基础上减少受试者的肌肉疲劳程度,该方法具有很强的实用推广性。

4 结语

随着人机交互技术的日益成熟,使用 sEMG 控制助力外骨骼成为可能。而目前对于外骨骼托举运动的关节连续解码依然存在较大的误差,因此本文提出了不同负载下的肩、肘关节旋转角度预测。结果表明:通过肌电信号的陷波滤波和带通滤波进行预处理,并对其从时域进行特征提取,再经由 BP 神经网络、支持向量机构建的预测模型,在本研究的 5 种负载大小中,10%1RM 负载在预测精度方面有较好的效果。将其与无负载情况进行对比,其预测效果明显改善。该方法也为接

下来的肌电信号控制上肢托举外骨骼提供了理论和实验支持。

本文采用以 10% 1RM 质量为间隔的 5 种负载情况,在后续的研究中,研究人员可以使用更小间隔的负载,进一步探究负载与肌电信号的关系,力求寻找到更精确的负载质量。

参考文献:

- [1] AUNG Y M, AL-JUMAILY A. sEMG based ANN for shoulder angle prediction [J]. Procedia Engineering, 2012, 41: 1009-1015.
- [2] ZHANG F, LI P F, HOU Z G, et al. sEMG - based continuous estimation of joint angles of human legs by using BP neural network [J]. Neurocomputing, 2012, 78(1): 139-148.
- [3] 周楠, 滕燕. 基于 SEMG 的膝关节康复动作模式识别技术研究 [J]. 机械制造与自动化, 2016, 45(6): 220-222, 228.
- [4] ZHAO D Z, MA Y H, MENG J Y, et al. MCR-ALS-based muscle synergy extraction method combined with LSTM neural network for motion intention detection [J]. Frontiers in Neurorobotics, 2023, 17: 1174710.
- [5] LI K, LI Z Z, ZENG H B, et al. Control of newly - designed wearable robotic hand exoskeleton based on surface electromyographic signals [J]. Frontiers in Neurorobotics, 2021, 15: 711047.
- [6] FARINA D, MERLETTI R, ENOKA R M. The extraction of neural strategies from the surface EMG [J]. Journal of Applied Physiology, 2004, 96(4): 1486-1495.
- [7] 梁成军. 不同负荷与收缩形式对肌肉抗阻力训练神经适应的影响 [J]. 中国运动医学杂志, 2020, 39(1): 53-58.
- [8] ZHANG L, LIU G, HAN B, et al. sEMG based human motion intention recognition [J]. Journal of Robotics, 2019(1): 1-12.
- [9] 张琴, 骆无意, 黄波, 等. 基于肌电信号的下肢关节连续运动预测 [J]. 华中科技大学学报(自然科学版), 2017, 45(10): 128-132.
- [10] VAPNIK V N. The nature of statistical learning theory [M]. New York: Springer, 1995.

收稿日期: 2023 - 10 - 20