

文章编号: 1004-7220(2023)02-0324-07

基于多模态信息融合的肘关节连续运动估计

李素姣^{1,2,3}, 朱越^{1,2}, 吴坤^{1,2}, 朱纯煜^{1,2}, 喻洪流^{1,2,3}

(1. 上海理工大学 康复工程与技术研究所, 上海 200093; 2. 上海康复器械工程技术研究中心, 上海 200093;

3. 民政部神经功能信息与康复工程重点实验室, 上海 200093)

摘要:目的 针对目前上肢康复训练设备多为被动式、训练方式单一、患者主动参与度较低等问题, 提出一种基于多模态信息融合的上肢连续运动估计算法, 实现对肘关节力矩的准确估计。**方法** 首先, 在4种角速度下, 采集受试者的表面肌电信号和姿态信号, 提取信号的时域特征并利用主成分分析方法进行特征融合; 其次, 通过附加动量法和自适应学习率对反向传播神经网络(back propagation neural network, BPNN)进行改进, 使用粒子群算法(particle swarm optimization, PSO)对神经网络进行优化, 构建基于PSO-BPNN的连续运动估计模型; 最后, 以第2类拉格朗日方程计算的关节力矩作为准确值, 对模型进行训练, 并与传统BPNN模型进行性能对比。**结果** 传统BP神经网络模型均方根误差为558.9 mN·m, R^2 系数为77.19%, 优化模型后的均方根误差和 R^2 系数分别为113.6 N·m、99.12%, 力矩估计准确度进一步提高。**结论** 本文提出的肘关节连续运动估计方法能够准确地识别运动意图, 为上肢外骨骼康复机器人的主动控制提供切实可行的方案。

关键词: 特征融合; 神经网络; 粒子群算法; 连续运动估计; 表面肌电信号

中图分类号: R 318.01

文献标志码: A

DOI: 10.16156/j.1004-7220.2023.02.018

Continuous Motion Estimation of Elbow Joint Based on Multi-Modal Information Fusion

LI Sujiao^{1,2,3}, ZHU Yue^{1,2}, WU Kun^{1,2}, ZHU Chunyu^{1,2}, YU Hongliu^{1,2,3}

(1. Institute of Rehabilitative Engineering & Technology, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Shanghai Engineering Research Center of Assistive Devices, Shanghai 200093, China; 3. Key Laboratory of Neural-Functional Information and Rehabilitation Engineering of the Ministry of Civil Affairs, Shanghai 200093, China)

Abstract: Objective Aiming at the problems of lacking initiative in upper limb rehabilitation training equipment, single training mode, and low active participation of patients, an upper limb continuous motion estimation algorithm model based on multi-modal information fusion was proposed, so as to realize accurate estimation of elbow joint torque. **Methods** Firstly, the surface electromyography (sEMG) signals and posture signals of participants were collected at four angular velocities, and the time domain characteristics of the signals were extracted. The principal component analysis was adopted for multi-feature fusion. The back propagation neural network (BPNN) was optimized through the additional momentum and the adaptive learning rate method. The particle swarm optimization (PSO) algorithm was used to optimize the neural network and a continuous motion estimation model based on PSO-BPNN was constructed. Finally, the joint torque calculated by the second type of

收稿日期: 2021-12-13; 修回日期: 2022-01-30

基金项目: 国家重点研发计划项目(2020YFC2007902), 国家自然科学基金项目(61903255)

通信作者: 喻洪流, 教授, E-mail: yhl98@hotmail.com

Lagrangian equation was used as the accurate value to train the model. The performance of the model was compared with the traditional BPNN model. **Results** The root mean square error (RMSE) of the traditional BPNN model was 558.9 N·m, and the R^2 coefficient was 77.19%, whereas the RMSE and the R^2 coefficient of the optimized model were 113.6 mN·m and 99.12%, respectively. Thereby, the accuracy of torque estimation was improved apparently. **Conclusions** The method for continuous motion estimation of the elbow joint proposed in this study can estimate the motion intention accurately, and provide a practical scheme for the active control of upper exoskeleton rehabilitation robot.

Key words: feature fusion; neural networks; particle swarm optimization; continuous motion estimation; surface electromyography (sEMG)

由于康复机器人能够提高康复训练效率,满足大多数偏瘫患者康复训练需求,缓解康复资源短缺,近年来得到广泛应用。现有的康复训练设备多为被动式,训练方式单一且机械化^[1]。主动式的康复训练通过检测患者的运动意图辅助患者完成训练,能够提高患者的主动参与度,有助于运动机能的重建,提高康复训练效果^[2]。

表面肌电(surface electromyography, sEMG)信号能够直接反映肌肉的运动状态,并且信号产生时间比动作提前 20~200 ms,故被广泛地应用于人体运动意图检测^[3-4]。基于 sEMG 的运动意图检测主要分为分类问题和回归问题^[5]。由于分类方法只能识别独立的离散动作,无法使控制对象连续自如地完成动作,故连续运动状态估计成为研究的新热点^[6]。

目前,连续运动状态估计多为通过 sEMG 信号预测关节角度^[7-12]。但是康复机器人在康复训练过程中,对力的控制优先等级大于对位置的优先等级,故学者们开始研究通过 EMG 信号预测关节力矩^[13-16]。Wang 等^[17]提出一种基于人工神经网络的 sEMG 驱动扭矩估计模型,采集来自前臂的 8 通道 sEMG,建立延时神经网络估计腕关节扭矩,根据人体运动意图控制腕关节旋转。陈江城等^[18]从幅值和频率出发,建立从 sEMG 到关节力矩的正向生物力学模型,以牛顿-欧拉逆动力学方法获得关节力矩作为预测值,完成模型参数标定。Zhang 等^[19]根据腕关节动力学模型计算参考腕关节力矩,然后基于长短时记忆方法建立从 sEMG 到关节力矩的预测模型,采用 Pearson 相关系数作为评估参数,平均达到了 0.928 9。Siu 等^[20]使用密集前馈、卷积、神经微分方程和长短时记忆神经网络进行踝关节力矩预测,预测力矩与实际力矩显示出强烈的正相关。

目前研究多采用 sEMG 信号进行连续运动估计,而 sEMG 是一种非平稳的随机信号,仅采用 sEMG 作为交互信号不利于系统的稳定控制。

本文融合多通道 sEMG 信号和关节角度信号作为特征矩阵,建立简化的上肢二连杆模型计算肘关节力矩作为期望输出,通过粒子群算法(particle swarm optimization, PSO)对改进后的反向传播神经网络(back propagation neural network, BPNN)进行参数优化,对基于 PSO-BPNN 算法构造的肘关节主动动力矩估计模型进行训练和测试。结果表明,该模型能够准确有效地估计肘关节力矩,将力矩作为控制系统的输入进行同步比例控制,可以实现上肢外骨骼的柔顺控制。

1 方法

本文基于多模态信息融合技术,使用 PSO 对改进后的 BPNN 进行优化,使用优化后的 BPNN 算法估计人体肘关节主动动力矩。主要研究内容分为三部分:多模态信号采集与处理(获取模型输入)、上肢二连杆动力学方程(获取模型期望输出)和基于 PSO-BPNN 的肘关节力矩估计模型,研究内容总体框图见图 1。

1.1 多模态信号采集与处理

1.1.1 信号采集 当受试者做肘关节屈伸运动时,分别记录肱二头肌、肱三头肌和肱桡肌的 sEMG 信号,同时采集肘、肩关节的角度数据。信号采集设备为美国 NORAXON 公司的人体全身运动移动监测系统,包括 16 通道无线 sEMG 采集系统、16 关节三维角度采集系统、数据集成同步采集盒和计算机数据站。sEMG 信号和关节角度同步采集,采样频率为 1.5 kHz。

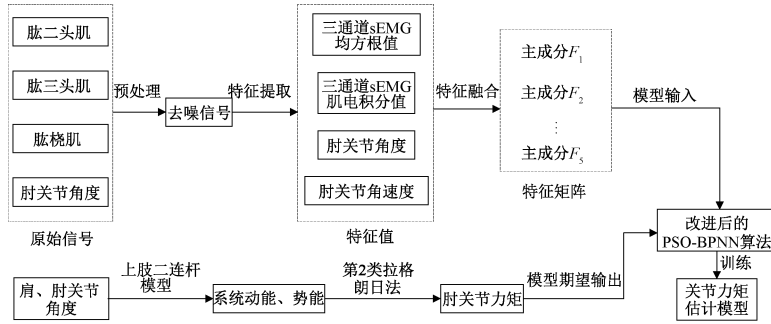


图1 总体框图

Fig. 1 Overall block diagram

在肘关节屈伸运动实验中,先测量受试者最大自主收缩情况下的EMG信号用于归一化。为了保证实验数据覆盖到不同运动速度,让每个受试者跟随动作视频在 $20^\circ/\text{s}$ 、 $40^\circ/\text{s}$ 、 $60^\circ/\text{s}$ 、 $80^\circ/\text{s}$ 4种速度下做屈伸运动。每位受试者在不同运动速度下分别采集6组实验数据,每组做10次肘关节屈伸,屈伸运动间隔2 s,每组实验间隔2 min 休息时间。

1.1.2 预处理 sEMG信号频率范围为20~500 Hz,主要频率范围集中在20~150 Hz。本文设计了两个滤波器对原始sEMG信号进行预处理。带通滤波器通带的截止频率为20~500 Hz,阻带截止频率为10、620 Hz。阻带衰减为-40 dB,将阻带信号衰减到原始信号的1%以下。50 Hz陷波滤波器通带的截止频率为49、51 Hz,阻带截止频率为49.9~50.1 Hz。阻带衰减为-21dB,将阻带信号衰减到原始信号的10%以下。滤除噪声后,对sEMG信号进行全波整流和包络线提取,可以更清楚地反映振幅的变化过程。预处理前后的sEMG信号如图2所示。

1.1.3 特征提取 本文选取均方根(root mean square, RMS)和积分肌电值(iEMG)作为特征值。其计算公式分别为:

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

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

式中: x_i 为各个通道sEMG信号幅值, $i=1,2,\dots,N$; N 为特征值的计算窗长。本文采用无重叠连续分割窗法进行特征提取,窗长为20 ms,移动步长为20 ms。

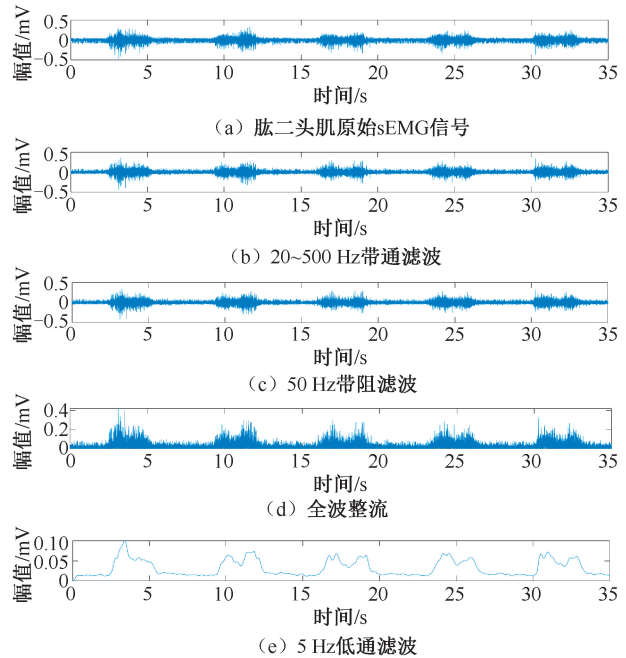


图2 表面肌电信号预处理

Fig. 2 Signal preprocessing of sEMG signals (a) Raw sEMG signal of biceps, (b) 20-500 Hz bandpass filter, (c) 50 Hz bandstop filter, (d) Full wave rectification, (e) 5 Hz low pass filter

1.1.4 多模态信息融合 为了将EMG信号特征值与角度信号特征值进行特征层融合,并去除冗余信息,降低矩阵维度,本文将提取出的特征向量标准化并采用主成分分析算法进行特征融合,计算各个特征向量的贡献率以及累计贡献率,计算结果见表1。其中, F_1 是包含信息最多的指标,称为第1主成分; F_2 是第2主成分,以此类推。

结果表明,经过主成分分析特征融合后的特征向量大于等于5维时,特征向量的累计贡献率提高

不大,充分说明主成分分析融合后的 5 维向量可以 99.98% 表示融合前的 8 维特征向量(即肱二头肌、肱三头肌和肱桡肌三通道 sEMG 信号的 RMS 和 iEMG,以及肘关节角度、角速度),实现了特征矩阵的有效降维(见表 1)。

表 1 主成分的贡献率以及特征值的累计贡献率

Tab. 1 Contribution rates of principal components and cumulative contribution rate of eigenvalues

主成分	特征值	贡献率/%	累计贡献率/%
F_1	6.499 9	81.25	81.25
F_2	1.045 5	13.07	94.32
F_3	0.240 4	3.01	97.32
F_4	0.125 1	1.56	98.89
F_5	0.087 8	1.10	99.98
F_6	0.000 6	0.01	99.99
F_7	0.000 3	0	100.00
F_8	0.000 3	0	100.00

1.2 上肢二连杆动力学模型

由于人体运动的关节力矩无法直接测量得到,许多研究人员基于人体的逆动力学来计算关节力矩^[21-23]。拉格朗日法通过广义坐标形式建立质点系统动力学方程,大大简化了求解过程,故本文选用第 2 类拉格朗日法计算人体上肢屈伸过程中的关节力矩^[22]。拉格朗日方程是基于能量项对系统变量及时间的微分建立而成的,引入拉格朗日方程直接获得多刚体动力学方程的解析公式,计算得到人体关节力矩作为连续运动估计模型的期望输出。

上肢简化为肩、上臂、前臂和手通过肩关节、肘关节连接组成 1 个二连杆模型(见图 3)。为了把上

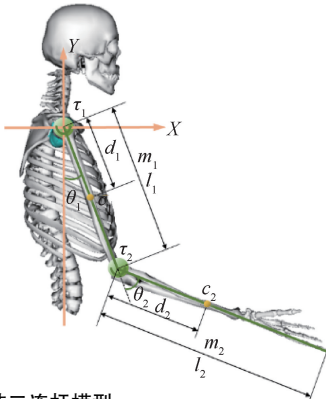


图 3 人体上肢二连杆模型

Fig. 3 Two-link model of human upper limb

注: θ_1 、 θ_2 分别为肩、肘关节角度, m_1 和 m_2 分别为上臂和前臂的质量, l_1 和 l_2 分别为上臂和前臂的长度, d_1 和 d_2 分别为上臂和前臂质心到关节中心的距离, I_1 和 I_2 分别为上臂和前臂的转动惯量。

肢屈伸运动简化成单自由度运动,实验过程中会要求受试者尽量保持手的末端和各关节只在竖直平面内运动,并且获取的肩肘关节角度为竖直平面的角度数据^[24]。

选择 θ_1 和 θ_2 为描述连杆位置的广义坐标,计算得到杆 1 和杆 2 质心的位置坐标、速度平方、角速度后,计算系统动能和势能分别为:

$$\begin{cases} E_{ki} = \frac{1}{2} m_i v_i^2 + \frac{1}{2} I_i \omega_i^2, & i = 1, 2 \\ E_k = \sum_{i=1}^n E_{ki}, & n = 2 \end{cases} \quad (3)$$

$$\begin{cases} E_{p1} = -m_1 g d_1 \cos \theta_1 \\ E_{p2} = -m_2 g l_1 \cos \theta_1 - m_2 g d_2 \cos(\theta_1 + \theta_2) \\ E_p = E_{p1} + E_{p2} \end{cases} \quad (4)$$

式中: E_{k1} 和 E_{k2} 分别为杆 1 和杆 2 的动能; E_k 为系统的总动能; E_{p1} 和 E_{p2} 分别为杆 1 和杆 2 的势能; E_p 为系统的总势能。然后,根据第 2 类拉格朗日方程:

$$\begin{cases} L(\theta, \dot{\theta}) = E_k - E_p \\ \tau = \frac{d}{dt} \left(\frac{\partial L}{\partial \dot{\theta}} \right) - \frac{\partial L}{\partial \theta} \end{cases} \quad (5)$$

求解得到肘关节力矩:

$$\begin{aligned} \tau = \frac{d}{dt} \left(\frac{\partial L}{\partial \dot{\theta}_2} \right) - \frac{\partial L}{\partial \theta_2} = & (I_2 + m_2 d_2^2) \ddot{\theta}_2 + \\ & (m_2 d_2^2 + m_2 l_1 d_2 \cos \theta_2 + I_2) \dot{\theta}_1 - (m_2 l_1 d_2 \sin \theta_2) \dot{\theta}_1 \dot{\theta}_2 + \\ & m_2 l_1 d_2 (\dot{\theta}_1^2 + \dot{\theta}_1 \dot{\theta}_2) \sin \theta_2 + m_2 g d_2 \sin(\theta_1 + \theta_2) \end{aligned} \quad (6)$$

式中: $L(\theta, \dot{\theta})$ 为拉格朗日函数,即系统的动能和势能的差值。

利用动力学方程计算关节力矩的过程中需要获取受试者的上肢各部分重量、重心位置、旋转半径和转动惯量等人体数据,这些数据无法直接测量,但是可以根据人体的身高、体重等基础测量数据,通过文献^[25]中的经验公式计算得到。

1.3 基于 PSO-BPNN 的关节力矩估计模型

1.3.1 模型 本文采用 3 层 BPNN 构建关节力矩预测模型(见图 4)。输入层神经元个数为 5,即数据融合后的五维特征向量。输出层的数量为 1,对

应肘关节力矩。隐含层个数由经验公式确定,经过试凑法发现隐含层个数为 3 时误差最小。最大训练次数为 3 000,训练精度是 10^{-3} ,初始学习率设置为 0.01,使用 tansig 函数作为输入层和隐藏层之间以及隐藏层到输出层之间的传递函数。神经网络模型的输出公式为:

$$\tau = \text{tansig}[\omega_{\text{out}} \text{tansig}(\omega_{\text{in}} s + b_{\text{in}}) + b_{\text{out}}] \quad (7)$$

$$\text{tansig} = \frac{2}{1 + e^{-2x}} - 1 \quad (8)$$

式中: $s = [F_1, F_2, F_3, F_4, F_5]$ 为特征向量; τ 为模型预测的肘关节力矩; ω_{in} 、 b_{in} 分别为输入层到隐含层的权值和阈值; ω_{out} 、 b_{out} 分别为隐含层到输出层的权值和阈值。

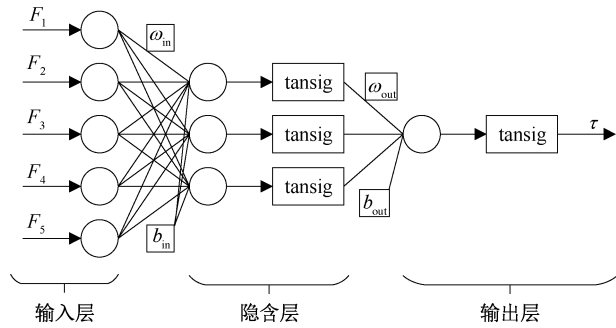


图 4 BPNN 结构

Fig. 4 BPNN structure

针对 BPNN 易陷入局部最优、收敛速度慢等问题,本文通过附加动量方法和自适应学习算法对 BPNN 进行改进。带附加动量的权值学习公式和自适应学习率计算公式如下:

$$\Delta\omega_{(k)} = \eta_{(k)} [(1 - \mu)g_{(k)} + \mu g_{(k-1)}] \quad (9)$$

$$\eta_{(k)} = 2^\lambda \eta_{(k-1)} \quad (10)$$

$$\lambda = \text{sign}[g_{(k)} g_{(k-1)}] \quad (11)$$

式中: k 为网络中训练的次数; $\Delta\omega_{(k)}$ 为第 k 次训练的权值增量; $g_{(k)}$ 为第 k 次训练计算出的梯度; $\eta_{(k)}$ 为第 k 次训练的学习率; λ 为梯度方向。

为了进一步增强网络的全局搜索能力,提高收敛速度和准确度,本文引入 PSO 对神经网络初始权值阈值进行优化。具体参数设置如下:种群规模 $N = 100$;学习因子 $c_1 = c_2 = 2$;最大迭代次数 $t_{\text{max}} = 2\ 000$;惯性权重线性递减,初值 $\omega_{\text{max}} = 0.9$,终值 $\omega_{\text{min}} = 0.4$ 。

1.3.2 评价指标 本文通过计算实际值和估计值

的均方根误差 (root mean square error, RMSE) 和决定系数 (R^2) 对关节力矩预测的准确性进行评估。RMSE 用来衡量实际值和估计值之间的偏差,越接近于 0,表明误差越小。决定系数是指因变量能够通过非线性回归关系被自变量解释的比例,越接近于 1,表明拟合效果越好。评价指标的计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$R^2 = \frac{\text{SSR}}{\text{SST}} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \times 100\% \quad (13)$$

式中: n 为肘关节力矩样本数; y_i 为第 i 个肘关节力矩实际值; \hat{y}_i 为第 i 个肘关节力矩估计值; \bar{y} 为肘关节力矩平均值。

2 实验结果

招募 7 名男性健康受试者,年龄 (25 ± 3) 岁,身高 (172 ± 8) cm,体重 (67 ± 13) kg。采集志愿者肘关节屈伸的 sEMG 信号和关节角度信号,验证该算法的有效性,并将改进后算法的估计结果与传统 BPNN 估计的效果进行对比。每位受试者分别采集了 240 次屈伸实验数据,7 名受试者共计 1 680 次。为了克服过度拟合问题,将实验样本按 6:2:2 比例分为训练集、验证集和测试集,进行力矩估计模型训练和测试^[17]。训练集旨在训练网络以获得更好的精度,验证集用于防止过拟合,当训练精度提高而验证集的估计误差却增大时说明网络过拟合,需要停止训练过程。训练完成后,通过测试集测试网络的泛化能力。

由模型在测试集上的关节力矩估计效果可知,通过粒子群优化改进后的 BPNN 可以实时准确地预测不同时刻肘关节屈伸运动时关节力矩的变化趋势,并估计出对应时刻的肘关节主动力矩 (见图 5)。

为了进一步比较算法的估计效果,用传统的 BPNN 与改进后算法的结果进行对比。在保证训练集、验证集和测试集样本完全一致,隐含层、传递函数等参数设置一致的情况下,使用传统的 BPNN 算法对肘关节力矩进行估计 (见图 6)。




图5 改进后 PSO-BPNN 算法估计结果

Fig. 5 Improved PSO-BPNN algorithm estimation results




图6 传统 BPNN 算法估计结果

Fig. 6 Estimation results of traditional BPNN algorithm

对模型的评价指标进行计算,各个样本集的 RMSE 和决定系数如表 2 所示。可以看出,改进后算法训练模型的 RMSE 更小,说明这种方法的估计值相对于 BPNN 更加精确。同时,改进后算法训练模型的决定系数大于传统神经网络模型,说明改进后算法的拟合效果更好。

表 2 力矩估计模型效果评估对比

Tab. 2 Evaluation and comparison for the effect of torque estimation models

算法		RMSE/(mN·m)	R^2 /%
改进的 PSO-BPNN 算法	训练集	116.1	99.12
	验证集	116.2	99.13
	测试集	113.6	99.17
传统 BPNN 算法	训练集	561.1	77.13
	验证集	560.9	76.77
	测试集	558.9	77.19

3 讨论

实验结果表明,基于 PSO 优化改进后的 BPNN 模型可以更为精确地实现肘关节力矩预测。本方法的改进之处主要体现在以下两方面:① 通过附加

动量方法和自适应学习算法对 BPNN 进行改进,避免神经网络陷入局部最优解;② 把 PSO 应用于神经网络优化,进一步增强网络的全局搜索能力,加快收敛速度。

一般来说,如果 RMSE 与实际平均力矩的比值小于 15%, $R^2 > 90\%$,则认为模型表现优秀^[26]。本文测试集的 RMSE 为 113.6 mN·m,实际平均力矩为 2 355.6 mN·m,比值为 4.82%, $R^2 = 99.17\%$,说明模型表现优秀。同时,改进的 PSO-BPNN 算法在测试集中的 RMSE 较传统 BPNN 算法减小 445.3 mN·m, R^2 系数较传统 BPNN 算法提高了 21.98%。由此可见,改进的 PSO-BPNN 算法训练出来的模型可以更精确地预测肘关节力矩,估计准确度远远高于传统 BPNN 算法。

此外,由表 2 可以看到,改进后算法训练的模型在 3 个样本集中的表现很好, RMSE 的范围为 113.6~116.1 mN·m, R^2 系数均达到了 99%,说明模型没有过拟合而且有很好的泛化能力,可以应用于在线控制系统。

进一步对模型的实时性进行评估,评估过程包括由原始信号输入到力矩输出。实时性测试运行在计算机主频 3.3 GHz 的 MATLAB2019b 环境下,共进行 10 组估计,每组 3 000 个样本(估计力矩个数),每组平均耗时为 279.47 ms,单次估计平均耗时 0.09 ms。原始信号的采集传输耗时约 25 ms,单次估计总耗时约 25.09 ms,由于 sEMG 信号比肢体动作提前 20~200 ms 产生,故本文模型可以满足后续应用系统的实时性要求。

与以往通过预测关节角度进行连续运动估计相比^[7-12],本文提出的方法通过预测关节力矩完成连续运动估计,能够实现更为柔顺的人机协同控制;其次,本方法可以在模型训练的过程中适应个体差异,降低误差;最后,本方法计算复杂度低,可以实现实时预测,使连续运动估计在实时性要求比较高的康复机器人控制方面的应用成为可能。

4 结论

本文提出一种基于多模态信息融合的上肢连续运动估计算法,将主成分分析算法应用于特征融合处理,利用融合后的五维特征向量作为模型输入

进行肘关节力矩估计;对上肢系统进行简化,建立上肢二连杆模型,通过拉格朗日法计算人体上肢屈伸过程中的关节力矩,作为模型输出;然后提出改进的 PSO-BPNN 算法,通过附加动量方法和自适应学习算法对 BPNN 进行改进,再采用 PSO 对 BPNN 中的初始权值和阈值进行优化,进一步建立了从特征向量映射到关节力矩的力矩估计模型。最后验证了该方法的有效性及其相对于传统神经网络模型的提高。该方法可以实现肘关节力矩的在线预测,为康复机器人控制提供技术支持。

本研究的下一步工作将分为两个方面:① 将力矩估计模型应用于上肢外骨骼机器人的柔顺控制,进行外骨骼实时控制实验,进一步验证模型效果;② 在肘关节力矩估计模型的基础上,将模型进一步扩展为多关节力矩估计,以适应多功能上肢康复的需求。

参考文献:

- [1] 张成杰. 柔性上肢康复机器人控制系统研究[D]. 重庆: 重庆理工大学, 2020.
- [2] 丁世来. 融合脑电信号和姿态信号的运动意图识别及主动式康复训练系统研究[D]. 苏州: 苏州大学, 2019.
- [3] TERAMAE T, NODA T, MORIMOTO J. EMG-based model predictive control for physical human-robot interaction: Application for assist-as-needed control [J]. IEEE Robot Autom Lett, 2018, 3(1): 210-217.
- [4] LI YR, ZHANG QH, ZENG NY, *et al.* Prediction of knee joint moment by surface electromyography of the antagonistic and agonistic muscle pairs [J]. IEEE Access, 2019, 7: 82320-82328.
- [5] 连西静, 崔升. 基于特征融合的人体运动识别[J]. 医用生物力学, 2019, 34(6): 644-649.
- [6] 桂奇政, 孟明, 马玉良, 等. 基于肌肉协同激活模型的上肢关节运动连续估计[J]. 仪器仪表学报, 2016, 37(6): 1405-1412.
- [7] CHAI Y, LIU K, LI C, *et al.* A novel method based on long short term memory network and discrete-time zeroing neural algorithm for upper-limb continuous estimation using sEMG signals [J]. Biomed Signal Proces, 2021, 67: 102416.
- [8] ZHANG L. An upper limb movement estimation from electromyography by using BP neural network [J]. Biomed Signal Proces, 2019, 49: 434-439.
- [9] BU D, GUO S, GAO W, *et al.* Continuous Estimation of a sEMG-Based Upper Limb Joint [C]//Proceedings of 16th IEEE International Conference on Mechatronics and Automation (IEEE ICMA). Tianjin: IEEE, 2019: 904-909.
- [10] TANG G, SHENG JQ, WANG DM, *et al.* Continuous estimation of human upper limb joint angles by using PSO-LSTM model [J]. IEEE Access, 2021, 9: 17986-17997.
- [11] ZHANG Q, LIU RF, CHEN WB, *et al.* Simultaneous and continuous estimation of shoulder and elbow kinematics from surface EMG signals [J]. Front Neurosci, 2017, 11: 280.
- [12] CHEN J, ZHANG X, CHENG Y, *et al.* Surface EMG based continuous estimation of human lower limb joint angles by using deep belief networks [J]. Biomed Signal Proces, 2018, 40: 335-342.
- [13] 刘鹏, 葛小青, 李宇, 等. 上肢康复机器人主动康复训练控制策略[J]. 中国科学院大学学报, 2019, 36(4): 570-576.
- [14] NURHANIM K, ELAMVAZUTHI I, IZHAR LI, *et al.* Development of a model For sEMG based joint-torque estimation using swarm techniques [C]//Proceedings of 2nd IEEE International Symposium on Robotics and Manufacturing Automation (IEEE-ROMA). Ipoh: IEEE, 2016.
- [15] WANG WQ, SHI WG, HOU ZG, *et al.* Prediction of human voluntary torques based on collaborative neuromusculoskeletal modeling and adaptive learning [J]. IEEE T Ind Electron, 2021, 68(6): 5217-5226.
- [16] HUANG SY, CAI SQ, LI GF, *et al.* Variable robot-resistance rehabilitation for upper limb based on an sEMG-Driven Model [C]//Proceedings of IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). Hong Kong: IEEE, 2019: 814-818.
- [17] WANG C, PENG L, HOU ZG, *et al.* sEMG-based torque estimation using time-delay ANN for control of an upper-limb rehabilitation robot [C]//Proceedings of IEEE International Conference on Cyborg and Bionic Systems (CBS). Shenzhen: IEEE, 2018: 585-591.
- [18] 陈江城, 张小栋, 李睿, 等. 利用表面肌电信号的下肢动态关节力矩预测模型 [J]. 西安交通大学学报, 2015, 49(12): 26-33.
- [19] ZHANG Y, ZHANG XD, LU ZF, *et al.* A novel wrist joint torque prediction method based on EMG and LSTM [C]//Proceedings of 10th Institute-of-Electrical-and-Electronics-Engineers International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER). Xi'an: [s. n.], 2020: 242-245.
- [20] SIU HC, SLOBODA J, MCKINDLES RJ, *et al.* A Neural network estimation of ankle torques from electromyography and accelerometry [J]. IEEE T Neur Sys Reh, 2021, 29: 1624-1633.