

DOI: 10.19650/j.cnki.cjsi.J2210124

# 基于 sEMG 信号的关节力矩 NARX 预测模型\*

刘 强<sup>1,2</sup>, 李玉榕<sup>1,2</sup>, 杜国川<sup>1,2</sup>, 连章汇<sup>1,2</sup>

(1. 福州大学电气工程与自动化学院 福州 350108; 2. 福建省医疗器械和医药技术重点实验室 福州 350108)

**摘要:**为解决利用力矩传感器控制肌力训练设备所带来的滞后性,利用表面肌电信号(sEMG)超前于运动的特性,设计了一组拮抗肌表面肌电信号的关节力矩预测模型。首先搭建康复训练设备为信号采集和实验验证提供条件。将sEMG经过预处理,选择sEMG信号的方差特征作为神经网络输入,利用带有外部输入的非线性自回归(NARX)模型的动态循环神经网络,分别建立了基于关节力矩实际值的超前多步(MSA)预测模型和基于模型预测输出(MPO)的预测模型,通过等张和等长测试实验,比较了MSA和MPO模型的力矩预测性能。实验结果表明,两种模型输出预测值和实际值之间都有极强关联性(皮尔逊相关系数均大于0.95)。随着超前预测的步数增加,MSA模型的预测精度降低,但是超前预测的时间增大。在等张和等长测试中,当超前步数分别小于29和35时,MSA预测精度显著高于MPO( $p < 0.05$ ),但MPO模型在成本和体积上更具优势。综上所述,两种模型均可以准确预测关节力矩,在实际康复训练设备控制中,可根据应用需求选择不同的力矩预测模型。

**关键词:** sEMG; NARX; 多步超前预测模型; 模型预测输出

**中图分类号:** TP391.4 TH77 **文献标识码:** A **国家标准学科分类代码:** 510.40

## NARX prediction model of joint torque based on sEMG signal

Liu Qiang<sup>1,2</sup>, Li Yurong<sup>1,2</sup>, Du Guochuan<sup>1,2</sup>, Lian Zhanghui<sup>1,2</sup>

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. Fujian Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou 350108, China)

**Abstract:** To solve the hysteresis caused by using torque sensors to control muscle force training equipment, a joint torque prediction model based on a group of antagonistic surface electromyography (sEMG) is designed in this article. Firstly, the rehabilitation training equipment is built to provide conditions for signal acquisition and experimental verification. sEMG is preprocessed and the variance characteristic of sEMG signal is selected as the neural network input. In addition, a dynamic recurrent neural network with the nonlinear auto-regressive model with exogenous inputs (NARX) is used in this study. A multi-step ahead prediction model (MSA) based on the actual values of joint moments and another model based on model prediction output (MPO) are developed respectively. The torque prediction performance of MSA and MPO models is compared by isotonic and isometric test experiments. Experimental results show that there is a strong correlation between the predicted output value and the actual output value of the two models (Pearson correlation coefficient is greater than 0.95). As the number of advance prediction steps increases, the prediction accuracy of MSA model decreases. However, the advance prediction time increases. When  $n$  is less than 29 and 35, the prediction accuracy of MSA is significantly higher than that of MPO ( $p < 0.05$ ). But the MPO model has advantages in cost and size. In summary, two models proposed in this article can accurately predict joint torques. In actual rehabilitation training equipment control, different torque prediction models can be selected according to application requirements.

**Keywords:** sEMG; NARX; multi-step ahead prediction model; model prediction output

## 0 引言

我国脑卒中发病率整体呈现出上升趋势,每年新发脑卒中患者数量约为120万,致残率高达75%<sup>[1]</sup>。此外,人口老龄化导致的肢体运动障碍患者数量增加。康复训练可以增强肢体功能障碍者的活动能力以及加快运动神经受损患者的神经恢复。我国康复需求量巨大,但康复医疗资源紧缺,康复设备的出现满足了肢体障碍患者的需要,减轻了康复医师的工作负担。

一般肌力训练有等张、等速、等长等主动训练模式以及被动训练模式等<sup>[2-3]</sup>。在主动训练中如果康复设备不能根据患者的运动意图(即主动力矩)及时调整输出,会给患者带来极大的不舒适感,严重时可能造成二次伤害;在被动训练时,患者如果在训练时发生肌肉痉挛,肌张力升高,对训练设备施加的力矩变大,若训练设备无法检测到突变的力矩,强行带动关节运动,会给患者带来二次伤害,所以目前大多数康复训练设备的控制信号是基于力矩传感器检测值进行控制。文献[4]设计一套基于伺服电机的上肢康复设备力矩交互控制系统,将力矩传感器信号通过变送处理后传输给主控电路,以此控制电机转动力矩。文献[5-6]提出了一种基于阻抗控制的康复设备主动训练控制策略,根据检测到的人机接触关节力矩调整康复设备的位置实现阻抗控制。文献[7]发明专利是通过电阻应变片来检测肢体的肌力方向和大小,由控制板控制电机输出和肢体等大反向的作用力来维持等速运动。从关节力矩的产生原理可知,传感器检测到的关节力矩信号是由肌肉收缩力而产生的,滞后于大脑的主动运动意愿,加上信号处理和电机控制所需的时间,使得训练设备辅助产生的关节运动滞后于用户的运动意图,用户体验感较差,而且从神经可塑性理论来说,也不利于患者神经功能重塑。

表面肌电信号(surface electromyography, sEMG)是神经系统产生的神经冲动通过神经系统传递到神经末梢时,肌纤维膜电位发生变化产生的动作电位叠加在皮肤表面形成的微弱信号。在皮肤表面检测到的肌电信号比肌肉实际收缩超前30~200 ms<sup>[8]</sup>。且sEMG具有无损伤性,检测结果重复性好<sup>[9]</sup>等特点,利用sEMG预测关节力矩可以让康复设备有足够的控制时间,提高用户体验感和训练安全性,促进大脑神经系统重塑。

近年来,越来越多康复设备将sEMG引入其中作为控制信号。利用sEMG的超前性预测人体的动作意图,转化为力矩或关节角度等动力学或运动学参数驱动康复设备动作。文献[10]利用sEMG和广义回归神经网络对手部输出力进行估计,比较了不同域特征值对估计结

果的影响。文献[11]将踝关节周围的胫骨前肌和腓肠肌的sEMG作为输入,经过神经-肌肉模型计算出肌肉激活度,利用Hill模型将肌肉激活度转化为关节力矩。文献[12]设计了一款用于偏瘫或截瘫患者的康复治疗的机器人,通过sEMG计算出关节运动角速度后作为阻尼型速度控制器的输入控制机器人运动速度。文献[13]提出了一种基于sEMG信号的人机协作控制方法,利用Hill模型建立关节力矩估计模型,使用回归方法将sEMG与关节角度合并来估计关节的期望力矩,以驱动上肢外骨骼根据佩戴者的运动意图进行动作。综上所述引入sEMG可以实现更自然的人机交互,但当前的研究主要集中在基于sEMG信号识别动作、步态等离散状态,对关节角度、力矩等连续信号的估计较多采用基于机理的方法,存在建模复杂,计算时间过长难以保证实时性等问题。相比于其他复杂的力矩预测方法,利用离线训练好神经网络进行关节力矩在线预测,既能保证精度又能保证计算的实时性。

本文从sEMG的生理特性出发,对sEMG进行滤波和特征值提取后,利用带有外部输入的非线性自回归(nonlinear auto-regressive model with exogenous inputs, NARX)模型的动态循环神经网络拟合sEMG与关节力矩之间的关系,实现基于sEMG实时预测关节力矩,为后续利用预测关节力矩实现训练设备控制打下基础。本文建立了两类关节力矩预测模型:1)基于关节力矩实际值的超前多步(multi-step ahead, MSA)预测模型;2)基于模型预测值输出(model predicted output, MPO)的闭环模型。MSA模型可以在已知前期力矩值的情况下实现超前多步预测,提高设备的超前控制时间。MPO用于无力矩传感器的情况下,实现力矩估计。

## 1 康复训练设备

本文设计的康复训练设备结构如图1所示,硬件包括机电传感器(1205 T,丹阳假肢厂有限公司),力矩传感器(T908B,常州瑞尔特测控系统有限公司),增量式编码器(NH4-17LS65CAT,台达有限公司),伺服电机(ECM-E2M,台达有限公司)以及相应的驱动器(ASDA-B2,台达有限公司),关节支撑件以及关节训练时所需要的配件,主控芯片采用STM32F4。

康复训练设备能完成等速,等长,等张和被动训练。等张训练要求在整个训练过程中阻力矩保持不变<sup>[14]</sup>,当受试者肌肉收缩产生的关节力矩大于设定的阻力矩,受试者关节开始运动。等速训练时要求训练装置允许受试者加速至不超过每个方向所选择的最大转动速度<sup>[14]</sup>。等长训练要求关节保持静止,但要求肌肉以最大等长收缩向不同方向发力。




图 1 康复训练设备

Fig. 1 Muscle strength training platform

被动训练要求由设备带动受试者关节在设定的范围内保持设定的速度运动,在此过程中,因无需肌肉主动发力,所以检测到的力矩较小,但肌肉发生痉挛时肌张力和肌电信号幅值升高<sup>[15]</sup>,对设备施加的阻力变大,当阻力矩大于一定阈值时判断为痉挛发生,从而快速停止保护关节不受二次伤害。

## 2 肌电信号的采集和处理

### 2.1 sEMG 采集与滤波

一组拮抗肌的双通道 sEMG 经过硬件电路滤波,放大和电压抬升之后,将原来微弱信号放大 1 000 倍至  $-3 \sim 3$  V,后通过 ADC 模块转换成数字信号,保留在直接存储器中,控制采样频率为 1 000 Hz。

由 sEMG 产生的机理和特点可知,sEMG 是一种不稳定且十分微弱的电信号。在利用金属电极采集 sEMG 时,不可避免受到来自外界环境和采集设备元件的干扰。这些干扰信号主要如下:1) 环境中干扰信号,这类干扰主要来自电机运行时的电磁干扰(高频干扰信号)和交流电源工频干扰信号(50 Hz 工频干扰信号)<sup>[16]</sup>,信号输入口残余的漂移电压等;2) 表贴电极和皮肤在肌肉收缩时的相互移动,从而引入的伪影噪声和基线漂移。这类信号主要集中在 10 Hz 以下的低频段。

因为 sEMG 信号频率集中在 10~500 Hz,根据干扰信号的频率特性,本文设计了 IIR 50 Hz 陷波器去除工频干扰和 IIR 巴特沃斯 10~500 Hz 带通滤波器去除 sEMG 的基线漂移和低频电磁干扰信号。

### 2.2 SEMG 特征值提取

sEMG 的特征提取通常有时域方法、频域方法、时频域方法,为降低运算复杂度,保证计算的快速性,本文提取 sEMG 的时域特征。通过比较,选取 sEMG 的方差作为时域信号特征值,如下:

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (sEMG(i) - sEMG_m)^2 \quad (1)$$

式中:sEMG<sub>m</sub> 表示滑动窗口内 sEMG 的平均值;VAR 可以反映表面肌电信号的幅度变化,VAR 越大,幅度变化越大,在一定程度上反映肌肉活动<sup>[10]</sup>。

肌电信号超前于实际动作的时间为 30~200 ms<sup>[8]</sup>,为保证用户无滞后感地进行训练,设备控制系统的响应时间应在 30~200 ms。窗长选取过小会降低模型预测精度,窗长过大又会导致设备响应时间长,因此本文利用带有重叠的滑动窗方法以提高实时性。考虑到 sEMG 的采样频率为 1 000 Hz,多次比较不同窗长对神经网络预测结果影响后,最终设置滑动窗口的长度设为 180 个单位,即窗长为 180 ms,每次平移一个单位,重叠窗长为 1 ms,即每 1 ms 在 180 ms 窗口内计算一次特征值,其工作过程如图 2 所示。




图 2 滑动窗口原理

Fig. 2 Sliding window principle

## 3 基于表面肌电信号的力矩预测

选取复杂模型预测关节力矩会导致计算时间过长难以保证预测力矩的超前性,所以在预测模型选择上需要兼顾预测精度和实时性,NARX 模型具有良好的动态特性及较高的抗干扰能力<sup>[17]</sup>。

### 3.1 基于 Multi-Step Ahead 模型的力矩预测

NARX 是一个动态循环网络,通过利用带时序的输入和输出的非线性函数来预测系统输出的当前值<sup>[18]</sup>。该网络有两种形式,一种是基于输出的实际测量值  $T_k$  的 NARX 模型,称为基于 NARX 的 MSA。

首先建立超前一步预测模型如下:

$$\hat{T}_{k+1} = f(T_k, T_{k-1}, \dots, T_{k-q+1}, u_k, u_{k-1}, \dots, u_{k-p+1}) \quad (2)$$

式中: $p$ 、 $q$  分别为输入和输出阶数; $u_k$  为 sEMG 特征输

入。递归计算  $n$  次得到 MSA 模型:

$$\hat{T}_{k+n} = \begin{cases} f(T_k, T_{k-1}, \dots, T_{k-q+1}, u_k, \\ u_{k-1}, \dots, u_{k-p+1}), & n = 1 \\ f(\hat{T}_{k+n-1}, \dots, \hat{T}_{k+1}, T_k, \dots, T_{k-q+n}, \hat{u}_{k+n-1}, \dots, \\ \hat{u}_{k+1}, u_k, \dots, u_{k+n-p}), & 2 \leq n \leq \min(p, q) \\ f(\hat{T}_{k+n-1}, \dots, \hat{T}_{k+1}, T_k, \dots, T_{k-q+n}, \hat{u}_{k+n-1}, \dots, \\ \hat{u}_{k+n-p}), & p < n < q + 1 \\ f(\hat{T}_{k+n-1}, \dots, \hat{T}_{k+n-q}, \hat{u}_{k+n-1}, \dots, \hat{u}_{k+1}, u_k, \dots, \\ u_{k+n-p}), & q < n < p + 1 \\ f(\hat{T}_{k+n-1}, \dots, \hat{T}_{k+n-q}, \hat{u}_{k+n-1}, \dots, \\ \hat{u}_{k+n-p}), & \max(p + 1, q + 1) \leq n \end{cases} \quad (3)$$

式中:  $\hat{T}_k$  为预测力矩,  $\hat{u}_k$  为 sEMG 特征预测值,  $n$  为超前步数。

其中输入预测值  $\hat{u}$  由线性自回归模型 (autoregressive, AR) 预测为:

$$\hat{u}_{k+h} = \begin{cases} a_1 u_k + a_2 u_{k-1}, \dots, a_d u_{k-d+1}, & h = 1 \\ a_1 \hat{u}_{k+h-1} + a_2 \hat{u}_{k+h-2}, \dots, a_h \hat{u}_k + \\ a_{h+1} u_{k-1}, \dots, a_d u_{k+h-d}, & 2 \leq h \leq d \\ a_1 \hat{u}_{k+h-1} + a_2 \hat{u}_{k+h-2}, \dots, + \\ a_d \hat{u}_{k+h-d}, & d + 1 \leq h \end{cases} \quad (4)$$

式中:  $d$  为 AR 模型阶数, 定阶准则用最小信息准则 (akaike information criterion, AIC), 根据准则求得的估计量越小阶数越优并确定最佳阶数。  $\sigma$  为噪声,  $a_i$  为参数序列,  $a_i$  的具体参数由最小二乘法确定。

关节力矩在采样过程中采集的并不是净关节力矩, 还包含关节配件的重力矩, 本文采用实际采样的关节配件重力矩进行补偿, 将关节配件安装在减速机构上自转一周, 采集每个角度所对应重力矩的大小和方向, 保存在重力补偿矩阵中, 如图 3(a) 所示, 实际运用中根据当前角度输出一个补偿力矩用于抵消采样关节力矩值中配件重力矩的影响。

多层前馈网络一般由数据输入层、隐含层 (hidden layer), 单隐含层或者多隐含层与模型输出层组成。多层前馈网络有较高的非线性映射能力, 本文利用多层前馈网络结合 NARX 模型形成基于 NARX 模型的动态循环神经网络 (dynamic recurrent neural network, DRNN), 进行关节力矩预测, 本文采用单隐含层的多层前馈神经网络。

1-Step Ahead 神经网络模型如图 3(a) 所示, 利用控制关节运动的一对拮抗肌的 sEMG 信号和重力补偿后的力矩实际值建立基于 NARX 神经网络的力矩预测模型。其中  $e_{1,k}$  和  $e_{2,k}$  分别为经过预处理后的肱二头肌和肱三头肌的 sEMG 信号, 分别经过特征值处理计算出特征值  $a_{1,k}$  和  $a_{2,k}$ , 得到输入  $u_k = [a_{1,k}, a_{2,k}]^T$ 。DRNN 的输入为  $u_k$  和重力补偿后的实际力矩的前几个时刻力矩  $T_k$ ,  $z^{-1}$  表示前一单位时间的输入或者输出,  $\theta_k$  为角度信号,  $T_0$  为补偿力矩。  $T_r$  为传感器检测到的力矩。根据式 (3) 和 (4), 由多个超前 1 步预测模型串联形成 MSA, 实现超前多步预测。

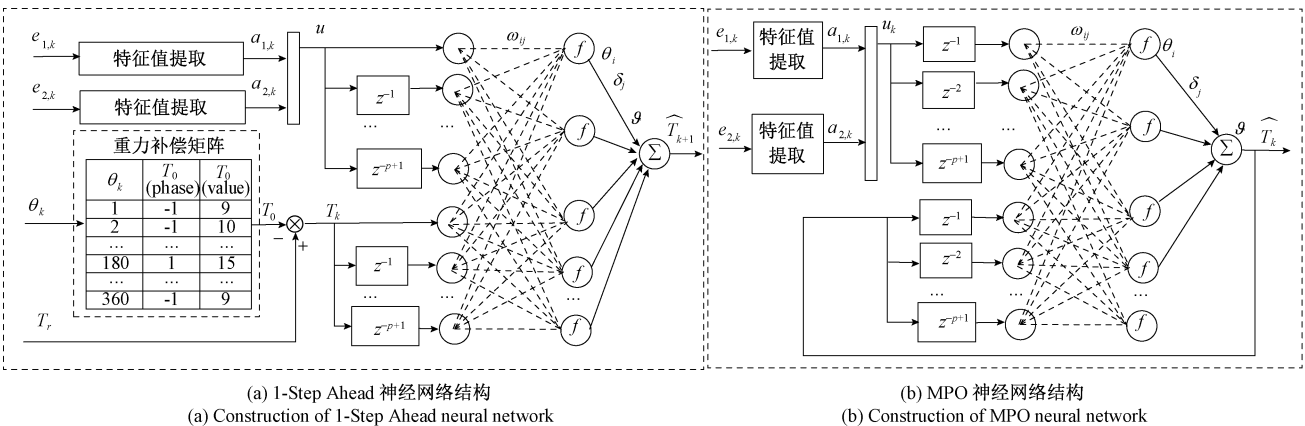


图3 NARX 神经网络结构

Fig. 3 Construction of the NARX neural network

### 3.2 基于 MPO 模型的力矩预测

由于力矩传感器较为笨重, 为缩小设备体积并节约成本, 在设备的硬件结构上可以舍弃力矩传感器, 此时可采用另一种基于模型预测输出值  $\hat{T}_k$  的 NARX 模型, 称为 MPO。

$$\hat{T}_k = f(\hat{T}_{k-1}, \hat{T}_{k-2}, \dots, \hat{T}_{k-q+1}, u_{k-1}, u_{k-2}, \dots, u_{k-p+1}) \quad (5)$$

如图 3(b) 所示, MPO 模型利用控制肘关节运动的一对拮抗肌 (肱二头肌和肱三头肌) 的 sEMG 信号  $u_k$  和关节力矩预测值  $\hat{T}_k$  作为输入。MPO 模型参数设置与

MSA 相同,不同之处在于,MPO 将前期时刻的实际值力矩替换为基于模型输出预测值,作为模型输入。

MPO 基于模型前几个时刻的预测值进行输出,而 MSA 模型将前几个时刻力矩的实际值纳入模型结构之中,预测的精度更高。神经网络离线训练在 MATLAB 平台中完成,隐含层节点数设置为 6,利用 Levenberg-Marquardt 算法训练。输入阶数  $p=2$ ,输出阶数  $q=2$ 。训练精度为  $1 \times 10^{-6}$ ,最大训练次数为 500 次。

### 4 实验结果与分析

#### 4.1 实验流程

本文的实验流程如图 4 所示,利用已搭建好的康复训练设备采集相关信号,将 sEMG 进行数字信号滤波和特征值提取之后输入到 NARX 神经网络中进行离线训练,训练完成后导出参数模型并进行在线预测。将脉冲信号通过软件 4 倍频法采样转换为角度信号,输入到重力补偿矩阵中计算出补偿力矩,以消除重力矩干扰。

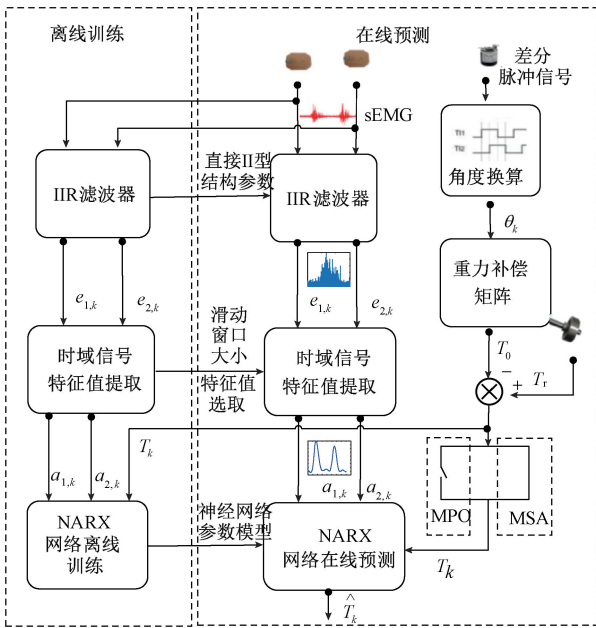


图 4 关节力矩预测流程

Fig. 4 Flow chart of joint torque prediction

#### 4.2 数据采集与评价指标

募集 4 位健康受试者参与实验,受试者没有神经肌肉紊乱、疼痛的病史,也没有接受上肢定期训练的经历,具体受试者信息如表 1 所示。

试验包括等张测试和等长测试。在等张测试中,屈伸时收缩形式设置为向心收缩,负荷设置为  $3 \sim 12 \text{ N} \cdot \text{m}$ ,

表 1 受试者信息

Table 1 Subject information

用户名	年龄	身高/cm	体重/kg	性别
S1	24	171	74	男
S2	24	173	72	男
S3	22	174	67	男
S4	25	172	65	男

在肘关节限位之间轮流进行肘关节 5 次屈伸运动。等长测试时将肘关节屈曲角度分别固定在距离水平位置  $30^\circ \sim 120^\circ$  的位置,以自主意愿和向内和向外方向以最大等长收缩力轮流发力,每次实验在每个角度下完成 5 次发力。采集 sEMG 和关节力矩等信号,前 3 个周期为训练集,后 2 个周期作为测试集。

本文使用归一化的均方根误差(normalized root mean square error, NRMSE)和皮尔逊相关系数  $\rho$  两个指标进行关节力矩预测性能的评估,通过双样本 t 检验的方法评估不同模型预测误差的统计差异, $p < 0.05$  表现出显著性。

#### 4.3 信号预处理和特征值处理结果

图 5 所示为受试者 S1 屈伸动作时肱二头肌的 sEMG,其中实线波形表示原始的 sEMG,虚线波形表示滤波后的 sEMG,滤波后的 sEMG 既可以滤除肌肉静息时段多余的干扰信号,又可以保留肌肉收缩时 sEMG 的幅值特征和频率特征。




图 5 归一化后的肱二头肌 sEMG

Fig. 5 Normalized biceps sEMG

肱二头肌和肱三头肌 sEMG 的 VAR 和肘关节屈伸过程中的归一化力矩如图 6 所示。sEMG 经过特征值提取之后可以更直观看幅值变化规律,肱二头和肱三头肌 sEMG 的特征量 VAR 波峰交替出现。从图 6 可以看出肱三头肌幅值特征值变化与伸肘时的力矩信号幅值变化有正相关变化趋势,肱二头肌幅值特征值变化与屈肘时的力矩信号幅值变化呈现负相关。




图6 屈伸时 sEMG 特征值与力矩关系

Fig. 6 Envelope diagram and activity segment division

#### 4.4 关节力矩预测试验结果

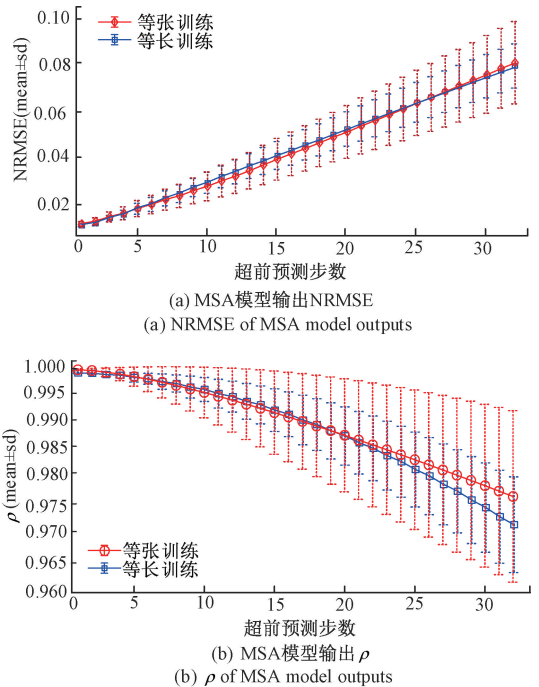
##### 1) Multi-Step Ahead 模型预测结果

本文对 MSA 模型预测误差进行分析,试验结果表明所有受试者在等张测试和等长测试中预测输出值和实际值相关系数  $\rho$  均大于 0.95,表示预测值和实际值之间极强相关。所有受试者在等长测试和等张测试模式下 MSA 模型的预测 NRMSE 均值(mean)和标准差(sd)如图 7(a)所示,对比等张测试所有受试者在所有负荷时的 NRMSE 和等长测试时所有受试者在所有角度的 NRMSE,两者的预测误差均随着超前预测的步数增加而增加;所有受试者在等长测试和等张测试模式下,MSA 模型的预测值和实际值间的相关系数  $\rho$  的均值和标准差如图 7(b)所示,相关系数均随着超前预测的步数增加而降低。

##### 2) MPO 与 MSA 预测结果对比

不同负荷等张测试和不同角度等长测试时,两种模型的预测值和实际值之间的 NRMSE 分别如图 8(a)和(b)所示。随着超前预测的步数增加,MSA 模型的 NRMSE 增大,预测精度降低。在等张和等长测试中,当超前步数分别小于 29 和 35 时,MSA 预测精度显著高于 MPO( $p < 0.05$ )。

不同负荷的等张测试和不同角度的等长测试下的两种模型的预测值和实际值之间的相关系数  $\rho$  如图 8(c)和(d)所示。随着超前预测的步数增加,MSA 模型的  $\rho$  减小,预测精度降低。在等张和等长测试中,当超前步数分别小于 29 和 35 时,MSA 预测精度显著高于 MPO ( $p < 0.05$ )。但 MPO 预测值与真实值的相关系数均已超过 0.95,表示预测值和实际值之间极强相关。

图7 等张测试和等长测试 MSA 模型输出 NRMSE 和  $\rho$ Fig. 7 NRMSE and  $\rho$  of MSA in isotonic and isometric test

MSA 和 MPO 模型的关节力矩输出结果如图 9 所示。其中图 9(a)、(b)为不同负荷等张测试和不同角度等长测试时 1-Step Ahead 模型预测的关节力矩结果,虚线表示 1-Step Ahead 模型的预测结果,实线表示经过重力补偿后的肘关节力矩实际值。图 9(c)、(d)为 29-Step Ahead 模型和 35-Step Ahead 模型预测的关节力矩预测结果,虚线表示 MSA 模型的预测结果,实线表示经过重力补偿后的肘关节力矩实际值。图 9(e)、(f)为不同负荷等张测试和不同角度等长测试时 MPO 模型预测的关节力矩结果,虚线表示 MPO 模型的预测结果,实线表示经过重力补偿后的肘关节力矩实际值。1-Step Ahead 模型输出的预测值相较于 MPO 模型输出预测值更加贴近实际值,但随着超前预测的步数增加,MSA 模型的预测精度不断下降,随着预测误差的累积,曲线预测值与实际值之间的偏移越来越大。在等长和等张测试中,当  $n$  分别为 29 和 35 时 MSA 模型与 MPO 模型预测精度无显著差异。

本文在 MATLAB 平台进一步验证算法的实时性,将 1-Step Ahead 和 MPO 模型分别迭代 10 000 次后计算其运行时间,并取平均值,完成 1-Step Ahead 或 MPO 所需时间约为 0.003~0.004 ms,远低于本文采用的滑窗重叠步长 1 ms。当递归进行 MSA 预测时,当达到与 MPO 相近的性能时(超前步数为 29 或 35 步),其运算时间仍远低于 1 ms,因此每超前一步,可以提供接近 1 ms 的超前时间用于设备控制。

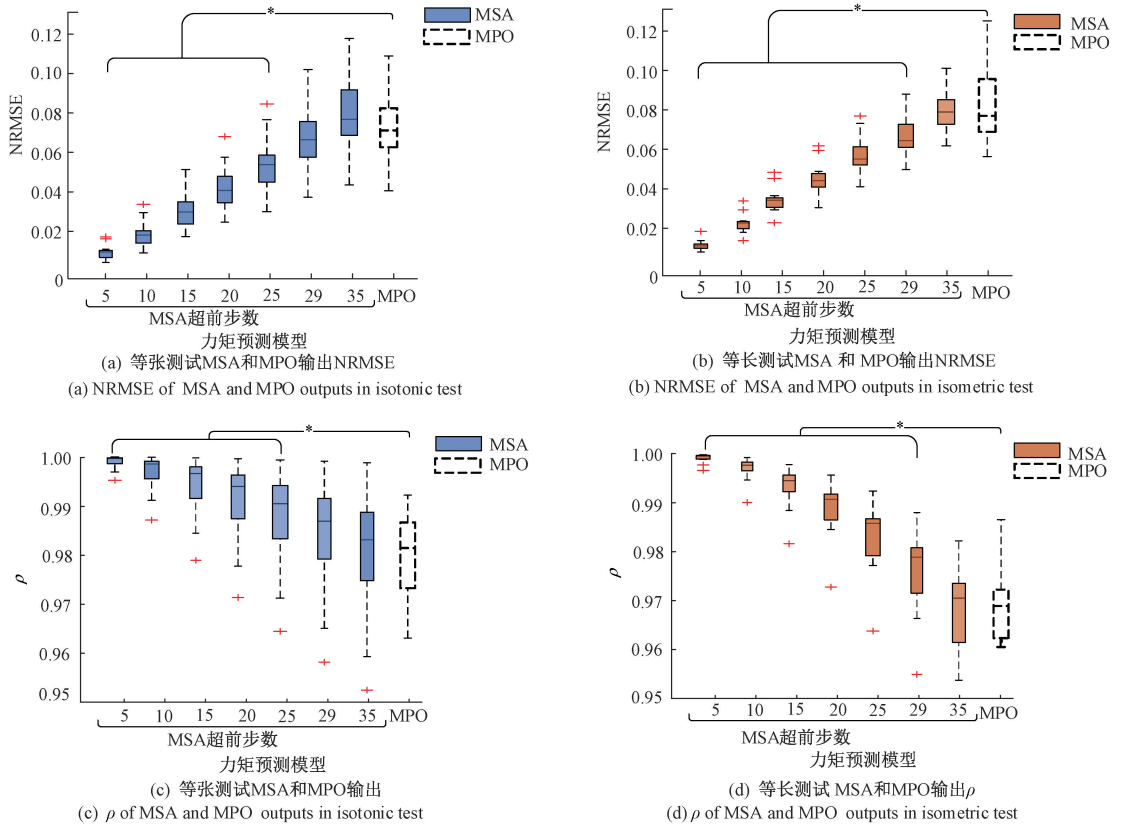


图 8 等张和等长测试模式下所有受试者 MSA 和 MPO 模型预测的 NRMSE 和  $\rho$  (\* :  $p < 0.05$ )

Fig. 8 NRMSE and  $\rho$  of MSA and MPO for all subjects in isometric and isometric test modes (\* :  $p < 0.05$ )

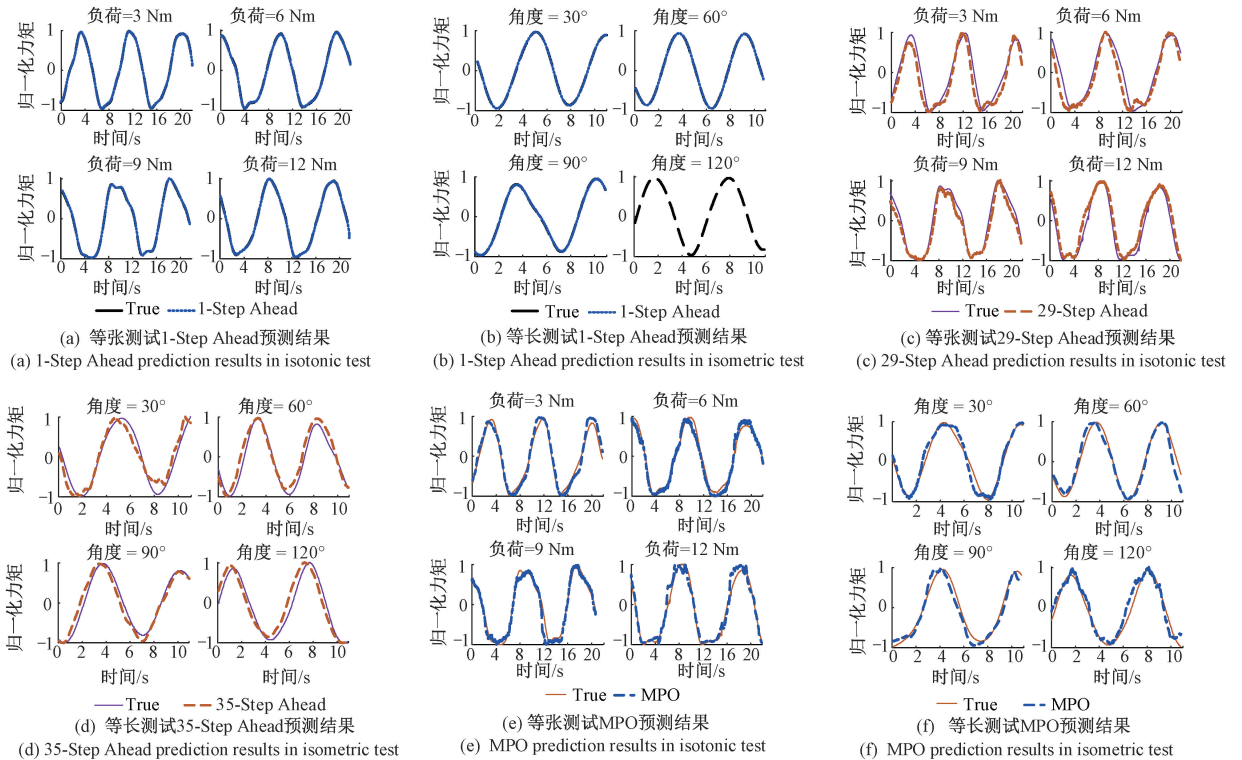


图 9 NARX 模型关节力矩预测结果

Fig. 9 Results of NARX model joint torque prediction

## 5 结 论

本文通过搭建康复训练设备,采集人体生理信号,利用基于 NARX 模型的动态循环神经网络建立了基于关节力矩实际值的超前多步预测模型 MSA,以及基于模型预测值输出的闭环模型 MPO。最后通过设计的关节等张测试实验和等长测试实验验证了关节力矩预测模型的实际预测效果。从实验结果可以看出两种模型的预测精度均较高,实际值与预测值之间的相关系数大。

MSA 模型随着预测的步长增加,模型的预测精度不断下降,预测误差不断升高,但是超前多步预测可以提高设备超前控制的时间,给予设备充分的反应时间。从模型结构来看,MPO 模型仅需要肌电信号作为输入,而 MSA 模型输入除了肌电信号,还需要前几个时刻的实际关节力矩,在设备硬件组成上需要力矩传感器。所以为减小设备体积并节约成本,利用商业标准设备离线训练好 MPO 模型,对关节力矩实时预测并控制肌力训练设备更具有优势。随着患者运动状态的改善,可利用商用标准设备采集数据,进一步修正神经网络模型减小误差。

综上所述,本文提出的两种模型均可以准确预测关节力矩并且在算法运行上具有良好的实时性,在实际运用中可以根据不同的应用场景选择不同的力矩预测模型并运用到肌力训练设备的控制中。

## 参考文献

- [ 1 ] 王陇德,毛群安,张宗久. 中国脑卒中防治报告[M]. 北京:人民卫生出版社,2018.  
WANG L D, MAO Q AN, ZHANG Z J. Stroke prevention and treatment in China [M]. Beijing: People's Medical Publishing House, 2018.
- [ 2 ] AKHMAD F W, CHENG W T. Isotonic and isometric exercise interventions improve the hamstring muscles' strength and flexibility: A narrative review [J]. Healthcare, 2022, 10:811-820.
- [ 3 ] GRBIC V, DJURIC S, KNEZEVIC O, et al. A novel two-velocity method for elaborate isokinetic testing of knee extensors[J]. International Journal of Sports Medicine, 2017, 38(10):741-746.
- [ 4 ] 蒲明辉,尹飞,赵倩倩,等. 卧式下肢康复机器人主动训练控制策略[J]. 机械设计与研究, 2021, 37(1): 66-70.  
PU M H, YIN F, ZHAO Q Q, et al. Active training control strategy for horizontal lower limb rehabilitation robot[J]. Machine Design and Research, 2021, 37(1): 66-70.
- [ 5 ] 王晓峰,李醒,王建辉. 基于无模型自适应的外骨骼式上肢康复机器人主动交互训练控制方法[J]. 自动化

学报, 2016, 42(12):1899-1914.

WANG X F, LI X, WANG J H. Active interaction exercise control of exoskeleton upper limb rehabilitation robot using model-free adaptive methods [J]. Acta Automatica Sinica, 2016, 42(12):1899-1914.

- [ 6 ] 吴青聪,张祖国. 基于屏障 Lyapunov 函数的上肢康复机器人自适应主动交互训练控制[J]. 仪器仪表学报, 2022, 43(2):216-224.  
WU Q C, ZHANG Z G. Adaptive active interactive training control of upper limb rehabilitation robot based on barrier Lyapunov function [J]. Chinese Journal of Scientific Instrument, 2022, 43(2):216-224.
- [ 7 ] 广州一康医疗设备实业有限公司. 一种等速肌力训练系统及其控制方法 [P]. CN108553834A, 中国, 2018-09-21.  
Guangzhou Yikang Medical Equipment Industry Co., Ltd. An isokinetic muscle strength training system and its control method [P]. CN108553834A, China, 2018-09-21.
- [ 8 ] DARIO F, MASSIMO S, DAVID G, et al. Neural data-driven musculoskeletal modeling for personalized neurorehabilitation technologies [J]. IEEE Transactions on Biomedical Engineering, 2016, 63(5):879-893.
- [ 9 ] IRSA T, KENNETH S, KIANG L C, et al. A review on crosstalk in myographic signals[J]. European Journal of Applied Physiology, 2019, 119(1):9-28.
- [ 10 ] 吴常铖,宋爱国,曾洪,等. 基于 sEMG 和 GRNN 的手部输出力估计[J]. 仪器仪表学报, 2017, 38(1): 97-104.  
WU CH CH, SONG AI G, ZENG H, et al. Force estimation based on sEMG and GRNN [J]. Chinese Journal of Scientific Instrument, 2017, 38(1):97-104.
- [ 11 ] DI A, RONG S, GAO J W. Movement performance of human-robot cooperation control based on EMG-driven hill-type and proportional models for an ankle power-assist exoskeleton robot [J]. Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(8): 1125-1134.
- [ 12 ] ZHANG F, HOU Z G, CHENG L, et al. iLeg-a lower limb rehabilitation robot: A proof of concept[J]. IEEE Transactions on Human-Machine Systems, 2016, 46(5):761-768.
- [ 13 ] LIU H, TAO J, LYU P, et al. Human-robot cooperative control based on sEMG for the upper limb exoskeleton robot [J]. Robotics and Autonomous Systems, 2020, 125: 103350.
- [ 14 ] GUILHEM G, A GUÉVEL, CORNU C. A standardization method to compare isotonic vs. isokinetic



eccentric exercises [J]. Journal of Electromyography & Kinesiology Official Journal of the International Society of Electrophysiological Kinesiology, 2010, 20 ( 5 ): 1000-1006.

- [15] 胡保华, 吴平平, 穆景颂, 等. 基于 sEMG 与 K-means 聚类的上肢痉挛状态定量评定方法 [J]. 电子测量与仪器学报, 2018, 32(6): 53-63.  
HU B H, WU P P, MU J S, et al. Quantitative evaluation method of upper limb spasticity based on sEMG signals and K-means clustering algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(6): 53-63.
- [16] 罗志增, 任晓亮. 表面肌电信号测试中工频干扰的抑制 [J]. 仪器仪表学报, 2005, 26(2): 193-195, 210.  
LUO ZH Z, REN X L. Suppression of power frequency interference in surface EMG signal measurement [J]. Chinese Journal of Scientific Instrument, 2005, 26(2): 193-195, 210.
- [17] EH A, AD B, MAS A, et al. Prediction of the droplet spreading dynamics on a solid substrate at irregular sampling intervals: Nonlinear auto-regressive eXo-genous artificial neural network approach (NARX-ANN) [J]. Chemical Engineering Research and Design, 2020, 156: 263-272.
- [18] WORDEN K, SURACE C, BECKER W. Uncertainty bounds on higher-order FRFs from Gaussian process NARX models [J]. Procedia Engineering, 2017, 199: 1994-2000.

## 作者简介



**Liu Qiang**

received his B. Sc. degree from Fuzhou University in 2020. He is currently a M. Sc. candidate at Fuzhou University. His main research interests include intelligent man-machine interface technology of sEMG, intelligent rehabilitation technology research and application.



E-mail: liyurong@ fzu. edu. cn

**Li Yurong** (Corresponding author) received her B. Sc. degree from Fuzhou University in 1994, M. Sc. degree and Ph. D. degree both from Zhejiang University in 1997 and 2001, respectively. She is currently a professor at Fuzhou University. Her main research interests include intelligent man-machine interface technology based on EEG and EMG signals, autonomously controlled motor function rehabilitation technology and equipment development, et al.

**刘强**, 2020 年于福州大学获得学士学位, 现为福州大学硕士研究生, 主要研究方向为肌电信号的智能人机接口技术, 智能康复技术的研究与应用。

E-mail: 951530291@qq.com

**李玉榕**(通信作者), 1994 年于福州大学获得学士学位, 1997 年于浙江大学获得硕士学位, 2001 年于浙江大学获得博士学位, 现为福州大学教授, 主要研究方向为基于脑电与肌电信号的智能人机接口技术、自主控制的运动功能康复技术与设备研发等。