

面向上肢康复的改进Hammerstein模型与最优迭代学习控制

霍本岩^{1†}, 李 祯¹, 刘艳红¹, 赵新刚², 张宇波¹

(1. 郑州大学 电气与信息工程学院, 河南 郑州 450001;

2. 中国科学院沈阳自动化研究所 机器人与智能系统全国重点实验室, 辽宁 沈阳 110169)

摘要: 功能性电刺激(FES)是一种临床上常用的康复技术,但目前基于FES的康复设备需要由康复医师根据经验控制,控制精度难以保证.本文使用参数递推辨识方法建立上肢肌骨系统的Hammerstein模型,进而提出了基于数据驱动Hammerstein模型的最优迭代学习控制方法.首先,分别使用神经网络(NN)、传递函数表示肌肉收缩过程中的招募曲线(IRC)与线性激活动态(LAD),建立预训练数据集并对模型参数进行递推辨识,从而建立上肢肌骨系统的改进 Hammerstein 模型;然后,根据模型的 IRC 与 LAD 分别设计 NN 非线性控制器与参数最优迭代学习控制器(POILC),得到NN与POILC串联控制器(NPOILC);最后,搭建上肢康复系统实验平台,招募5位受试者对所提出的方法进行实验验证.实验结果表明:相较于传统的PD型迭代学习控制器和多项式与POILC串联控制器,本文提出的NPOILC最终迭代的均方根误差分别由 8.02° 与 9.74° 降低至 4.87° ,分别下降了39.3%与50.0%;收敛迭代数分别由平均5.0次与4.3次减至3.4次,分别下降了32.0%与20.9%.实验结果验证了本文方法的有效性,实现了上肢康复系统的建模与控制,且具有较高的控制精度与较快的收敛速度.

关键词: 功能性电刺激; Hammerstein模型; 迭代学习控制; 上肢康复系统

引用格式: 霍本岩, 李祯, 刘艳红, 等. 面向上肢康复的改进Hammerstein模型与最优迭代学习控制. 控制理论与应用, 2026, 43(3): 585 – 593

DOI: 10.7641/CTA.2024.30836

Improved Hammerstein model and optimal iterative learning control for upper limb rehabilitation

HUO Ben-yan^{1†}, LI Zhen¹, LIU Yan-hong¹, ZHAO Xin-gang², ZHANG Yu-bo¹

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou Henan 450001, China;

2. State Key Laboratory of Robotics and Intelligent Systems, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang Liaoning 110169, China)

Abstract: Functional electrical stimulation (FES) is a widely used rehabilitation technique clinically. However, currently FES-based devices require control by rehabilitation physicians based on their experience, making it difficult to guarantee control accuracy. To solve this problem, this paper employs a recursive identification method of parameters to establish a Hammerstein model of the upper limb musculoskeletal system. And then, an optimal iterative learning control method based on this model is proposed. Initially, the neural network (NN) and a transfer function are used to represent the isometric recruitment curve (IRC) and linear activation dynamics (LAD) of muscles, respectively. A pre-trained dataset is established and the model parameters are recursively identified based on the dataset, establishing an improved Hammerstein model for the upper limb musculoskeletal system. Subsequently, a NN controller and a parameter optimal iterative learning controller (POILC) are designed based on the IRC and LAD of the model, respectively, resulting in the NN-POILC cascaded controller (NPOILC). Finally, an experimental platform is built, and five subjects are recruited to verify the proposed methods. The experimental results show that compared with PD-ILC and the Polynomial-POILC, the proposed NPOILC reduces the RMS error of the final iterations from 8.02° and 9.74° to 4.87° , marking a reduction of 39.3% and 50.0%, respectively. The experimental results verify the effectiveness of the method proposed in this paper, achieving modeling and control of the upper limb rehabilitation system, with higher control accuracy and faster convergence rate.

Key words: functional electrical stimulation; Hammerstein model; iterative learning control; upper limb rehabilitation system

Citation: HUO Benyan, LI Zhen, LIU Yanhong, et al. Improved Hammerstein model and optimal iterative learning control for upper limb rehabilitation. *Control Theory & Applications*, 2026, 43(3): 585 – 593

收稿日期: 2023–12–29; 录用日期: 2024–11–22.

[†]通信作者. E-mail: huoby@zzu.edu.cn; Tel.: +86 371-67783113.

本文责任编辑: 侯忠生.

国家重点研发计划项目(2022YFB4703203), 国家自然科学基金青年科学基金项目(62103376)资助.

Supported by the National Key Research & Development Project of China (2022YFB4703203) and the National Natural Science Foundation of China (62103376).

1 引言

脑卒中是指因脑血管病变引起的脑部缺血或出血的病症,也被称为中风.这种疾病可能导致脑部受损,从而影响正常的语言、视力、肢体运动等功能,甚至导致永久的残疾或死亡.2019年全球范围内脑卒中的新发病例为1220万例,现有病例1.01亿例,是世界第3大死亡和残疾原因^[1].卒中6个月后,只有18%的脑卒中幸存者恢复了完全运动功能^[2].运动康复治疗方法主要包括上肢和下肢的康复训练.相较于下肢的行走功能,上肢的运动更为复杂,运动功能的恢复较下肢也更为缓慢和困难.上肢主要承担复杂、精细、灵巧的动作,在日常生活中起着重要作用.帮助庞大的上肢肢体运动障碍患者群体重建运动功能具有重要意义.

功能性电刺激 (functional electrical stimulation, FES) 是治疗脑卒中患者肢体功能障碍的重要康复技术之一^[3]. FES通过一定强度的低频脉冲电信号刺激一组或多组肌肉,诱发肌肉运动,产生功能性运动(如伸手、抓握、托举等)^[4],以达到改善或恢复被刺激肌肉或肌群功能的目的.实验和临床治疗均证实, FES不仅可以促进主动运动、缓解肌肉痉挛、防止肌肉萎缩^[5],还可以促进大脑运动功能区神经元的重塑,最终达到康复治疗目的^[6].

目前基于 FES 的康复设备大多采用开环控制,刺激强度依赖康复师的经验,控制精度难以保证.迭代学习控制 (iterative learning control, ILC) 是一种利用历史迭代的跟踪误差和控制信号提高当前迭代控制性能的控制方法.对于 FES 康复系统, ILC 能充分利用患者重复进行训练产生的数据,是一种理想的控制方法.目前,已有许多 ILC 方法应用于 FES 的控制中,例如 Zhang 等人^[7]使用自适应网络模糊推理系统建立膝关节的关节肌肉模型,并使用无模型的 PID-ILC 对施加于股四头肌的 FES 进行控制; Zhang 等人^[8]提出了一种集成肌肉骨骼模型的迭代学习控制策略,利用肌骨模型确定合适的初始控制信号,加速了控制器的收敛; Huo 等人^[9]将患者的自主意愿视为输入干扰,针对上肢康复系统建立了一个简化线性名义模型,并基于该模型设计了一种变增益梯度 ILC 方法; 肌肉疲劳导致的模型精度下降会影响 ILC 的控制精度, Zhao 等人^[10]通过在 ILC 中加入遗忘因子,减少了历史迭代中失配模型对当前控制的影响; Sa-e 等人^[11]通过将表面肌电信号引入 ILC 的设计,研究了有患者自主意愿情况下的范数最优迭代学习控制方法.

上述控制方法中,无模型的 ILC 控制方法虽然不需要系统的先验知识,但收敛速度往往较慢^[12].较慢的收敛速度使得有效的康复训练次数减少,不利于患者的恢复,且多次电刺激易引发肌肉疲劳,进一步影响控制精度.基于模型的 ILC 往往控制精度更高,但却很

少被用于临床实践,主要原因是上肢电刺激肌骨模型非线性较强.肌肉不仅会受到痉挛和疲劳等时变影响,还对生理条件(包括皮肤阻抗、温度、湿度和电极放置)高度敏感,导致难以获得可靠的生物力学模型.

常用的肌肉模型有 Hammerstein 模型^[13]和 Hill 模型^[14],二者均为经验模型.相较于 Hill 模型,前者是一种模块化的模型,结构简单,能有效地反映非线性动态系统,常被用于 FES 的控制中^[9,11]. Hammerstein 模型的结构如图 1 所示.这个模型由静态非线性曲线和动态线性子模型串联而成.代表肌肉纤维募集特性的静态非线性曲线被称为等距招募曲线 (isometric recruitment curve, IRC).线性激活动态 (linear activation dynamics, LAD) 表示肌肉的收缩动态特性.常见的 IRC 参数化表示有饱和增益块、样条函数、分段线性函数、神经网络等.




图 1 Hammerstein 模型的结构

Fig. 1 Structure of Hammerstein model

Hammerstein 模型的参数通常根据输入输出数据进行辨识,其中的困难是非线性部分和线性部分之间的中间信号难以获得.解决这一问题的思路主要分为递推方法与非递推方法^[15].递推方法先辨识模型的某一部分(非线性或线性),利用辨识出的部分估计中间信号,然后利用估计的中间信号辨识另一部分,经过反复递推得到令人满意的 Hammerstein 模型.非递推方法先辨识出系统的整体参数,再采用奇异值分解等方法将参数分离.非递推方法克服了递推方法有时无法收敛的问题,但可能导致过参数化.

现有方法通常采用多项式函数或 S 型募集函数表示 IRC^[11],这些方法可以保证 IRC 的单调性,以便后续进行线性化处理,但这种方法建立的模型不具有泛化能力,无法预测不同患者上肢肌骨系统的个体差异.神经网络 (neural network, NN) 可以在系统内部具体结构和参数均未知的情况下,仅通过输入输出数据拟合复杂的非线性关系,对于 IRC 是一种理想的非线性映射.目前已有的研究结果显示^[16],仅使用在线数据对 NN 进行训练得到的 IRC 泛化能力较差,且收敛速度慢,且无法应对肌肉疲劳导致的时变性.

针对这些问题,本文建立了用于 NN 预训练的数据集.该数据集由大量经过设计的输入数据(电刺激水平)及其对应的输出数据(肘关节屈曲角度)组成.由于输入数据的数据量过大,难以通过人体获得对应的输出数据,使用 Freeman 等人^[17]提出的上肢肌骨系统仿真模型代替患者的上肢产生对应的训练输出数据.使用预训练数据集对 Hammerstein 模型的参数进行辨识.

上肢肌骨系统仿真模型包含2个健康受试者和2个脑卒中患者的模型参数, 经过预训练的NN具有较强的泛化能力, 对不同患者进行在线建模时, 具有较快的收敛速度和较高的建模精度。

根据所建模型的LAD设计参数最优迭代学习控制(parameter-optimal ILC, POILC). 为了消除IRC部分非线性的影响, 即线性化Hammerstein模型, 本文使用预训练数据集训练了一个IRC特性的逆NN, 并将之串联在POILC之后, 得到NN-POILC串联控制器(NN-POILC cascaded controller, NPOILC). 在每一次迭代中, 在线更新Hammerstein模型与NPOILC非线性控制器, 提高本文方法对肌肉特性的变化和外界扰动的鲁棒性. 使用MATLAB对本文提出的建模及控制方法进行仿真验证. 搭建实验平台, 对所提出的方法进行实验验证, 并分析建模误差、控制误差、收敛速度等性能。

本文的主要贡献如下:

1) 提出了一种改进的Hammerstein模型参数辨识方法, 其中IRC部分使用NN逼近, 使用最小二乘法辨识LAD部分传递函数的参数. 为了提高NN的泛化能力和在线训练收敛速度, 对模型进行预训练, 并在后续控制过程中使用在线数据对模型进行更新;

2) 基于Hammerstein模型的LAD部分设计POILC. 为消除模型IRC部分的影响, 使用预训练数据集训练了逆IRC特性的NN控制器, 该控制器同样使用在线数据进行更新, 以应对上肢肌骨系统的时变性. 将NN控制器与POILC串联, 从而构建NPOILC控制方法. 该方法能有效应对肌肉特性随时间的变化和外界扰动。

全文内容安排如下: 第2节针对上肢肌骨系统提出基于NN的Hammerstein模型的递推辨识方法; 第3节介绍了根据所辨识模型设计的NPOILC; 第4节对建模与控制方法进行了仿真, 并在上肢康复系统实验平台中开展了实验, 验证了所提出方法的有效性; 最后, 第5节对本文进行总结并给出结论与展望。

2 系统描述

本节介绍了上肢肌骨系统的Hammerstein模型, 并给出了模型参数的递推辨识方法。

2.1 上肢肌骨系统的Hammerstein模型

上肢肌骨系统的Hammerstein模型, 如图1所示, 由静态非线性函数与动态线性子模型串联而成. 模型可以表示为

$$\begin{cases} y(t) = G(w(t)), \\ w(t) = f(u(t)), \end{cases} \quad (1)$$

其中: $u(t), w(t), y(t) \in \mathbb{R}^1$ 分别为第 t 个采样时刻模型的输入(电刺激水平)、线性子系统的输入以及模型的输出(肘关节屈曲角度); $t = 0, 1, \dots, T$, 其中 $T \in \mathbb{N}^1$

为一次迭代的采样数; $G(\cdot)$ 为表示肌肉收缩动力学的LAD; $f(\cdot)$ 为代表肌肉纤维募集的IRC。

LAD的单输入单输出线性子模型 $G(\cdot)$ 的形式为

$$y(t) = - \sum_{i=1}^{n_a} a_i y(t-i) + \sum_{j=0}^{n_b} b_j w(t-j), \quad (2)$$

其中: $a_i (i=1, 2, \dots, n_a), b_j (j=0, 1, \dots, n_b) \in \mathbb{R}^1$ 为模型参数; $n_a, n_b \in \mathbb{N}^1$ 是模型的阶数, 且 $n_a \geq n_b$ 。

本文选择使用包含1层隐藏层的NN(记为NN1)作为IRC的静态非线性函数. 于是IRC的非线性函数 $f(\cdot)$ 可以表示为

$$w(t) = \sum_{m=1}^M \omega_m g\left(\sum_{l=1}^L \eta_{l,m} u_l(t) + \beta_m\right) + \beta_1, \quad (3)$$

其中: $u_l(t) (l=1, 2, \dots, L) \in \mathbb{R}^1$ 为NN1的第 l 个输入, 具体结构如图2所示; Z^{-1} 表示单位时延; $\eta_{l,m} (m=1, 2, \dots, M) \in \mathbb{R}^1$ 是第 l 个输入层神经元到第 m 个隐藏层神经元的权重; $\beta_m, \omega_m \in \mathbb{R}^1$ 分别是第 m 个隐藏层神经元的偏置、第 m 个隐藏层神经元与输出层神经元的权重; β_1 为输出层神经元的偏置; $g(\cdot)$ 为激活函数, 选择使用Sigmoid函数。




图2 神经网络NN1的输入

Fig. 2 Input of NN1

2.2 数据驱动建模方法

确定了Hammerstein模型的具体形式, 建模问题则转化为一个参数辨识的问题: 对于肌肉模型(1), 其中: $G(\cdot)$ 的待辨识参数为 θ , $f(\cdot)$ 的待辨识参数为 ψ , 给定一组输入输出数据 $\{\tilde{u}, \tilde{y}\}$, 寻找解 $\hat{\theta}$ 与 $\hat{\psi}$ 使得

$$(\hat{\theta}, \hat{\psi}) = \operatorname{argmin}_{\theta, \psi} \|\tilde{y} - G(f(\tilde{u}, \psi), \theta)\|. \quad (4)$$

辨识模型参数的一个困难是静态非线性和动态线性子模型之间的中间信号难以获得. 解决这个问题思路为递推辨识. 首先, 辨识模型的某一部分(非线性或线性), 利用辨识出的部分估计中间信号, 然后利用估计的中间信号辨识另一部分, 经过反复递推得到建模精度达到期望精度的Hammerstein模型. 由于IRC部分使用NN进行拟合, 为了降低NN的随机性对LAD动态模型的影响, 先对LAD进行辨识. 首次辨识时, 假定IRC为常量 α , 根据式(1)可得

$$\tilde{w}(t) = f(\tilde{u}(t)) = \alpha \tilde{u}(t). \quad (5)$$

LAD是一个线性模型, 使用成熟的线性系统辨识方法最小二乘法即可. 辨识得到的LAD线性子模型为

$$y(t) = G(w(t), \hat{\theta}), \quad (6)$$

其中 $\hat{\theta}$ 为 θ 的估计值.

根据输出数据 $\tilde{y}(t)$ 与 $\hat{\theta}$ 可以得到LAD输入的估计为

$$\hat{w}(t) = G^{-1}(\tilde{y}(t), \hat{\theta}), \quad (7)$$

其中 $G^{-1}(\cdot)$ 为LAD模型的逆模型. 将系统输入 $\tilde{u}(t)$ 与IRC的估计输出(即LAD输入的估计 $\hat{w}(t)$)作为一组输入输出数据对拟合IRC部分的NN(3)进行训练. 本文采用反向传播的方法训练NN. 训练后的NN为

$$w(t) = f(u(t), \hat{\psi}), \quad (8)$$

其中 $\hat{\psi}$ 为IRC参数 ψ 的估计.

使用另一组输入输出数据 $\{\tilde{u}_0, \tilde{y}_0\}$ 对建模精度进行测试. 根据输入数据 $\tilde{u}_0(t)$, 通过式(6)(8)可以得到模型输出 $\hat{y}_0(t)$. 记模型输出误差 $e_m(t) \in \mathbb{R}^1$ 为

$$e_m(t) := \tilde{y}_0(t) - \hat{y}_0(t), \quad (9)$$

模型输出的均方误差(mean square error, MSE)为

$$e_{\text{MSE}} = \frac{1}{T} \sum_{t=1}^T e_m^2(t). \quad (10)$$

当 $e_{\text{MSE}} \leq \epsilon$ 时(ϵ 为一个较小的正常数, 代表建模精度), 达到期望建模精度. 否则, 使用根据 $\tilde{u}(t)$ 与式(8)更新的 $\hat{w}(t)$ 代替式(5), 重复式(6)–(8)的过程, 对Hammerstein模型进行递推辨识, 直到达到足够的模型精度. 表1总结了上述数据驱动迭代建模过程.

表1 Hammerstein模型数据驱动迭代建模算法

Table 1 Data-driven iterative modeling algorithm for Hammerstein model

输入: 训练数据 $\{\tilde{u}, \tilde{y}\}$; 测试数据 $\{\tilde{u}_0, \tilde{y}_0\}$;	
IRC预设常量 α ; 期望精度 ϵ	
输出: 模型参数 $\hat{\psi}, \hat{\theta}$	
1	根据最小二乘法估计LAD参数 $\hat{\theta}$
2	使用式(6)估计IRC的输出 \hat{w}
3	使用 \tilde{u} 与 \hat{w} 训练NN(3), 得到IRC参数 $\hat{\psi}$
4	使用 \tilde{u}_0 对模型进行测试, 并根据式(8)–(9)计算模型精度的量化指标 e_{MSE}
5	while ($e_{\text{MSE}} > \epsilon$) do
6	根据 \tilde{u} 与式(7)更新 \hat{w}
7	重复步骤1–4
8	end
9	return 模型参数 $\hat{\psi}, \hat{\theta}$

本文使用4输入1输出的神经网络NN1表示IRC部分, 其隐藏层包含6个神经元, 训练集、验证集与测试集的比例为7:1.5:1.5. 用包含两个极点的二阶系统表示LAD部分的线性系统.

为了使NN具有较强的泛化能力, 以正弦函数、三角波函数、高斯曲线隶属函数等作为基函数设计1500组不同参数(幅值、相位等)的预训练输入信号 \tilde{u} , 并使

用Freeman等人^[17]提出的上肢模型代替患者的上肢产生预训练输出数据 \tilde{y} . 使用预训练数据集对Hammerstein模型进行预训练, 并在后续的迭代学习控制中使用每一次迭代产生的在线数据对IRC部分进行训练, 以应对上肢肌骨系统的时变性.

3 NPOILC控制方法

对于具有重复运动性质的被控对象, ILC是一种理想的控制方法. 基于优化的迭代学习控制能够通过建立合适的性能指标函数得到最优的控制输入, 从而避免迭代域上不理想的瞬态行为. 当模型精度足够时, 还可以使误差快速地单调收敛.

3.1 POILC

模型(1)中线性部分改写为状态空间模型的形式, 即

$$\begin{cases} \mathbf{x}(t+1) = A\mathbf{x}(t) + Bw(t), & \mathbf{x}(0) = \mathbf{x}_0, \\ y(t) = C\mathbf{x}(t), \end{cases} \quad (11)$$

其中: $\mathbf{x}(t) \in \mathbb{R}^{n_a}$ 为状态; $A \in \mathbb{R}^{n_a \times n_a}$, $B \in \mathbb{R}^{n_a \times 1}$, $C \in \mathbb{R}^{1 \times n_a}$ 为系统参数矩阵; 在不失一般性的情况下可以假设 $\mathbf{x}_0 = \mathbf{0}$. 模型(11)可以写为提升形式, 即

$$\mathbf{y}_k = G_e \mathbf{w}_k, \quad (12)$$

其中: 提升形式对象模型 $G_e \in \mathbb{R}^{T \times T}$ 为

$$G_e = \begin{bmatrix} CB & 0 & \cdots & 0 \\ CAB & CB & \cdots & 0 \\ CA^2B & CAB & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ CA^{T-1}B & CA^{T-2}B & \cdots & CB \end{bmatrix}; \quad (13)$$

$\mathbf{w}_k, \mathbf{y}_k \in \mathbb{R}^T$ 分别为第 $k \in \mathbb{N}^1$ 次迭代中提升形式的输入输出超向量, 具体形式为 $\mathbf{w}_k := [w_k(0) \ w_k(1) \ \cdots \ w_k(T-1)]^T$, $\mathbf{y}_k := [y_k(1) \ y_k(2) \ \cdots \ y_k(T)]^T$.

POILC第 $k+1$ 次迭代的参数最优控制更新律为

$$\mathbf{p}_{k+1} = \mathbf{p}_k + \frac{\mathbf{e}_k^T G_e \mathbf{e}_k}{\mathbf{e}_k^T G_e^T G_e \mathbf{e}_k} \mathbf{e}_k, \quad (14)$$

其中 $\mathbf{p}_k, \mathbf{e}_k \in \mathbb{R}^T$ 分别为第 k 次迭代的控制信号和输出与期望的误差信号, 具体为 $\mathbf{p}_k := [p_k(0) \ p_k(1) \ \cdots \ p_k(T-1)]^T$, $\mathbf{e}_k := [e_k(1) \ e_k(2) \ \cdots \ e_k(T)]^T$.

本节介绍的POILC的误差范数单调收敛性已得到详细证明^[18], 故在此省略.

3.2 NN非线性控制器

POILC根据Hammerstein模型中LAD部分 $G(\cdot)$ 设计, 没有考虑IRC部分 $f(\cdot)$ 产生的影响. 模型与控制方法的失配将导致误差沿迭代轴收敛速度变慢, 无法保证单调收敛甚至发散. 为了解决这一问题, 需要设计一个非线性控制器 $g(\cdot)$, 来消除IRC部分的影响. 令

$$\mathbf{u}_{k+1} = g(\mathbf{p}_{k+1}), \quad (15)$$

其中 $\mathbf{u}_{k+1} \in \mathbb{R}^T$ 为非线性控制器的输出, 具体形式为 $\mathbf{u}_{k+1} := [u_{k+1}(0) \ u_{k+1}(1) \ \dots \ u_{k+1}(T-1)]^T$, 从而使得IRC部分的输出为

$$\mathbf{w}_{k+1} = f(\mathbf{u}_{k+1}) = f(g(\mathbf{p}_{k+1})) \approx \mathbf{p}_{k+1}, \quad (16)$$

这样可以尽可能消除IRC的影响, 将系统线性化.

本文式(15)中的 $g(\cdot)$ 采用另一个NN(记为NN2)进行拟合. NN2的结构与NN1相同, 其训练所用的输入输出数据分别为表1中最后一次建模时训练NN1所用的输出 $\hat{\mathbf{y}}$ 与输入 $\hat{\mathbf{u}}$.

本文所提出的建模与控制方法NPOILC的总体框架如图3所示.




图3 建模与控制方法的总体框架

Fig. 3 Structure of modeling and control strategy

4 仿真与实验

4.1 建模及仿真实验

根据第2.2小节中的参数递推辨识方法, 使用数据集 $\{\hat{\mathbf{u}}, \hat{\mathbf{y}}\}$ 对上肢肌骨系统进行建模. 使用高斯曲线隶属函数作为测试输入数据 $\hat{\mathbf{u}}_0$, 对建模精度进行测试. 为了验证建模算法的可靠性, 重复10次上述建模过程, 结果如表2所示.

表2 模型的输出MSE与建模所需递推次数

Table 2 Output MSE of the model and number of recursions for modeling

样本	$e_{\text{MSE}} \times 10^{-4}$	迭代次数
1	9.43	1
2	4.68	1
3	5.32	3
4	9.97	14
5	9.62	10
6	3.62	1
7	8.67	1
8	9.00	1
9	9.27	1
10	8.41	2

由表2可以看出, 10次建模试验中大多数情况可以在1次迭代后达到理想的精度. 由于 ϵ 设置为 1×10^{-3} , e_{MSE} 多集中在 9×10^{-4} 附近, 若继续进行递推, 模型精度可以继续提高, 但这样会带来较大的计算负担, 且NN可能过拟合. 以第5, 6组为例, 其 e_{MSE} 的20次迭代变化分别如图4-5所示, 其中红色叉号标记表示建模结果第1次达到理想精度.

图6为建模输出. 图中黄色实线为表2中第6组所建模型的输出, e_{MSE} 为 3.62×10^{-4} . 作为对照, 使用5阶多项式作为Hammerstein模型的IRC部分, 线性部分仍为包含两个极点的二阶模型, 图6中红色点划线即为

该模型的输出, e_{MSE} 为 5.08×10^{-4} . 根据图6及 e_{MSE} 可知, 相较于使用多项式作为IRC部分, 基于NN的Hammerstein模型拥有更好的建模精度.




图4 第5组建模的MSE

Fig. 4 MSE of the 5th model




图5 第6组建模的MSE

Fig. 5 MSE of the 6th model




图6 模型输出

Fig. 6 Output of the model

使用受试者的在线数据对模型进行在线更新后的建模结果如图7所示. 通过对图6与图7预训练后的模型和在线训练的模型输出进行对比, 可以看到虽然预

训练模型与受试者实际输出有误差,使用在线数据对预训练模型更新后,模型具有较高的精度.而使用多项式作为IRC的模型,使用在线数据建模时则无法较好地拟合模型的输出.




图7 使用在线数据更新后的模型输出

Fig. 7 Output of the model updated with online data

4.2 控制方法仿真验证

建立系统模型后,根据第3.1, 3.2小节中的方法设计控制器(14)–(15),得到第 $k+1$ 次迭代的控制信号 \mathbf{u}_{k+1} .初始的控制信号 \mathbf{u}_1 选择高斯曲线隶属函数.将控制信号施加于Freeman等人^[17]提出的上肢肌骨运动模型,得到肘关节屈曲角度的仿真输出 \mathbf{y}_{k+1} .

为了对比模型对控制器设计的影响,设计第4.1小节对照组中拟合IRC部分的多项式的逆函数控制器,并串联在POILC之后,得到多项式-POILC串联控制器(polynomial-POILC cascaded controller, PPOILC).无模型的PD型ILC(PD-type ILC, PDILC)与PPOILC作为对照组(其参数选为 $k_p = 12$, $k_d = 550$),本文提出的NPOILC作为实验组,进行仿真实验.

NPOILC的前10次迭代的输出如图8所示,虚线为肘关节期望输出角度,实线为仿真系统的输出.图9为每次迭代的MSE,可以直观地展示控制器的收敛性能.相较于PDILC,在NPOILC的控制下,系统的输出均方误差MSE在前5次迭代内快速单调下降并收敛,最大误差为0.0356 rad,即2.0397°.对于两种使用不同模型的POILC, NPOILC的收敛速度更快,且最终迭代的MSE更小;而PPOILC由于使用多项式进行拟合,在第2次迭代时控制量会产生较大的变化,进而导致较大的误差,并且有发散的趋势.




图8 系统前10次迭代的输出

Fig. 8 Output of the system during the first 10 iterations

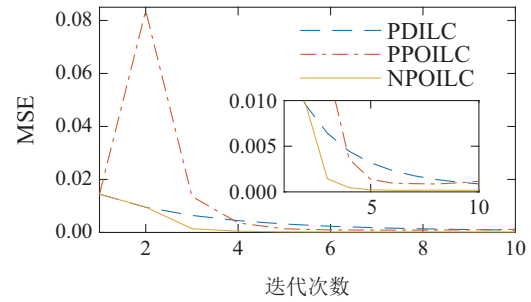


图9 PDILC, PPOILC和NPOILC的输出MSE

Fig. 9 MSE of PDILC, PPOILC and NPOILC

为了测试控制方法的泛化能力,使用不同的期望轨迹(改变幅值的高斯曲线隶属函数、正弦函数)对3种控制器进行测试, NPOILC的输出及对应的MSE分别如图10–13所示.从图11–13可以看出,对于不同期望轨迹,相较于PDILC, NPOILC均能快速收敛,而PPOILC在迭代域上出现不理想的瞬态行为.




图10 改变期望轨迹幅值时系统前10次迭代的输出

Fig. 10 Output of the system during the first 10 iterations when altering the amplitude of the desired trajectory

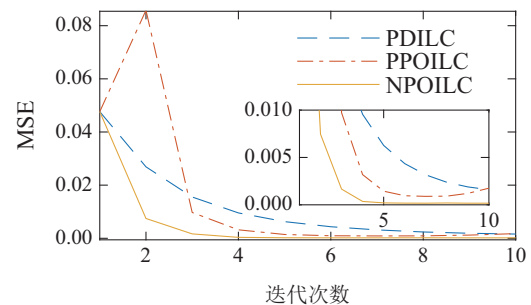


图11 改变期望轨迹幅值时不同控制器的输出MSE

Fig. 11 MSE of different controllers when altering the amplitude of the desired trajectory

4.3 实验验证及结果分析

本节以实际的上肢肌骨系统为控制对象,构建基于NPOILC的上肢康复系统实验平台,以分析该控制器控制肘关节屈曲角度跟踪期望轨迹的性能.

上肢康复系统实验平台的实物图如图14所示.其中,电刺激器为自主设计的由Arduino Nano作为微控制器的多通道电刺激器,输出幅值90 V、频率40 Hz的脉宽调制(pulse width modulation, PWM)电刺激信号. PWM信号的脉宽范围限制在0~1000 μs , 以免输出过

大电流. 电刺激器通过串口与MATLAB通信. 角度传感器(SG 110, Biometrics Ltd., U.K.)的数据由信号采集单元(W4X8, Biometrics Ltd., U.K.)通过蓝牙发送至上位机(MATLAB R2015b (32位), MathWorks, U.S.). 角度传感器的角度信号采集频率为100 Hz. 刺激电极的尺寸为4 cm×4 cm×2 mm.




图 12 正弦函数作为期望轨迹时系统前10次迭代的输出
Fig. 12 Output of the system during the first 10 iterations when a sine function is taken as the desired trajectory




图 13 正弦函数作为期望轨迹时不同控制器的输出MSE
Fig. 13 MSE of different controllers when a sine function is taken as the desired trajectory




图 14 上肢康复系统实验平台实物图
Fig. 14 Physical image of upper limb rehabilitation system experimental platform

实验环境如图15所示. 实验中, 前臂的运动限制在一个竖直的二维平面上. 角度传感器的两段固定在上臂和前臂侧面, 在肘关节完全伸展时将角度传感器置零. 电极的位置直接影响肌肉的刺激效果, 从而影响产生的运动. FES刺激器一个通道的两个电极应分别放置于肱二头肌肌腱和肌腹处, 但由于存在个体差异, 确定电极的最佳位置通常需要反复尝试.




图 15 上肢肌骨系统电刺激实验环境
Fig. 15 The experimental environment for electrical stimulation of the upper limb musculoskeletal system

固定角度传感器与电极片后, 运行MATLAB程序, 通过电刺激器对电刺激水平进行实时控制. 同时, 记录角度传感器采集到的肘关节角度. 如图16所示, 每次训练持续24 s, 训练之间休息15 s, 防止肌肉疲劳. 每组实验进行10次迭代, 每个受试者进行3次重复实验.




图 16 实验流程
Fig. 16 Experimental process

本文的实验已获得郑州大学生命科学伦理审查委员会的许可, 伦理证书编号: ZZUIRB2023-085. 在对偏瘫患者进行实验之前需要先验证方法和系统的精度和稳定性, 以防对患者造成二次伤害, 因此实验中招募了5位健康志愿者作为受试者. 由于FES不需要自主肌肉功能^[19], 脑卒中早期患者的偏瘫程度较轻, 若肌肉未发生痉挛, 其肌骨系统对FES的响应与健康受试者差异不大. 由于本文未考虑自主意愿对FES效果的影响, 实验要求受试者的肱二头肌在整个实验过程中尽量完全放松, 以免对实验结果产生干扰.

为验证本文所提建模方法及相应控制策略的有效性, 使用PDILC和PPOILC作为对照组, 与NPOILC进行对比. 在3种控制器的作用下, 2号受试者1次实验所得到的10次迭代的实际肘关节角度和期望轨迹以及对应的MSE分别如图17–20所示.




图 17 PDILC控制下10次迭代的肘关节角度和期望轨迹(15 s迭代间隔已从图中略去)
Fig. 17 Elbow joint angle and desired trajectory during the first 10 iterations under PDILC (The 15-second iteration intervals have been omitted from the figure)




图 18 PPOILC控制下10次迭代的肘关节角度和期望轨迹
Fig. 18 Elbow joint angle and desired trajectory during the first 10 iterations under PPOILC




图 19 NPOILC控制下10次迭代的肘关节角度和期望轨迹
Fig. 19 Elbow joint angle and desired trajectory during the first 10 iterations under NPOILC




图 20 前10次迭代的MSE
Fig. 20 MSE for the first 10 iterations

分析5位受试者的所有迭代的MSE的平均值及最终迭代的MSE, 由图21-22可知, 对于所有受试者, NPOILC相较于PDILC与PPOILC, 无论是所有迭代的MSE还是最终迭代的MSE都更小, 控制精度更高. 此外, 从误差线可以看出, 对同一受试者进行多次重复实验, NPOILC的结果变化更小, 控制效果更稳定.




图 21 所有迭代的MSE平均值
Fig. 21 Mean MSE for all iterations




图 22 最后一次迭代的MSE
Fig. 22 MSE of the last iteration

受试者肘关节角度所有迭代的均方根误差 (root MSE, RMSE)与最终迭代RMSE分别见表3-4. 相较于PDILC, NPOILC最终迭代的RMSE由0.14 rad(8.02°)降至0.085 rad(4.87°), 下降39.3%, 而相较于PPOILC则下降了50.0%.

表 3 所有迭代的RMSE
Table 3 RMSE of all iterations

受试者	PDILC	PPOILC	NPOILC
1	0.21	0.21	0.17
2	0.22	0.25	0.14
3	0.14	0.15	0.084
4	0.23	0.18	0.11
5	0.14	0.19	0.12
平均	0.19	0.20	0.13

表 4 最后一次迭代的RMSE
Table 4 RMSE of the last iteration

受试者	PDILC	PPOILC	NPOILC
1	0.13	0.17	0.12
2	0.23	0.22	0.084
3	0.075	0.16	0.057
4	0.17	0.13	0.074
5	0.10	0.16	0.090
平均	0.14	0.17	0.085

实验结果表明, 相较于使用多项式作为IRC, 使用NN作为IRC的Hammerstein模型具有更强的泛化能力, 更能真实反应受试者肱二头肌对FES的响应, 根据该模型设计的控制器NPOILC性能也更为优越. 此外, POILC对模型精度要求较高, 当模型与实际受试者失配时, 控制效果不理想. 因此, 在部分受试者使用PPOILC作为控制器时控制精度反而比无模型的PDILC低.

为了比较各个控制方法的收敛速度, 分析了5位受试者MSE降至一次实验过程中最大MSE的20%所需的迭代次数, 该指标越小表示收敛速度越快. 表5结果显示, 相较于PDILC与PPOILC, NPOILC的收敛速度更快, 分别由平均5.0次与4.3次降至3.4次, 分别下

降了32.0%与20.9%。较快的收敛速度可以在相同的康复过程中为患者提供更多次更准确的FES。

表5 MSE降至最大值的20%所需迭代数

Table 5 Number of iterations required to reduce MSE to 20% of maximum value

受试者	PDILC	PPOILC	NPOILC
1	4.7	4.7	3.7
2	3.0	6.0	2.7
3	5.3	3.0	3.4
4	6.7	4.3	2.0
5	5.3	3.3	5.3
平均	5.0	4.3	3.4

5 结论

针对FES控制精度低、鲁棒性差等问题, 本文基于Hammerstein模型对上肢肌骨系统进行建模, 提出模型预训练与在线更新方法, 并根据该模型设计NPOILC控制器。首先, 建立预训练数据集, 根据Hammerstein模型参数递推辨识方法对由NN与传递函数串联而成的模型进行预训练, 并在控制过程中对NN在线更新; 其次, 根据所建模型的LAD部分设计POILC, 并训练逆IRC特性的NN作为非线性控制器与POILC串联, 得到本文提出的NPOILC; 最后, 搭建了基于NPOILC的上肢康复系统实验平台, 招募了5位受试者进行实验验证。对实验数据的分析表明, 本文所建模型可以较好地描述肌骨系统特性, 基于该模型的NPOILC相较于PDILC和PPOILC具有精度高、收敛速度快、泛化能力强等优势。后续, 将尝试将表面肌电信号作为一种反馈信号集成到控制系统中。此外, 本次实验招募的受试者均有健全的上肢运动能力, 后续将招募脑卒中导致的偏瘫患者进行进一步实验。

参考文献:

- [1] FEIGIN V L, STARK B A, JOHNSON C O, et al. Global, regional, and national burden of stroke and its risk factors, 1990 - 2019: A systematic analysis for the global burden of disease study 2019. *The Lancet Neurology*, 2021, 20(10): 795 - 820.
- [2] BERTANI R, MELEGARI C, COLA M C, et al. Effects of robot-assisted upper limb rehabilitation in stroke patients: A systematic review with meta-analysis. *Neurological Sciences*, 2017, 38(9): 1561 - 1569.
- [3] HOWLETT O A, LANNIN N A, ADA L, et al. Functional electrical stimulation improves activity after stroke: A systematic review with meta-analysis. *Archives of Physical Medicine and Rehabilitation*, 2015, 96(5): 934 - 943.
- [4] MARQUEZ-CHIN C, POPOVIC M R. Functional electrical stimulation therapy for restoration of motor function after spinal cord injury and stroke: A review. *BioMedical Engineering OnLine*, 2020, 19(1): 34.
- [5] RABELO M, MOURA J R V B, LIMA L A O, et al. Overview of FES-assisted cycling approaches and their benefits on functional rehabilitation and muscle atrophy. *Muscle Atrophy*, 2018: 561 - 583.

- [6] HARA Y. Brain plasticity and rehabilitation in stroke patients. *Journal of Nippon Medical School*, 2015, 82(1): 4 - 13.
- [7] ZHANG J, ZHANG L, GUO S, et al. Iterative learning control of functional electrical stimulation based on joint muscle model. *The 3rd International Conference on Computational Intelligence and Intelligent Systems (CIIS)*. Tokyo, Japan: Association for Computing Machinery, 2020: 119 - 123.
- [8] ZHANG Q, MENG Y, WU L, et al. Artificially induced joint movement control with musculoskeletal model-integrated iterative learning algorithm. *Biomedical Signal Processing and Control*, 2020, 59: 101843.
- [9] HUO B, LIU Y, QIN Y, et al. Disturbance observer based iterative learning control for upper limb rehabilitation. *The 46th Annual Conference of the IEEE Industrial Electronics Society (IECON)*. Singapore: IEEE, 2020: 2774 - 2779.
- [10] ZHAO G, ZENG Q, HUO B, et al. FES-based hand movement control via iterative learning control with forgetting factor. *International Conference on Intelligent Robotics and Applications (ICIRA)*. Cham: Springer International Publishing, 2022: 281 - 292.
- [11] SA-E S, FREEMAN C T, YANG K. Iterative learning control of functional electrical stimulation in the presence of voluntary user effort. *Control Engineering Practice*, 2020, 96: 104303.
- [12] CHI R, HOU Z, HUANG B, et al. A unified data-driven design framework of optimality-based generalized iterative learning control. *Computers & Chemical Engineering*, 2015, 77: 10 - 23.
- [13] BREND O, FREEMAN C, FRENCH M. Multiple-model adaptive control of functional electrical stimulation. *IEEE Transactions on Control Systems Technology*, 2015, 23(5): 1901 - 1913.
- [14] HAEUFLE D F B, GÜNTHER M, BAYER A, et al. Hill-type muscle model with serial damping and eccentric force-velocity relation. *Journal of Biomechanics*, 2014, 47(6): 1531 - 1536.
- [15] JIA Li, LI Xunlong. Identification of Hammerstein model: Review and prospect. *Control Theory & Applications*, 2014, 31(1): 1 - 10. (贾立, 李训龙. Hammerstein模型辨识的回顾及展望. 控制理论与应用, 2014, 31(1): 1 - 10.)
- [16] LI Y, CHEN W, CHEN J, et al. Neural network based modeling and control of elbow joint motion under functional electrical stimulation. *Neurocomputing*, 2019, 340: 171 - 179.
- [17] FREEMAN C T, HUGHES A-M, BURRIDGE J H, et al. A model of the upper extremity using FES for stroke rehabilitation. *Journal of Biomechanical Engineering*, 2009, 131(3): 031011.
- [18] OWENS D H. *Iterative Learning Control: An Optimization Paradigm*. London, England: Springer London, 2016.
- [19] MANGOLD S, SCHUSTER C, KELLER T, et al. Motor training of upper extremity with functional electrical stimulation in early stroke rehabilitation. *Neurorehabilitation and Neural Repair*, 2009, 23(2): 184 - 190.

作者简介:

- 霍本岩 副教授, 目前研究方向为康复机器人和迭代学习控制, E-mail: huoby@zzu.edu.cn;
- 李 祯 硕士研究生, 目前研究方向为康复机器人和数据驱动建模, E-mail: 763514739@qq.com;
- 刘艳红 教授, 目前研究方向为机器人建模与控制 and 智能人机交互, E-mail: liuyh@zzu.edu.cn;
- 赵新刚 教授, 目前研究方向为机器人控制、人机自然交互、康复机器人系统和外骨骼机器人系统, E-mail: zhaoxingang@sia.cn;
- 张宇波 副教授, 目前研究方向为康复机器人和信号处理, E-mail: yuboz@zzu.edu.cn.