

基于进化动态递归模糊神经网络的上肢康复机器人自适应阻抗控制^①

徐国政^② 宋爱国^③ 李会军

(东南大学仪器科学与工程学院 南京 210096)

摘 要 针对机器人辅助患肢进行康复训练时患肢病情的变化对系统运动平滑性和稳定性造成的影响,在传统阻抗控制方法的基础上,提出了一种基于进化动态递归模糊神经网络(EDRFNN)的新的自适应阻抗控制方法。该方法根据在线辨识得到的患肢机械阻抗参数,运用 EDRFNN 对目标阻抗控制参数进行动态调整。在调整过程中,首先采用混合进化算法离线优化目标阻抗控制参数,然后再利用基于 Lyapunov 函数稳定收敛性理论设计的动态 BP 算法对目标阻抗控制参数在线作进一步的调整。分析和仿真结果表明,这种新的方法较其它阻抗控制方法更能有效地适应患肢病情的变化,且具有较好的平滑性和稳定性。

关键词 康复机器人, 动态递归, 模糊神经网络, 进化算法, 在线辨识, 自适应阻抗控制

0 引 言

康复机器人技术是近年来发展起来的一种新的运动神经康复治疗技术^[1]。在机器人辅助患者进行康复运动的过程中,一个重要的方面就是康复机器人能够实时感知患者的病情状态并采取相应的控制策略,从而使得当患肢病情发生变化时,控制系统的运动平滑性基本保持不变。近年来不少研究者已经对此问题进行了研究,其中应用较为广泛的有力控制策略^[1,2]、基于力势场和生物电信号的控制方法等^[3,4]。

阻抗控制是一种已被广泛用于康复机器人的运动控制的有效的人力控制方法^[5,6],这种传统的阻抗控制方法虽然取得了一定的效果,但是整个系统的性能仍然取决于目标阻抗控制参数的选取。随着智能控制技术的发展,阻抗控制方法和智能控制技术相结合,在一定程度上弥补了传统方法的不足,提高了康复训练效果^[7-9]。然而到目前为止,运用(模糊)神经网络技术设计的康复机器人阻抗控制策略大都基于前馈神经网络进行设计,前馈神经网络是一种静态网络,而患者在康复训练过程中,由于肌力/肌张力的变化、肌肉痉挛等因素的存在,其病情是动态多变的,此外,上述控制策略大都直接根据传感器检测信息进行设计,而且控制器参数多采用

传统的易陷于局部最优的反向传播(back-propagation, BP)算法进行优化,因此上述控制策略仍有一定的局限性。针对上述问题,本文提出了一种基于进化动态递归模糊神经网络(evolutionary dynamic recurrent fuzzy neural network, EDRFNN)的上肢康复机器人自适应阻抗控制方法。该方法以具有较好动态学习和映射能力的动态递归模糊神经网络(DRFNN)^[10]为基础分别设计目标刚度控制器和阻尼控制器,同时将传感器检测信息同患肢病情特性识别相结合,根据在线辨识得到的患肢机械阻抗参数,运用 EDRFNN 对目标刚度参数和阻尼参数分别进行在线调整;同时针对传统 BP 算法的缺点,提出一种控制器参数混合学习算法,该方法分别运用混合进化算法和基于 Lyapunov 函数稳定收敛性理论设计的动态 BP 算法对控制器参数进行离线和在线优化。分析和仿真结果表明,较其它阻抗控制方法而言,改进后的控制策略能够较好地改善机器人辅助康复运动控制系统的动态性能,特别是在患肢病情发生变化时,系统具有更好的运动平滑性和稳定性。

1 患肢机械阻抗参数在线辨识

研究表明,患肢在恢复的不同阶段中其机械阻抗、刚度、阻尼参数是不断变化的^[11,12],这些参数较为准确地反映出了患肢在恢复过程中的病情特性。

① 863 计划(2008AA040202)资助项目。

② 男,1979 年生,博士;研究方向:康复机器人传感与控制技术;E-mail: xgzseu@yahoo.com.cn

③ 通讯作者, E-mail: a.g.song@seu.edu.cn

(收稿日期:2009-08-05)

弹簧-阻尼模型

$$f_e = b_e \dot{x} + k_e x \quad (1)$$

可用来表示患肢的动力学特性,式中, f_e 为康复机械手末端同患肢之间的相互作用力, $x, \dot{x}$ 分别为患肢的位移和速度, b_e, k_e 分别为患肢的阻尼和刚度。

假设 $\hat{b}_e, \hat{k}_e$ 为患肢机械阻抗参数 b_e, k_e 相应的估计值,则有

$$\hat{f}_e = \hat{b}_e \dot{x} + \hat{k}_e x \quad (2)$$

根据最小二乘法

$$E = \sum_{i=1}^N [f_e(i) - \hat{f}_e(i)]^2 \quad (3)$$

$$\frac{\partial E}{\partial \hat{b}_e} = 0, \frac{\partial E}{\partial \hat{k}_e} = 0 \quad (4)$$

有

$$\begin{bmatrix} \hat{b}_e \\ \hat{k}_e \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N \dot{x}^2(i) & \sum_{i=1}^N \dot{x}(i)x(i) \\ \sum_{i=1}^N x(i)\dot{x}(i) & \sum_{i=1}^N x^2(i) \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^N \dot{x}(i)f_e(i) \\ \sum_{i=1}^N x(i)f_e(i) \end{bmatrix} \quad (5)$$

式中 N 是采样点数。为了能较好地对患肢机械阻抗参数进行在线估计,引入滑动平均方法,则有

$$\begin{bmatrix} \hat{b}_e(t) \\ \hat{k}_e(t) \end{bmatrix} = \begin{bmatrix} \sum_{i=t-N+1}^t \dot{x}^2(i) & \sum_{i=t-N+1}^t \dot{x}(i)x(i) \\ \sum_{i=t-N+1}^t x(i)\dot{x}(i) & \sum_{i=t-N+1}^t x^2(i) \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=t-N+1}^t \dot{x}(i)f_e(i) \\ \sum_{i=t-N+1}^t x(i)f_e(i) \end{bmatrix} \quad (6)$$

2 EDRFNN 阻抗控制器

2.1 EDRFNN 阻抗控制器结构

n 关节康复机械手在关节空间的动力学模型为

$$M(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) = \tau - \tau_e \quad (7)$$

式中, $\ddot{\theta}, \dot{\theta}, \theta$ 分别是关节的加速度、速度和位置向量, $M(\theta) \in R^{n \times n}$ 是正定的惯性矩阵, $h(\theta, \dot{\theta}) = C(\theta, \dot{\theta}) + G(\theta)$, 其中 $C(\theta, \dot{\theta}) \in R^{n \times n}$ 是哥氏力和离心力向量, $G(\theta) \in R^{n \times n}$ 是重力向量, $\tau \in R^n$ 是关节驱动力矩, $\tau_e \in R^n$ 是患肢对康复机械手的反作用力矩。

考虑目标阻抗控制模型

$$M_d \ddot{X} + B_d(\dot{X} - \dot{X}_d) + K_d(X - X_d) = F_d - F_e \quad (8)$$

其中 M_d, B_d, K_d 分别为目标惯性、阻尼和刚度矩阵; X_d, X 分别为康复机械手末端期望和实际位移矢量; $\dot{X}_d, \dot{X}$ 为相应的速度矢量; $\ddot{X}$ 为康复机械手末端实际加速度矢量。

根据式(7)和(8)并进行相应变换,可得康复机器人阻抗力控制律为

$$\begin{aligned} \tau = & M(\theta)J^{-1}\{M_d^{-1}[(B_d(\dot{X}_d - \dot{X}) \\ & + K_d(X_d - X)] - \ddot{J}\theta\} + (J^T - M(\theta)J^{-1}M_d^{-1})F_e \\ & + M(\theta)J^{-1}M_d^{-1}F_d + h(\theta, \dot{\theta}) \end{aligned} \quad (9)$$

式中 J 为雅克比矩阵。

图1给出了基于EDRFNN设计的上肢康复机器人自适应阻抗力控制器框图,它是在传统阻抗控制器基础上,增加了本文所提出的EDRFNN刚度控制器和EDRFNN阻尼控制器。图2给出了EDRFNN刚度控制器结构,该控制器采用5层网络,在第2层引入动态递归单元。患肢机械阻抗参数 $\hat{b}_e, \hat{k}_e$ 作为控制器输入, K_d 为控制器输出。EDRFNN阻尼控制器结构类似。




图1 康复机器人进化动态递归模糊神经网络阻抗控制




图 2 EDRFNN 刚度控制器结构

2.2 EDRFNN 阻抗控制器学习算法

EDRFNN 阻抗控制器结构确定之后,需要通过学习结构和模糊隶属函数参数来优化 K_d, B_d 。常用的 BP 算法通常都是随机地给出一组待学习参数的初值,该初值对算法的学习速度有很大影响。此外,该方法中学习速率的选择大都通过试凑得到。由文献[10]知,学习速率的选择对控制系统的稳定性及收敛速度具有较大影响。根据上述分析,首先采用混合进化算法离线优化目标阻抗控制参数,然后再利用基于 Lyapunov 函数稳定收敛性理论设计的动态 BP 算法对目标阻抗控制参数在线作进一步的调整,从而得到适应于患肢病情特性的目标阻抗控制参数。以 EDRFNN 刚度控制器为例进行分析。

2.2.1 混合进化算法离线优化

遗传算法 (genetic algorithm, GA) 在进化过程中由于交叉算子的存在可能会在一定程度上破坏父代与子代之间的行为链接,从而导致网络结构发生变化,而进化编程 (evolutionary programming, EP) 技术主要是依靠变异算子来实现进化,能够较好地保持父代与子代之间的行为链接^[13]。综合考虑 GA 与 EP 的优缺点,对适应度低的个体运用 GA 进行进化,适应度居中的个体运用 EP 进行进化,适应度最佳的个体直接复制到子代组建新的种群^[13]。混合进化算法的具体流程图如图 3 所示,主要进化过程如下:

(1) 编码:对决策变量进行实数编码,并根据决策变量的区域范围随机产生一定数量种群。

(2) 计算目标函数值。目标函数为

$$E_{off}^S = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^p (\hat{y}_j - y_j)^2 \quad (10)$$

式中, N 为进化样本数目, $\hat{y}_j$ 和 y_j 分别为 DRFNN 刚度控制器的实际输出和期望输出。




图 3 混合进化算法流程

计算适应度值。适应度公式为

$$Fitness = \frac{1}{\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^p (\hat{y}_j - y_j)^2} \quad (11)$$

(3) 交叉:采用“两点交叉”方法实现。

(4) 变异:GA 采用“均匀变异”策略;EP 采用传统进化编程 (classical EP, CEP) 和快速进化编程 (fast EP, FEP) 相结合的方法^[14]对适应度居中的个体进行进化,进化过程中变异算子取为

$$\begin{aligned} \sigma' &= \sigma \exp(\tau' N(0,1) + \tau N'(0,1)) \\ x' &= x + 0.5 \sigma' (N(0,1) + C(0,1)) \end{aligned} \quad (12)$$

首先运用 Mamdani 推理算法和 DRFNN 阻抗控制器控制规则计算得到模糊数值判决表 ($\hat{b}_e, \hat{k}_e, K_d$),然后运用该判决表作为样本数据对 DRFNN 进行离线优化,待优化的参数有:输出层连接权值 w_{ij}^S ;递归层连接权值 θ_{ij}^S ;输入量隶属函数的中心值和宽度值 m_{ij}^S, σ_{ij}^S 。混合进化算法优化结果如图 4 所示。

由图可以看出,基于 GA 和 EP 混合算法对 DRFNN 优化是有效的。




图4 刚度控制器进化结果

2.2.2 在线学习

在在线学习阶段,将离线优化好的 EDRFNN 网




图5 EDRFNN 阻抗力控制结构简图

根据梯度下降法对 $\frac{\partial E_{on}^S}{\partial w_{ij}^S}, \frac{\partial E_{on}^S}{\partial \theta_{ij}^S}, \frac{\partial E_{on}^S}{\partial m_{ij}^S}, \frac{\partial E_{on}^S}{\partial \sigma_{ij}^S}$ 进行

计算,有

$$\frac{\partial E_{on}^S}{\partial w_{ij}^S} = -\delta_p^5 o_k^4$$

$$\frac{\partial E_{on}^S}{\partial \theta_{ij}^S} =$$

$$\delta_{ij}^2 \frac{-2[x_i^1(k) + o_{ij}^2(k-1) \times \theta_{ij}^S - m_{ij}^S] o_{ij}^2(k-1)}{(\sigma_{ij}^S)^2}$$

$$\frac{\partial E_{on}^S}{\partial m_{ij}^S} = \delta_{ij}^2 \frac{-2[x_i^1(k) + o_{ij}^2(k-1) \times \theta_{ij}^S - m_{ij}^S]}{(\sigma_{ij}^S)^2}$$

$$\frac{\partial E_{on}^S}{\partial \sigma_{ij}^S} = \delta_{ij}^2 \frac{-2[x_i^1(k) + o_{ij}^2(k-1) \times \theta_{ij}^S - m_{ij}^S]^2}{(\sigma_{ij}^S)^3}$$

络放入系统运行,系统在线根据定义的目标函数对网络参数进行微调。以 EDRFNN 刚度控制器为例进行分析。目标函数定义为

$$E_{on}^S(k) = \frac{1}{2} [X_d(k) - X(k)]^2 + \frac{1}{2} [F_d(k) - \hat{F}_e(k)]^2 \quad (13)$$

采用引入动量项的动态 BP 算法对参数 $w_{ij}^S, \theta_{ij}^S, m_{ij}^S, \sigma_{ij}^S$ 进行在线调整:

$$W_{ij}^S(k+1) = W_{ij}^S(k) + \eta^S \left(-\frac{\partial E_{on}^S}{\partial W_{ij}^S} \right) + \gamma (W_{ij}^S(k) - W_{ij}^S(k-1)) \quad (14)$$

其中 $W^S = [m^S, \sigma^S, \theta^S, \omega^S]^T$ 为控制器待训练参数, $\eta^S = [\eta_m^S, \eta_\sigma^S, \eta_\theta^S, \eta_\omega^S]^T$ 为训练过程中相应参数的学习速率, γ 为惯性系数。为方便对 EDRFNN 阻抗控制器在线学习算法进行分析,进一步给出 EDRFNN 阻抗力控制结构简图,如图 5 所示。

$$\delta_p^5 = -\frac{\partial E_{on}^S(k)}{\partial net_p^5(k)} = -\left[\frac{\partial E_{on}^S(k)}{\partial K_d(k)} \frac{\partial K_d(k)}{\partial net_p^5(k)} \right] \quad (15)$$

$$\delta_{ij}^2 = -\frac{\partial E_{on}^S(k)}{\partial net_{ij}^2(k)} = -\left[\frac{\partial E_{on}^S(k)}{\partial K_d(k)} \frac{\partial K_d(k)}{\partial net_{ij}^2(k)} \right] \quad (16)$$

式中 $\frac{\partial K_d(k)}{\partial net_p^5(k)}, \frac{\partial K_d(k)}{\partial net_{ij}^2(k)}$ 直接根据梯度下降法进行计算。 net_i^k 和 o_i^k 分别表示第 k 层中第 i 节点输入和输出, f_i^k 表示第 k 层中第 i 节点传递函数。

令

$$e_p = X_d - X, e_f = F_d - \hat{F}_e$$

$$E_p^S(k) = \frac{1}{2} [e_p(k)]^2$$

$$E_f(k) = \frac{1}{2} [e_f(k)]^2$$

根据图 5 有

$$\begin{aligned} \frac{\partial E_{on}^s(k)}{\partial K_d(k)} &= \frac{\partial E_p^s(k)}{\partial K_d(k)} + \frac{\partial E_f(k)}{\partial K_d(k)} \\ &= \frac{\partial E_p^s(k)}{\partial u(k)} \frac{\partial u(k)}{\partial F_s(k)} \frac{\partial F_s(k)}{\partial K_d(k)} \\ &\quad + \frac{\partial E_f(k)}{\partial u(k)} \frac{\partial u(k)}{\partial F_s(k)} \frac{\partial F_s(k)}{\partial K_d(k)} \end{aligned} \quad (17)$$

且

$$\begin{aligned} \frac{\partial E_p^s(k)}{\partial u(k)} &= \frac{\partial E_p^s(k)}{\partial X(k)} \frac{\partial X(k)}{\partial u(k)} \\ \frac{\partial E_f(k)}{\partial u(k)} &= \frac{\partial E_f(k)}{\partial \hat{F}_e(k)} \left[\frac{\partial \hat{F}_e(k)}{\partial X(k)} \frac{\partial X(k)}{\partial u(k)} + \frac{\partial \hat{F}_e(k)}{\partial \dot{X}(k)} \frac{\partial \dot{X}(k)}{\partial u(k)} \right] \end{aligned}$$

其中 $\frac{\partial \hat{F}_e(k)}{\partial X(k)}$, $\frac{\partial \hat{F}_e(k)}{\partial \dot{X}(k)}$, $\frac{\partial F_s(k)}{\partial K_d(k)}$ 分别可以由(2)和(8)式进行计算。

对 EDRFNN 阻尼控制器进行分析时,其目标函数定义为

$$\begin{aligned} E_{on}^D(k) &= \frac{1}{2} [\dot{X}_d(k) - \dot{X}(k)]^2 \\ &\quad + \frac{1}{2} [F_d(k) - \hat{F}_e(k)]^2 \end{aligned} \quad (18)$$

分析方法与 EDRFNN 刚度控制器类似。

2.2.3 算法收敛性分析

设 $W^s = [m^s, \sigma^s, \theta^s, \omega^s]^T$ 为刚度控制器训练参数, $\eta^s = [\eta_m^s, \eta_\sigma^s, \eta_\theta^s, \eta_\omega^s]^T$ 为相应参数学习速率,如果学习速率选择方式为

$$0 < \eta^s < \frac{2}{[\max_k(\xi_1(k), \xi_2(k))]^2 \left[\max_k \left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right]^2} \quad (19)$$

则算法收敛,其中

$$\begin{aligned} \xi_1(k) &= \frac{\partial e_p(k)}{\partial K_d(k)}, \quad \xi_2(k) = \frac{\partial e_f(k)}{\partial K_d(k)} \\ \left\| \frac{\partial K_d(k)}{\partial W} \right\|^2 &= \left[\frac{\partial K_d(k)}{\partial W} \right]^T \left[\frac{\partial K_d(k)}{\partial W} \right], \quad \cdot \cdot \cdot \end{aligned}$$

是 Euclidean 范数。

证明:定义 Lyapunov 函数

$$\begin{aligned} V(k) &= [e_p(k)]^2 + [e_f(k)]^2 \\ \Delta V(k) &= V(k+1) - V(k) \\ &= (2e_p(k)\Delta e_p(k) + (\Delta e_p(k))^2) \\ &\quad + (2e_f(k)\Delta e_f(k) + (\Delta e_f(k))^2) \end{aligned}$$

运用文献[10]中的方法进行推理可得

$$\begin{aligned} \Delta V(k) &= -2\eta^s[\xi_1(k)]^2[e_p(k)]^2 \left[\left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right] \\ &\quad + \left(-\eta^s[\xi_1(k)]^2 e_p(k) \left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right)^2 \end{aligned}$$

$$\begin{aligned} &-2\eta^s[\xi_2(k)]^2[e_f(k)]^2 \left[\left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right] \\ &+ \left(-\eta^s[\xi_2(k)]^2 e_f(k) \left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right)^2 \end{aligned} \quad (20)$$

进一步化简

$$\begin{aligned} \Delta V(k) &= -\eta^s[\xi_1(k)]^2[e_p(k)]^2 \left[\left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right] \\ &\quad \times \left(2 - \eta^s[\xi_1(k)]^2 \left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right) \\ &\quad - \eta^s[\xi_2(k)]^2[e_f(k)]^2 \left[\left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right] \\ &\quad \times \left(2 - \eta^s[\xi_2(k)]^2 \left\| \frac{\partial K_d(k)}{\partial W^s} \right\|^2 \right) \end{aligned} \quad (21)$$

为满足收敛条件, $\Delta V(k) < 0$, 从而 η 须满足

$$\begin{aligned} 0 < \eta^s < \frac{2}{[\xi_1(k)]^2 \left\| \frac{\partial K_d(k)}{\partial W} \right\|^2}, \quad 0 < \eta^s < \\ \frac{2}{[\xi_2(k)]^2 \left\| \frac{\partial K_d(k)}{\partial W} \right\|^2} \circ \quad \text{取} \quad 0 < \eta^s < \\ \frac{2}{[\max_k(\xi_1(k), \xi_2(k))]^2 \left[\max_k \left\| \frac{\partial K_d(k)}{\partial W} \right\|^2 \right]^2}, \quad \text{则} \end{aligned}$$

$\Delta V(k) < 0$ 恒成立。证毕。

3 仿真结果

为验证本文所提算法的有效性,现给出一 2 自由度康复机器人的仿真试验。康复机器人动力学模型如式(7)所示(取 $n = 2$),具体参数为: $m_1 = 8\text{kg}$, $m_2 = 8\text{kg}$, $l_1 = 0.5\text{m}$, $l_2 = 0.5\text{m}$, $\theta_1(0) = 0\text{rad}$, $\theta_2(0) = \pi/3\text{rad}$, $\dot{\theta}_1(0) = 0\text{rad/s}$, $\dot{\theta}_2(0) = 0\text{rad/s}$ 。控制器输入、输出的模糊集论域均定义为 $[-6, 6]$ 。在该论域中,为每个输入和输出分别定义 7 个模糊语言变量:“负大”、“负中”、“负小”、“零”、“正小”、“正中”、“正大”。各语言变量隶属函数均取为高斯基函数。

由现代偏瘫治疗学原理^[15],患肢在恢复过程中通常经历软瘫期、痉挛期及恢复期等三个主要阶段,在恢复期中伴有痉挛情况发生时,患肢作用力会有较大幅度的提高,根据文献[11, 12]中患肢机械阻抗参数变化的实验结果,在仿真时考虑了患肢的病情变化,如图 6 中的虚线所示,运用本文所提辨识算法,得到患肢在线估计的机械阻抗参数(图 6 中实线所示)。由图可以看出,该在线辨识算法能较准确地辨识出患肢机械阻抗参数。

运用本文提出的 EDRFNN 阻抗控制方法对控制系统性能进行分析。基于传统 BP 算法优化的 DRFNN 阻抗控制器、FNN 阻抗控制器^[9]及传统阻抗控制器分别作为参考方法进行对比。首先考察患肢在恒定的辅助力作用下,当患肢病情发生如图 6 所示变化时,控制系统的稳定性和力跟踪效果。取辅助力参考值 $F_{d1} = 10.5\text{N}$,仿真时间为 10s ,相应的力控制效果如图 7(a)-(c)所示。




图 6 患肢机械阻抗辨识曲线




图 7(a) EDRFNN 与 DRFNN 恒定辅助力控制




图 7(b) EDRFNN 与 FNN 恒定辅助力控制




图 7(c) EDRFNN 与传统阻抗控制器恒定辅助力控制

为深入研究本文提出的算法在患肢病情发生如图 6 所示变化情况下的力控制效果,进一步考察患肢在变化辅助力作用下的控制性能。取 $F_{d2} = 10.5\sin(t)\text{N}$,仿真时间为 10s ,相应的力控制效果如图 8(a)-(c)所示。




图 8(a) EDRFNN 与 DRFNN 变化辅助力控制




图 8(b) EDRFNN 与 FNN 恒定辅助力控制




图 8(c) EDRFNN 与传统阻抗控制器变化辅助力控制

为具体比较上述各种阻抗控制算法在患肢病情发生变化情况下的控制性能,选取“绝对最大力超调值”、力跟踪误差的“均值”及“标准差”作为性能指标,恒定和变化辅助力作用下各种阻抗控制算法性能比较结果分别如表 1、表 2 所示。

表 1 恒定辅助力作用下各种阻抗控制算法性能比较

	EDRFNN	DRFNN	FNN	传统
绝对最大力超调值	12.804	24.325	37.251	69.882
均值	-0.817	0.687	-5.299	1.242
标准差	0.869	1.596	4.657	9.206

表 2 变化辅助力作用下各种阻抗控制算法性能比较

	EDRFNN	DRFNN	FNN	传统
绝对最大力超调值	8.221	18.779	32.272	62.196
均值	-0.192	-0.034	-1.776	1.227
标准差	0.964	1.332	5.489	9.341

由上述比较结果可以看出,患肢在恢复过程中对其施加变化和恒定辅助力作用时,随着病情的变化,在 EDRFNN 阻抗控制、DRFNN 阻抗控制、FNN 阻抗控制和传统阻抗控制算法作用下,四种力控制方法都会发生不同程度的力超调和振荡,并且均存在一定的力跟踪误差,但是传统阻抗控制方法由于在整个控制过程中其目标阻抗控制参数保持不变,导致其力控制稳定性受患肢病情变化的影响最大;FNN 算法在整个控制过程中目标阻抗控制参数能随着患肢病情的变化做出适当调整,受影响的程度较传统阻抗控制算法要小,但是有一定的跟踪误差;DRFNN 算法在整个控制过程中不但能根据病情的变化及时调整目标阻抗控制参数,而且由于在结构上引入了动态递归层,从仿真结果可以看出,同前两

种算法相比,DRFNN 算法受患肢病情的影响较前两种算法都要小,跟踪误差也非常小;EDRFNN 算法除了具有 DRFNN 算法所具有的优点以外,而且在离线优化过程中采用了混合进化算法,较传统 BP 算法离线优化具有一定的优越性,因此,较 DRFNN 阻抗力控制方法具有更小的力超调峰值,而且在患肢病情变化缓慢时力跟踪效果也非常好。

由上述分析可知,在患肢恢复过程中,当病情发生变化时,由于本文提出的基于 EDRFNN 的自适应阻抗控制算法能及时调整机器人末端同患肢之间的动态关系,因此较其它阻抗控制方法具有更强的稳定性和鲁棒性。

4 结 论

在机器人辅助患肢进行康复训练过程中,保持系统运动平滑及稳定并根据患肢恢复过程中的病情特点实时调整机械手末端同患肢之间的相互作用是至关重要的。本文在传统阻抗控制方法的基础上,提出一种基于进化动态递归模糊神经网络的自适应阻抗控制方法。该方法通过对患肢机械阻抗参数进行在线辨识,并根据辨识得到的参数,运用进化动态递归模糊神经网络对康复机器人末端同患肢之间的相互作用进行在线调整,使之能适应患肢病情的变化。仿真实验结果表明,本文提出的控制策略能够较好地改善系统的动态性能,使系统具有较好的平滑性和稳定性。

参考文献

- [1] Lum P S, Burgar G. The MIME robotic system for upper-limb neuro-rehabilitation: results from a clinical trial in subacute stroke. In: Proceedings of the 9th International Conference on Rehabilitation Robotics, Chicago, USA, 2005. 511-514
- [2] Ju M S, Lin C C K, Lin D H, et al. A rehabilitation robot with force-position hybrid fuzzy controller: hybrid fuzzy control of rehabilitation robot. *IEEE Trans on Neural Systems Rehab Eng*, 2005, 13(3):349-358
- [3] Patton J L, Mussa-Ivaldi F A. Robot-assisted adaptive training: custom force fields for teaching movement patterns. *IEEE Trans on Biomed Eng*, 2004, 51(4):636-646
- [4] Kiguchi K, Rahman M H, Sasaki M, et al. Development of a 3 DOF mobile exoskeleton robot for human upper-limb motion assist. *Robotics and Autonomous Systems*, 2008, 56: 678-691
- [5] Krebs H I, Hogan N, Aisen M L, et al. Robot-aided neurorehabilitation. *IEEE Trans Rehab Eng*, 1998, 6(1):75-87

- [6] Richardson R, Brown M, Bhakta B, et al. Design and control of a three degree of freedom pneumatic physiotherapy robot. *Robotica*, 2003, 21(6):589-604
- [7] Tsuji T, Tanaka Y. On-line learning of robot arm impedance using neural networks. *Robotics and Autonomous Systems*, 2005, 52(4):257-271
- [8] Xu Z, Fang G. Fuzzy-neural impedance control for robots. *Lecture Notes in Control and Information Sciences*, 2004, 299: 263-275
- [9] Kiguchi K, Tanaka T, Fukuda T. Neuro-fuzzy control of a robotic exoskeleton with EMG signals. *IEEE Trans on Fuzzy Systems*, 2005, 12(4):481-490
- [10] Lee C H, Teng C C. Identification and control of dynamic systems using recurrent fuzzy neural networks. *IEEE Trans on Fuzzy Systems*, 2000, 8(4): 346-349
- [11] Lin C C, Ju M S, Lin C W, et al. The pendulum test for evaluating spasticity of the elbow joint. *Arch Phys Med Rehabil*, 2003, 84(1):69-74
- [12] Noritsugu T, Tanaka T. Application of rubber artificial muscle manipulator as a rehabilitation robot. *IEEE/ASME Trans on Mechatronics*, 1997, 2(4):259-267
- [13] Liu S, Wang Y, Zhu Q. Development of a new EDRNN procedure in control of human arm trajectories. *Neurocomputing*, 2008, 72:490-499
- [14] Koenig A, Williams J, Pekarek S. Optimization of an automotive generator using evolutionary programming. In: Proceedings of the 58th IEEE International Conference on Vehicular Technology, Orlando, USA, 2003. 3212-3219
- [15] 赵钰,李恩江. 现代偏瘫治疗学. 北京:人民军医出版社,1996. 181-186

Adaptive impedance control based on evolutionary dynamic recurrent fuzzy neural network for upper-limb rehabilitation robots

Xu Guozheng, Song Aiguo, Li Huijun

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096)

Abstract

In consideration of the fact that when an upper-limb robot-aided rehabilitation system works the change of the impaired limb's physical condition often has influence on the system's rehabilitation training efficiency, the paper studies the existing impedance control methods for upper-limb rehabilitation robots, and on the basis of this a new adaptive impedance control strategy based on evolutionary dynamic recurrent fuzzy neural network (EDRFNN) is proposed. The strategy uses an on-line identification method to estimate the impaired limb's mechanical impedance parameters, and uses the EDRFNN to dynamically regulate the target impedance control parameters. In the regulating, the hybrid evolutionary algorithm is applied to offline optimize desired impedance control parameters, and then the dynamic back-propagation (BP) algorithm designed based on the Lyapunov theory is used to further on-line adjust the target impedance control parameters. The analysis and simulation results indicate that the proposed algorithm is much more stable and robust than other impedance control methods.

Key words: rehabilitation robot, dynamic recurrent, fuzzy neural network, evolutionary algorithm, on-line identification, adaptive impedance control