

# 柔性关节微操作机器人自适应模糊预测控制<sup>\*</sup>

师五喜<sup>1</sup> 霍伟<sup>1</sup>

吴宏鑫<sup>2</sup>

(1. 北京航空航天大学第七研究室, 北京 100083)

(2. 北京控制工程研究所科技委, 北京 100080)

**摘要** 对一种柔性关节微操作机器人系统提出了多输入多输出直接自适应模糊广义预测控制方法, 此方法先基于机器人理论模型设计出广义预测控制器, 再构造直接自适应模糊控制器逼近广义预测控制器, 并用机器人视觉误差信息对控制器参数和广义误差向量估计值中的未知向量进行自适应调整, 以增强对建模误差的鲁棒性, 并证明了所设计的控制器可使微操作机器人跟踪时变参考轨迹时的广义误差估计值收敛到原点的小邻域内, 以达到控制要求. 仿真结果验证了此方法的有效性.

**关键词** 微操作机器人, 广义预测控制, 自适应模糊控制

## 引言

随着科学技术的飞速发展, 微操作机器人的应用越来越广. 这类机器人大都采用柔性关节, 难以建立精确数学模型, 给其控制器设计带来很大困难.

文[1]对北京航空航天大学机器人所研制的微操作机器人提出了基于显微视觉的伺服控制方法, 利用视觉系统得到的误差信息, 通过雅可比阵反算出压电驱动器应有的伸长量, 再控制它达到期望伸长. 这种方法是间接利用视觉信息, 且需有测量伸长量的应变传感器. 本文对上述柔性关节微操作机器人设计了直接自适应模糊广义预测控制方法, 此方法先基于机器人理论模型设计出利用视觉误差信息的多输入多输出广义预测控制律, 然后为克服建模不确定性用自适应模糊逻辑系统逼近上述控制律, 并利用广义误差向量估计值对控制器参数和广义误差向量估计值中的未知量进行自适应调整, 构成一种直接自适应模糊广义预测控制器. 这一方法的优点是: 对模型的高度不确定性有良好鲁棒性; 直接利用视觉误差调整控制器, 节省了计算量; 不需要应变测量装置, 降低了机器人制造成本.

## 1 微操作机器人的结构描述及运动学模型

本文研究的微操作机器人结构是一并联 Delta 机构(图 1), 由上下两个等边三角形平台组成, 两

平台间由三个尺寸相同的并联运动链连接. 每条运动支链由一杆件和一平行四边形机构串联而成, 与上下平台经柔性铰链  $E$  和  $A$  相连, 杆件和平行四边形机构经柔性铰链  $B$  相连.

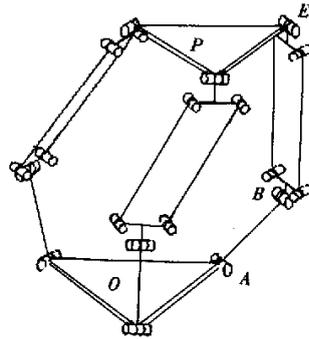


图 1 微操作机器人 Delta 机构

Fig. 1 Delta mechanism of the micromanipulator

对每一支链, 坐标系  $O$ - $XYZ$  的原点建在下平台中心  $O$ ,  $X$  轴沿  $OA_i$  方向,  $Z$  轴沿平台平面的法线并指向上平台,  $Y$  轴按右手坐标系确定(图 2). 上平台中心  $P$  为运动输出点, 其坐标为  $(x, y, z)$ . 杆件  $A_i B_i$  的输入角  $\theta_{i1}$  ( $i=1, 2, 3$ ) 的改变通过压电陶瓷驱动杆  $A_i B_i$  绕柔性铰转动来实现. 设  $u$  为三路压电陶瓷驱动电压组成的向量, 由文[2]知微操作机器人运动学输入输出关系的理论模型为

2003-09-03 收到第一稿, 2003-10-09 收到修改稿.

\* 国家自然科学基金重点资助项目(60034010).

$$\Delta P = J_s \begin{bmatrix} d_1 & 0 & 0 \\ 0 & d_2 & 0 \\ 0 & 0 & d_3 \end{bmatrix} u \quad (1)$$

其中  $\Delta P = [\Delta x, \Delta y, \Delta z]^T$ ,  $d_i$  是伸长系数,  $J_s = J/l_0$ ,  $l_0$  为压电陶瓷运动输入点位置与柔性铰链回转中心间的距离,  $J$  是机器人的雅可比阵, 其表达式详见文[2].

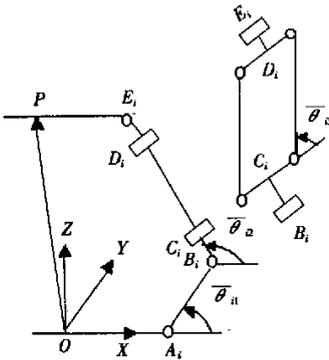


图 2 运动支链简图  
Fig. 2 A kinematic subchain

### 2 预测模型及预测控制律推导

机器人的操作目标需经显微视觉系统放大, 受显微光路结构限制, 视觉系统只能获得平面视觉信息, 故只考虑 XY 平面的运动, 将(1)离散化为

$$y(k+1) = y(k) + T J_{s2} \begin{bmatrix} d_1 & 0 & 0 \\ 0 & d_2 & 0 \\ 0 & 0 & d_3 \end{bmatrix} u(k) \quad (2)$$

其中  $y(k) = [x(k), y(k)]^T$ ,  $T$  为采样周期,  $J_{s2}$  是  $J_s$  前两行. 从上式递推地得到预测方程

$$Y = GU + Fy(k) \quad (3)$$

其中

$$Y = \begin{bmatrix} y(k+1) \\ y(k+2) \\ \vdots \\ y(k+N) \end{bmatrix}, G = T \begin{bmatrix} G_0 \\ G_0 & G_0 \\ \vdots & \vdots & \ddots \\ G_0 & G_0 & \dots & G_0 \end{bmatrix}$$

$$G_0 = J_{s2} \begin{bmatrix} d_1 & 0 & 0 \\ 0 & d_2 & 0 \\ 0 & 0 & d_3 \end{bmatrix}, U = \begin{bmatrix} u(k) \\ u(k+1) \\ \vdots \\ u(k+N-1) \end{bmatrix}$$

$$F = [1 \quad \dots \quad 1]^T$$

取性能指标函数

$$J = \sum_{j=1}^N \|y(k+j) - y_r(k+j)\|^2 + \sum_{j=1}^N \|u(k+j-1)\|_{\lambda}^2 \quad (4)$$

其中  $\|u\|_{\lambda}^2 = u^T \Lambda u$ ,  $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \lambda_3\}$  是控制加权矩阵,  $y_r(k)$  是期望轨线,  $N$  是预测时域. 定义  $Y_r = [y_r^T(k+1), y_r^T(k+2), \dots, y_r^T(k+N)]^T$ , 则性能指标函数(4)式可写成

$$J = \|Y - Y_r\|^2 + \|u\|_{\lambda}^2 \quad (5)$$

其中  $\Xi = \text{block diag}\{\Lambda\}$ . 把(3)式代入(5)式并对  $U$  求导, 可得使  $J$  最小的控制律为

$$U = (G^T G + \Xi)^{-1} G^T [Y - Fy(k)] \quad (6)$$

令  $P^T$  是  $U = (G^T G + \Xi)^{-1} G^T$  的前 3 行, 根据滚动优化的思想, 广义预测控制律可写成<sup>[3]</sup>

$$u(k) = P^T [Y_r - Fy(k)] \quad (7)$$

可证明此广义预测控制律具有如下重要性质:

**引理** 定义广义误差向量

$$E_g(k+N) = P^T (Y - Y_r) + Q^T \Xi U \quad (8)$$

其中  $Q^T$  是  $(G^T G + \Xi)^{-1}$  前 3 行, 则  $E_g(k+N) = 0$  当且仅当  $u(k)$  由(7)式定义.

**证** 由(3)式知: (8)式成立当且仅当

$$P^T (GU - Fy(k) - Y_r) + Q^T \Xi U = 0 \quad (9)$$

而利用  $P$  和  $Q$  的定义可算出

$$P^T GU + Q^T \Xi U = [I, 0, \dots, 0] [(G^T G + \Xi)^{-1} G^T G + (G^T G + \Xi)^{-1} \Xi] U = u(k)$$

由此式知: (9)式成立当且仅当(7)式成立. 证毕.

### 3 直接自适应模糊广义预测控制器设计与稳定性分析

因微操作机器人准确的数学模型未知, 控制律(7)无法实施, 故本文用模糊逻辑系统构成的向量逼近(7)式, 所采用的规则库形如<sup>[4]</sup>

$R^{(l)}$ : 如果  $\hat{x}_1$  为  $F_1^l$ , 且  $\dots$ , 且  $\hat{x}_n$  为  $F_n^l$ , 则  $\hat{y}$  为  $G^l$

$$l = 1, 2, \dots, M$$

其中  $M$  为规则库中的模糊规则数,  $[\hat{x}_1, \dots, \hat{x}_n]^T$  是将输入  $X = [x_1, \dots, x_n]^T$  模糊化后所得的模糊变量,  $\hat{y}$  为输出语言变量,  $F_i^l (i=1, \dots, n)$  和  $G^l$  均为模糊集合, 其对应的隶属函数  $\mu_{F_i^l}(x_i)$  和  $\mu_{G^l}(\hat{y})$  均为高斯型. 采用单值模糊产生器, 乘积推理规则和中心平均模糊消除器, 则模糊逻辑系统的输出为<sup>[4]</sup>

$$\hat{f}(X|\Theta) = \Theta^T \Gamma(X) \quad (10)$$

其中  $\Theta = [\theta_1, \dots, \theta_M]^T$ ,  $\theta_l = \hat{y}^l (y^{-1}$  为  $\mu_{G^l}$  取最大值时所对应的点),  $\Gamma(X) = [\gamma_1(X), \dots, \gamma_M(X)]^T$ ,  $\gamma_l(X)$

$= [\prod_{i=1}^m \mu_{r_i}^*(x_i)] / [\sum_{i=1}^m \prod_{i=1}^m \mu_{r_i}^*(x_i)]$  为模糊基函数.

利用形如(10)式的模糊逻辑系统逼近(7)式的三个分量, 得如下三个自适应模糊广义预测控制器

$$u(k) = \begin{bmatrix} \hat{f}(X(k)|\Theta_1) \\ \hat{f}(X(k)|\Theta_2) \\ \hat{f}(X(k)|\Theta_3) \end{bmatrix} = \begin{bmatrix} \Theta_1^T \Gamma_1(X(k)) \\ \Theta_2^T \Gamma_2(X(k)) \\ \Theta_3^T \Gamma_3(X(k)) \end{bmatrix} \quad (11)$$

其中  $X(k) = y(k) \in U_x \in R^2$ .

由引理知, 使  $E_g(k+N) = 0$  的控制律就是控制律(7), 这表明使序列  $\{\|E_g(k)\|\}$  收敛到零的控制律可收敛到(7)式. 因此若用  $E_g(k)$  对控制器参数  $\Theta_i(k)$  进行自适应调节, 使得序列  $\{\|E_g(k)\|\}$  收敛到零, 就说明模糊广义预测控制器(11)收敛到(7)式, 从而达到控制目的. 但现在准确数学模型未知, 由(8)式知  $E_g(k)$  无法算出, 故只能利用广义误差向量估计值  $\hat{E}_g(k)$  调节控制器参数  $\Theta_i(k)$ , 然后通过保证  $\{\|E_g(k)\|\}$  收敛到原点的小邻域内来达到控制目的. 为此据(8)式定义广义误差向量估计值

$$\hat{E}_g(k) = \Psi^T(k-N)Z(k-N) \quad (12)$$

其中  $\Psi^T(k) = [\hat{P}^T(k), \hat{Q}^T(k)]$ ,  $\hat{P}$  和  $\hat{Q}$  是  $P$  和  $Q$  的估计值,  $Z(k-N) = [y(k-N+1) - y_r(k-N+1), \dots, y(k) - y_r(k), \Delta u(k-N), \dots, \Delta u(k-1)]^T$ .

采用以下自适应律来调节参数向量  $\Theta_i(k)$ :

$$\Theta_i(k) = \begin{cases} \Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}, \\ \text{当 } \left\| \Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \right\| \leq M_i^1, \\ P_1 \{ \Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \}, \\ \text{当 } \left\| \Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \right\| > M_i^1 \end{cases} \quad (13)$$

其中  $\hat{E}_{g_i}$  是  $\hat{E}_g$  的第  $i$  个分量,  $M_i^1$  是设计者取定的正数,  $\|\Theta_i(0)\| \leq M_i^1, \dots, \|\Theta_i(-N+1)\| \leq M_i^1, \alpha_i$  是自适应学习率. 投影算子  $P_1$  定义为<sup>[5]</sup>

$$P_1 \{ \Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \} = M_i^1 \frac{\Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}}{\|\Theta_i(k-N) - \frac{\alpha_i \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}\|}$$

令  $\Psi_i$  是  $\Psi^T$  的第  $i$  行, 采用如下的自适应律来调节参数向量  $\Psi_i$ :

$$\Psi_i(k) =$$

$$\begin{cases} \Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}, \\ \text{当 } \left\| \Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \right\| \leq M_i^2, \\ P_2 \{ \Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \}, \\ \text{当 } \left\| \Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \right\| > M_i^2 \end{cases} \quad (14)$$

其中  $M_i^2$  是设计者取定的正数,  $\|\Psi_i(0)\| \leq M_i^2, \dots, \|\Psi_i(-N+1)\| \leq M_i^2, \alpha_i^2$  是自适应学习率. 投影算子  $P_2$  定义为

$$P_2 \{ \Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)} \} = M_i^2 \frac{\Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}}{\|\Psi_i(k-N) - \frac{\alpha_i^2 \hat{E}_{g_i}(k) \Gamma_i(X(k-N))}{(1 + \|Z(k-N)\|^2)}\|}$$

**定理** 若微操作机器人满足  $\|u(k)\|$  有界时  $\|y(k)\|$  有界, 采用自适应模糊广义预测控制器(11), 参数  $\Theta_i(k)$  和  $\Psi_i(k)$  的自适应调节律取为式(13)和(14), 则当  $\alpha_i^1 > 0, \alpha_i^2 > 0, \alpha_i^1 + \alpha_i^2 \leq 1$  时有

- 1)  $\{\|u(k)\|\}$  和  $\{\|y(k)\|\}$  是有界序列.
- 2)  $\{\|E_g(k)\|\}$  收敛到原点的一个小邻域内.

**证** 1) 如果(13)式第一行成立, 则  $\|\Theta_i(k)\| \leq M_i^1$ . 如果(13)式第二行成立, 则  $\|\Theta_i(k)\| = M_i^1$ . 所以对任意  $k > 0$ , 均有  $\|\Theta_i(k)\| \leq M_i^1$ . 同理用(14)式可证, 对任意  $k > 0$ , 均有  $\|\Psi_i(k)\| \leq M_i^2$ . 又由基函数定义知, 任取  $k > 0$ , 均有,  $\|\gamma_i(X(k))\| < 1$ , 故由(11)式知  $\|u(k)\|$  有界. 又由定理假设知  $\|y(k)\|$  有界, 故  $\{\|u(k)\|\}$  和  $\{\|y(k)\|\}$  是有界序列.

2) 利用(3)式和(8)式可算出

$$E_g(k+N) = \begin{bmatrix} \hat{f}(X(k)|\Theta_1) \\ \hat{f}(X(k)|\Theta_2) \\ \hat{f}(X(k)|\Theta_3) \end{bmatrix} - P^T(Y_r - Fy(k)) \quad (15)$$

记  $\Theta_i^* = \operatorname{argmin}_{\Theta_i \in M_i^1} \{ \sup_{X(k) \in U_x} \|\hat{f}(X(k)|\Theta_i) - P_i^T(Y_r - Fy(k))\| \}$ , 最佳逼近误差  $\omega_i(k) = \hat{f}(X(k)|\Theta_i^*) - P_i^T(Y_r - Fy(k))$ ,  $\Phi_{1i} = \Theta_i - \Theta_i^*$ ,  $\Phi_{2i} = \Psi_i - \bar{\Psi}_i$ ,  $\bar{\Psi}_i = [P_i^T, Q_i^T]^T$ , 则由(15)式和(12)式可得

$$\hat{E}_g(k+N) = \begin{bmatrix} \Phi_{11}^T(k-N) \Gamma_1(X(k-N)) \\ \Phi_{12}^T(k-N) \Gamma_2(X(k-N)) \\ \Phi_{13}^T(k-N) \Gamma_3(X(k-N)) \end{bmatrix} +$$

$$\begin{bmatrix} \omega_1(k-N) \\ \omega_2(k-N) \\ \omega_3(k-N) \end{bmatrix} + \begin{bmatrix} \Phi_{21}^T(k-N) \\ \Phi_{22}^T(k-N) \\ \Phi_{23}^T(k-N) \end{bmatrix} \mathbf{Z}(k-N) \quad (16)$$

取函数

$$V(k) = \sum_{i=1}^3 \left[ \frac{1}{\alpha_1^2} \Phi_{1i}^T(k) \Phi_{1i}(k) + \frac{1}{\alpha_2^2} \Phi_{2i}^T(k) \Phi_{2i}(k) \right]$$

以下分情况讨论:

I) 若(13)式第一行和(14)式第一行成立, 则有

$$\Phi_{1i}(k) = \Phi_{1i}(k-N) - \alpha_1 \mathbf{H}_{1i}(\mathbf{X}(k-N)) \bar{\mathbf{E}}_{gi}(k) \quad (17)$$

$$\Phi_{2i}(k) = \Phi_{2i}(k-N) - \alpha_2 \mathbf{H}_{2i}(\mathbf{X}(k-N)) \bar{\mathbf{E}}_{gi}(k) \quad (18)$$

其中  $\mathbf{H}_{1i}(\mathbf{X}(k)) = \Gamma_i(\mathbf{X}(k)) / [1 + \|\mathbf{Z}(k)\|]$ ,  $\mathbf{H}_{2i}(k) = \mathbf{Z}(k) / [1 + \|\mathbf{Z}(k)\|]$ ,  $\bar{\mathbf{E}}_{gi}(k) = \hat{\mathbf{E}}_{gi}(k) / [1 + \|\mathbf{Z}(k-N)\|]$ . 由(17)和(18)式可算出

$$V(k) - V(k-N) =$$

$$\sum_{i=1}^3 [-2\Phi_i^T(k-N)\mathbf{H}_i(\mathbf{X}(k-N)) \cdot \bar{\mathbf{E}}_{gi}(k) + \eta_i(k-N)\bar{\mathbf{E}}_{gi}^2(k)] \quad (19)$$

其中  $\Phi_i^T = [\Phi_{1i}^T, \Phi_{2i}^T]$ ,  $\mathbf{H}_i^T = [\mathbf{H}_{1i}^T, \mathbf{H}_{2i}^T]$ ,  $\eta_i = \alpha_i \|\mathbf{H}_{1i}\|^2 + \alpha_i^2 \|\mathbf{H}_{2i}\|^2$ . 又由(16)式知

$$\Phi_i^T(k-N)\mathbf{H}_i(\mathbf{X}(k-N)) = \bar{\mathbf{E}}_{gi}(k) - \bar{\omega}_i(k-N)$$

其中  $\bar{\omega}_i(k) = \omega_i(k) / [1 + \|\mathbf{Z}(k)\|]$ . 代入(19)式得

$$V(k) - V(k-N) = \sum_{i=1}^3 \{ (-1 + \eta_i(k-N) [\bar{\mathbf{E}}_{gi}(k) - \frac{\bar{\omega}_i(k-N)}{1-\eta_i(k-N)}]^2 - \bar{\mathbf{E}}_{gi}^2(k) + \frac{\bar{\omega}_i^2(k-N)}{1-\eta_i(k-N)}) \} \quad (20)$$

而  $\|\mathbf{H}_{1i}(\mathbf{X}(k-N))\| < 1$ ,  $\|\mathbf{H}_{2i}(\mathbf{X}(k-N))\| < 1$ , 所以  $-1 + \eta_i(k-N) < 0$ , 因此由(20)式可得

$$V(k) - V(k-N) = -\|\mathbf{E}_g(k)\|^2 + \sum_{i=1}^3 \frac{\bar{\omega}_i^2(k-N)}{1-\eta_i(k-N)} \quad (21)$$

II) 若(13)式第二行和(14)式第一行成立, 由于  $\|\Theta_i^*(k)\| \leq M_1^*$ , 对(13)式中的投影算法有

$$\|\Theta_i(k) - \Theta_i^*\|^2 < \|\Theta_i(k-N) - \frac{\alpha_i \hat{\mathbf{E}}_{gi}(k) \Gamma_i(\mathbf{X}(k-N))}{(1 + \|\mathbf{Z}(k-N)\|)^2} - \Theta_i^*\|^2$$

由此式及(18)式可得到(19)式, 按 I) 的方法可知(21)式成立.

III) 若(13)式第一行和(14)式第二行成立, 由于  $\|\Psi_i(k) - \bar{\Psi}_i\| \leq M_2^*$ , 对(14)式中的投影算法有

$$\|\Psi_i(k) - \bar{\Psi}_i\|^2 < \|\Psi_i(k-N) - \frac{\alpha_i \hat{\mathbf{E}}_{gi}(k) \Gamma_i(\mathbf{X}(k-N))}{(1 + \|\mathbf{Z}(k-N)\|)^2} - \bar{\Psi}_i\|^2 \quad (22)$$

由此式及(17)式可证明(19)式成立, 按 I) 的方法可知(21)式成立.

N) 若(13)式第二行和(14)式第二行成立, 则(19)和(22)式成立, 按 I) 的方法可知(21)式成立.

综上所述, 对于自适应律(13)和(14)式, 都有(21)式成立. 记  $\max_i \{\sup |\omega_i(k-N)|\} = \epsilon$ , 又  $\|\mathbf{H}_{1i}(\mathbf{X}(k-N))\|$  和  $\|\mathbf{H}_{2i}(k-N)\|$  不能同时趋于 1, 故  $\eta_i(k-N)$  不可能趋于 1. 因  $0 < \eta_i(k-N) < 1$ ,  $W =$

$$\sup \sum_{i=1}^3 1/[1-\eta_i(k-N)] \text{ 有界, 由(21)式得 } V(k) = V(k-N) - [\|\bar{\mathbf{E}}_g(k)\|^2 - \epsilon^2 W]$$

令此式中  $k$  从 1 到  $l$ , 并将所得各式相加得

$$V(l) + V(l-1) + \Delta + V(l-N+1) < V(0) + V(-1) + \Delta + V(-N+1) - [\|\bar{\mathbf{E}}_g(k)\|^2 - \epsilon^2 W]$$

对任意  $k$ , 因  $\|H(k)\|$  和  $\|\Psi_i(k)\|$  有界, 故  $\|\Phi_{1i}(k)\| \|\Phi_{2i}(k)\|$  和有界, 所以  $V(k)$  有界. 对上式取极限后得

$$\lim_{l \rightarrow \infty} \sum_{k=1}^l [\|\bar{\mathbf{E}}_g(k)\|^2 - \epsilon^2 W] \leq V(0) + V(-1) + \dots + V(-N+1) < \infty$$

因级数收敛时其通项必趋于零, 由上式知

$$\lim_{l \rightarrow \infty} [\|\bar{\mathbf{E}}_g(k)\|^2 - \epsilon^2 W] = 0$$

因此当  $k \rightarrow \infty$  时,  $\|\bar{\mathbf{E}}(k)\| \rightarrow \epsilon \sqrt{W}$ , 收敛到原点的邻域内. 根据万能逼近定理<sup>[4]</sup>, 只要采用足够多的模糊规则数,  $\omega_i(k-N)$  会充分小, 从而  $\epsilon$  也是很小的量, 因此  $\|\bar{\mathbf{E}}_g(k)\|$  收敛到原点的小邻域内. 又由于  $1 + \|\mathbf{Z}(k-N)\|$  有界, 所以  $\|\hat{\mathbf{E}}_g(k)\|$  收敛到原点的小邻域内. 证毕.

### 4 仿真研究

由文[2]知: 本文所研究的微操作机器人理论模型中  $d_1 = d_2 = d_3 = 0.0420 \mu\text{m}/\text{V}$ ,

$$\mathbf{J}_i = \begin{bmatrix} -12.5490 & 6.2745 & 6.2745 \\ 0 & -10.8630 & 10.8630 \\ 3.6230 & 3.6230 & 3.6230 \end{bmatrix}$$

设控制目的是使微操作机器人跟踪圆轨迹

$$\begin{cases} x(k) = 0.02 + 0.05\cos 0.04\pi t \\ y(k) = 0.04 + 0.05\sin 0.04\pi t \end{cases}$$

为更好选取  $\Psi_i$  初值, 用理论模型按广义预测控制矩阵求逆法求出  $[\mathbf{P}^T, \mathbf{Q}^T]^T$  的第  $i$  列作为  $\Psi_i(0)$ , 求得  $\Psi_1(0) = [-524, 0, -523, 0, 19944, 27, 27, -27, 13, 13]^T \times 10^{-4}$ ,  $\Psi_2(0) = [262, -454, 261, -453, 27, 19944, 27, 13, -27, 13]^T \times 10^{-4}$ ,  $\Psi_3(0) = [262, 454, 261, 453, 27, 27, 19944, 13,$

13, -27]<sup>T</sup> × 10<sup>-4</sup>.

设计模糊逻辑系统时须确定  $y_1(k)$  和  $y_2(k)$  的取值范围. 为此进行如下的——映射<sup>[6]</sup>:

$$\bar{y}_1(k) = \frac{y_1(k)}{|y_1(k)| + 1}$$

这使得  $\bar{y}_1(k) \in (-1, 1)$ . 对  $y_2(k)$  可做同样映射. 因此模糊逻辑系统输入  $X(k) = [x_1(k), x_2(k)]^T = [\bar{y}_1(k), \bar{y}_2(k)]^T$ , 其中  $x_i$  的隶属函数均取为

$$\mu_1 = \exp\{-\left(\frac{x_i + 1}{0.7}\right)^2\}, \mu_2 = \exp\{-\left(\frac{x_i}{0.7}\right)^2\}$$

$$\mu_3 = \exp\{-\left(\frac{x_i - 1}{0.7}\right)^2\}$$

控制器参数  $\theta_i (i=1, 2, 3)$  的初值通过对理论模型离线训练得到. 按文[4]中方法, 把以上隶属函数中心值作为(7)式的输入, 其输出作为参数向量  $\theta_i$  的训练初值, 然后对理想模型进行仿真训练. 控制算法中  $N=1, \lambda_1=\lambda_2=\lambda_3=0.5, \alpha_1^1=\alpha_1^2=\alpha_1^3=0.6, \alpha_2^1=\alpha_2^2=\alpha_2^3=0.1, M_1^1=8.8, M_2^1=10, T=0.05$ . 取  $t=20$  时  $\theta_i$  的值  $[-1248, 1447, 1862, 17268, -2072, 21442, -2333, -166, 2737]^T \times 10^{-4}$ ,  $[1516, 17172, 2643, -7542, -233, 12201, -3402, -21777, -1141]^T \times 10^{-4}$ ,  $[-1332, -19745, -5659, 20485, 1192, -27399, 6856, 28329, -1183]^T \times 10^{-4}$  为初值  $\theta_i(0)$ .

用以上初值的控制器进行控制仿真, 仿真中真实系统  $J$  的取标定值<sup>[2]</sup>

$$\bar{J}_i = \begin{bmatrix} -3.7341 & 8.4042 & -3.4530 \\ -8.0191 & 0.6764 & 6.2543 \\ -8.5306 & 9.8255 & -7.3426 \end{bmatrix}$$

三路驱动器伸长系数真值为<sup>[2]</sup>  $d_1=0.0445 \mu\text{m}/\text{V}$ ,  $d_2=0.0400 \mu\text{m}/\text{V}$ ,  $d_3=0.0428 \mu\text{m}/\text{V}$ . 图3是从  $(0.03, 0.06)$  出发的跟踪结果, 图4是跟踪误差.

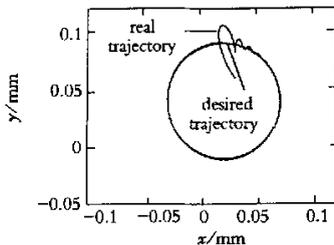


图3 跟踪圆的轨迹

Fig. 3 Trajectory of tracking the circle

本文还对微操作机器人跟踪直线轨迹

$$\begin{cases} x(k) = 0.01 + 0.0027t \\ y(k) = 0.02 + 0.0020t \end{cases}$$

进行了仿真研究. 图5是从点  $(0.01, 0.03)$  出发的跟踪情况, 图6是跟踪误差.

从图中可看出, 尽管理想模型中  $J$  与实际模型  $\bar{J}$  间有很大差别, 但利用理想模型设计的控制器仍使实际系统有很好的控制效果, 说明本文方法有很强的鲁棒性.

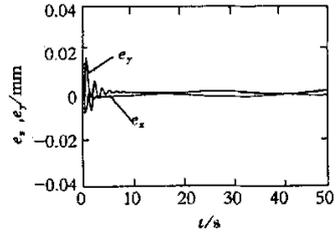


图4 x轴和y轴上的跟踪误差  $e_x$  和  $e_y$

Fig. 4 Tracking errors  $e_x$  and  $e_y$  on x and y axes

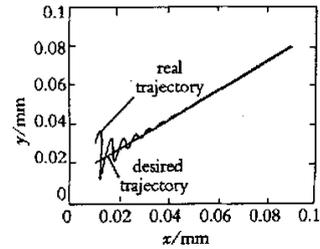


图5 跟踪直线的轨迹

Fig. 5 Trajectory of tracking the straight line

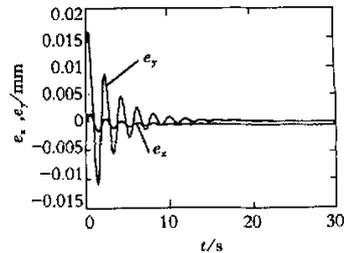


图6 x轴和y轴上的跟踪误差  $e_x$  和  $e_y$

Fig. 6 Tracking errors  $e_x$  and  $e_y$  on x and y axes

### 5 结论

本文对一种柔性关节微操作机器人系统提出了轨迹跟踪的多输入多输出直接自适应模糊广义预测控制方法, 此方法将广义预测控制与自适应模糊相结合, 对系统建模不确定性有良好的鲁棒性, 且基于

视觉误差信息进行控制,减小了实时计算量,并去掉了文[1]方法中的应变测量装置,降低了机器人的制造成本。文中用两个仿真结果验证了所提出方法的有效性。

### 参 考 文 献

- 1 赵玮. 面向生物工程的微操作机器人系统的控制[博士论文]. 北京:北京航空航天大学, 2001(Zhao Wei. Control of micro-manipulator systems for bioengineering, [Ph D Thesis]. Beijing: Beijing University of Aeronautics and Astronautics, 2001(in Chinese))
- 2 毕树生. 面向生物工程的微操作机器人系统研究[博士论文]. 北京:北京航空航天大学, 2002(Bi Shusheng, Research on micro-manipulator systems for bioengineering, [Ph D Thesis]. Beijing: Beijing University of Aeronautics and Astronautics, 2002(in Chinese))
- 3 Wang W. A direct adaptive generalized predictive control algorithm for MIMO systems. *Int J Control*, 1994, 5: 1371~1381.
- 4 王立新. 自适应模糊系统与amp;控制——设计与稳定性分析. 北京:国防工业出版社, 1995 (Wang Lixin. Adaptive Fuzzy Systems and Control — Design and Stability Analysis. Beijing: National Defence Industry Press, 1995(in Chinese))
- 5 Goodwin GC, Sin KS. Adaptive Filtering, Predictive and Control. Englewood Cliffs, NJ: Prentice-Hall, 1984
- 6 Liu GP, Kadirkamanathan V, Billings S. Predictive Control for Nonlinear Systems Using Neural Networks. *Int J Control*, 1998, 5: 1119 ~1132

## ADAPTIVE FUZZY PREDICTIVE CONTROL OF A MICROMANIPULATOR WITH FLEXIBLE JOINTS\*

Shi Wuxi<sup>1</sup> Huo Wei<sup>1</sup> Wu Hongxin<sup>2</sup>

(1. The Seventh Research Division, Beijing University of Aeronautics and Astronautics. Beijing 100083, China)

(2. Science and Technology Committee, Beijing Institute of Control Engineering. Beijing 100080, China)

**Abstract** A multi-input multi-output direct adaptive fuzzy generalized predictive control method for a micromanipulator with flexible joints is presented. First, a generalized predictive controller is designed based on the manipulator's theoretical model. Then, in order to increase the robustness for modeling errors, a direct adaptive fuzzy controller is constructed to approximate the generalized predictive controller, and the fuzzy controller parameters as well as the unknown vectors in the generalized error estimation vector are adjusted adaptively by the use of vision error information. It is proved that, when the micromanipulator tracks a time-varying reference trajectory, the proposed controller forces the norm of the generalized error estimation vector to converge to a small neighborhood of the origin, thus the control requirements can be fulfilled. Simulation results demonstrate the effectiveness of this method.

**Key words** micromanipulator, generalized predictive control, adaptive fuzzy control