

基于阻抗控制的动态装配过程仿真研究¹⁾

黄心汉 杜克林 王 敏 胡建元

(华中理工大学自控系 武汉 430074)

(E-mail: xhhuang@mail.hust.edu.cn)

摘要 机器人化装配是一个复杂的动力学过程，在高速装配时不可避免地会对工件造成损伤。为了寻求解决该问题的有效方法，根据采用阻抗控制方法推导出的装配过程的动力学方程，提出了一种采用径向基函数网络(RBFN)来学习装配过程动力学的渐进学习机制和通过梯度下降法调整阻抗参数的强化学习算法。数值仿真结果证明了该方法的有效性和渐进学习的优越性。

关键词 阻抗控制，装配动力学，梯度下降法，渐进学习，径向基函数网络。

A SIMULATION INVESTIGATION ON DYNAMIC ASSEMBLY PROCESS BASED ON IMPEDANCE CONTROL

HUANG Xinhuan DU Kelin WANG Min HU Jianyuan

(Dept. of Automatic Control Huazhong University of Science and Technology, Wuhan 430074)

Abstract Robotic assembly is a complicated dynamic process. High speed assembly may incur serious damage to robotic systems and workpieces. In order to find out an effective method to resolve the problem, this paper presents a progressive learning strategy of RBFN to learn the dynamics of the assembly process. We then implement an intensified learning algorithm using gradient search method to adjust impedance components. All of the strategies are based on the dynamic equations that are derived on the basis of the concept of impedance control. Computational simulation results are given to demonstrate the effectiveness and advantage of the approach.

Key words Impedance control, assembly dynamics, gradient search method, progressive learning, radial basis function network (RBFN).

1 引言

在自适应控制中，设计参考信号已经成为系统参数稳定收敛的一个中心问题。其稳定条件不仅依赖于控制对象的动力学特性，也依赖于参考对象的激励水平。然而，有时系统并不能被充分地激励，造成系统参数无法收敛到其真值。所以需要一种既允许系统被充分

1) 国家自然科学基金资助项目。

激励,而又处于稳定的策略.文献[1]发展了渐进学习的方法,其思想是逐渐增大被激励的参数空间,这样便可以避免学习的不稳定和发散,加速学习过程,保持理想的性能.传统的学习控制主要集中于研究学习规划及其收敛条件.渐近学习不仅要说明学习规划,还要把它与一系列规划任务相结合,其中任务的复杂程度的变化依赖于学习过程.通过把学习算法与运动速度规划相结合,参数空间可通过改变运动速度有选择性地激发,过大的参数变化可被抑制.文献[2]提出了一个用于训练神经网络使其接近操作手的逆动力学的增量方法.通过逐渐地变化,从逆动力学的易解释区域朝向所要求的动作的轨迹参数来得到接近理想轨迹的训练数据.文献[3]采用LMS树网络,作为对RBF的高维逼近,这允许选择基函数,为局部高斯基,从而在轨迹的一部分进行的训练将不会对在不同部分已学习好了的信息产生不利影响.文献[4]采用自适应强化学习(ARL)算法,用摄动/相关技术来学习内模,用一个RBFN表示内模,比通用的基于模型的学习算法估得的梯度和基于内模的参数变化要平稳,对不确定性和噪声更具鲁棒性.在对简单装配任务的静态柔顺学习的应用可参见文献[5].

阻抗控制着重于从环境的角度来研究机器人动力学行为^[6].采用该方法,当机器人从自由空间向约束空间运动时,控制器结构不需要进行切换.当机器人与环境相互作用时,力反馈环自然封闭,从而避免了由于过大接触力造成的破坏.阻抗控制的目标是要在末端执行器位置 X 和接触力 F 之间,建立一个理想的由设计者指定的动力学关系,定义为目标阻抗.为实施力跟踪,由设计者设定力矢量 F_r ,并且目标阻抗由接触力误差 $E = F_r - F$ 而不是接触力 F 来控制.典型地,目标阻抗被选为一个线性二阶系统以使力误差 E 和末端执行器位置 X 之间的动态关系模拟质量-弹簧-阻尼系统.阻抗控制尤其适合于装配作业^[7].

渐近学习是一个动态过程,其任务的分配在学习过程中动态地变化.对装配问题,文献[1]通过改变运动速度命令,先以低速然后以高速.在低速时,只学习准静态参数;随着运动速度的增加,与动态运动相关的参数被激起并学习.只要运动速度渐近地增加,系统不必同时学习所有的参数,而只需在整个参数空间的一个有限的范围内来精化以前的结果.这极大地简化了该学习问题.本文拟用阻抗控制和渐近学习算法对轴孔装配的动态过程进行仿真研究,这比起文献[1]的把球插入孔中的情形要复杂得多.

2 问题的提出

作者把阻抗控制应用到机器人高速轴孔装配,提出一个具体的算法来学习最优阻抗.如图1(a),在平面内插轴入倒角孔内.控制器给定了轴的质心 G 的名义轨迹, $X_d(t) = [x_d(t), y_d(t), \theta_d(t)]^T$.由于装配过程固有的不确定性,孔并不精确地与轨迹对中,从而轴一般与倒角面相撞.柔顺控制对解决装配过程的几何不确定性是必要的,但对于高速装配还不够.当轴以高速与倒角面相撞时,准静态控制可能无法阻止轴从倒角表面弹起,而导致装配失败^[8].为阻止弹起并正确地引导轴,需要一个动态控制律,如阻抗控制^[6],包括阻尼、惯性及柔顺或刚度项.

如图1(b),轴被以适当的阻抗夹持着实施阻抗控制.设轴的质量为 m_0 ,惯量为 I_0 ,记 $M_0 = \text{diag}(m_0, m_0, I_0)$,则有

$$F + P = M_0 \ddot{X}, \quad (1)$$

式中 $P = (p_x, p_y, p_\theta)$ 是作用于轴上的接触力对 G 点的分量, $F = (f_x, f_y, f_\theta)$ 是受控的驱动机构的力对 G 点的分量. 阻抗控制的目标是通过控制驱动力 F 来模拟理想的机械阻抗. 图1(b)的系统理想的动力学为

$$\begin{aligned} P &= M\ddot{X} + D(\dot{X} - \dot{X}_d) \\ &\quad + K(X - X_d), \end{aligned} \quad (2)$$

式中 M, D, K 分别为理想的惯性、阻尼及刚度矩阵, $X = (x, y, \theta)$. 外力 F 可由装于末端执行器上的力传感器测量. 由式(1),(2)得到阻抗控制律

$$F = M_0 M^{-1} D \Delta \dot{X} + M_0 M^{-1} K \Delta X + (M_0 M^{-1} - I) P, \quad (3)$$

其中 $\Delta X = X_d - X$, $\Delta \dot{X} = \dot{X}_d - \dot{X}$ 分别是位置和速度的误差, P 的确定取决于接触阶段. 假定阻抗矩阵为对角阵

$$K = \text{diag}(k_x, k_y, k_\theta), \quad D = \text{diag}(d_x, d_y, d_\theta), \quad M = \text{diag}(m_x, m_y, m_\theta). \quad (4)$$

3 装配动力学

本文给出基于阻抗控制的理想的动力学关系. 分析中采用如下假设: 1) 恒定的参考速度; 2) 插入方向竖直; 3) 静态和动态摩擦系数相等; 4) 轴和孔都为刚性; 5) 装配系统的侧向偏差总是小于倒角宽度; 6) 倒角孔和非倒角轴.

轴孔接触情况的变化一般有三个阶段^[9]: 倒角相交、一点接触和两点接触, 有时还会在两点接触之后出现一点接触. 实际上, 只有在两点接触阶段动态楔紧和卡阻才会发生. 在倒角相交和一点接触阶段, 不会发生卡阻和楔紧, 但这两个阶段决定两点接触阶段的初始条件.

3.1 倒角相交

如图2(a), 假定坐标系 xoy 定位于倒角的底边缘, 质心 G 点的位置为

$$x = -H_A - L_G \sin \theta + r \cos \theta, \quad y = L_G \cos \theta + r \sin \theta + H_A \tan \alpha. \quad (5)$$

由动力学方程(2), 此时 $P = (K_1, K_2, K_3)^T F_n$, 其中 $K_1 = \sin \alpha - \mu \cos \alpha$, $K_2 = \cos \alpha + \mu \sin \alpha$, $K_3 = (L_G K_1 - r K_2) \cos \theta + (L_G K_2 + r K_1) \sin \theta$, 代入几何约束(5)直至其二阶导数, 消去 F_n 得

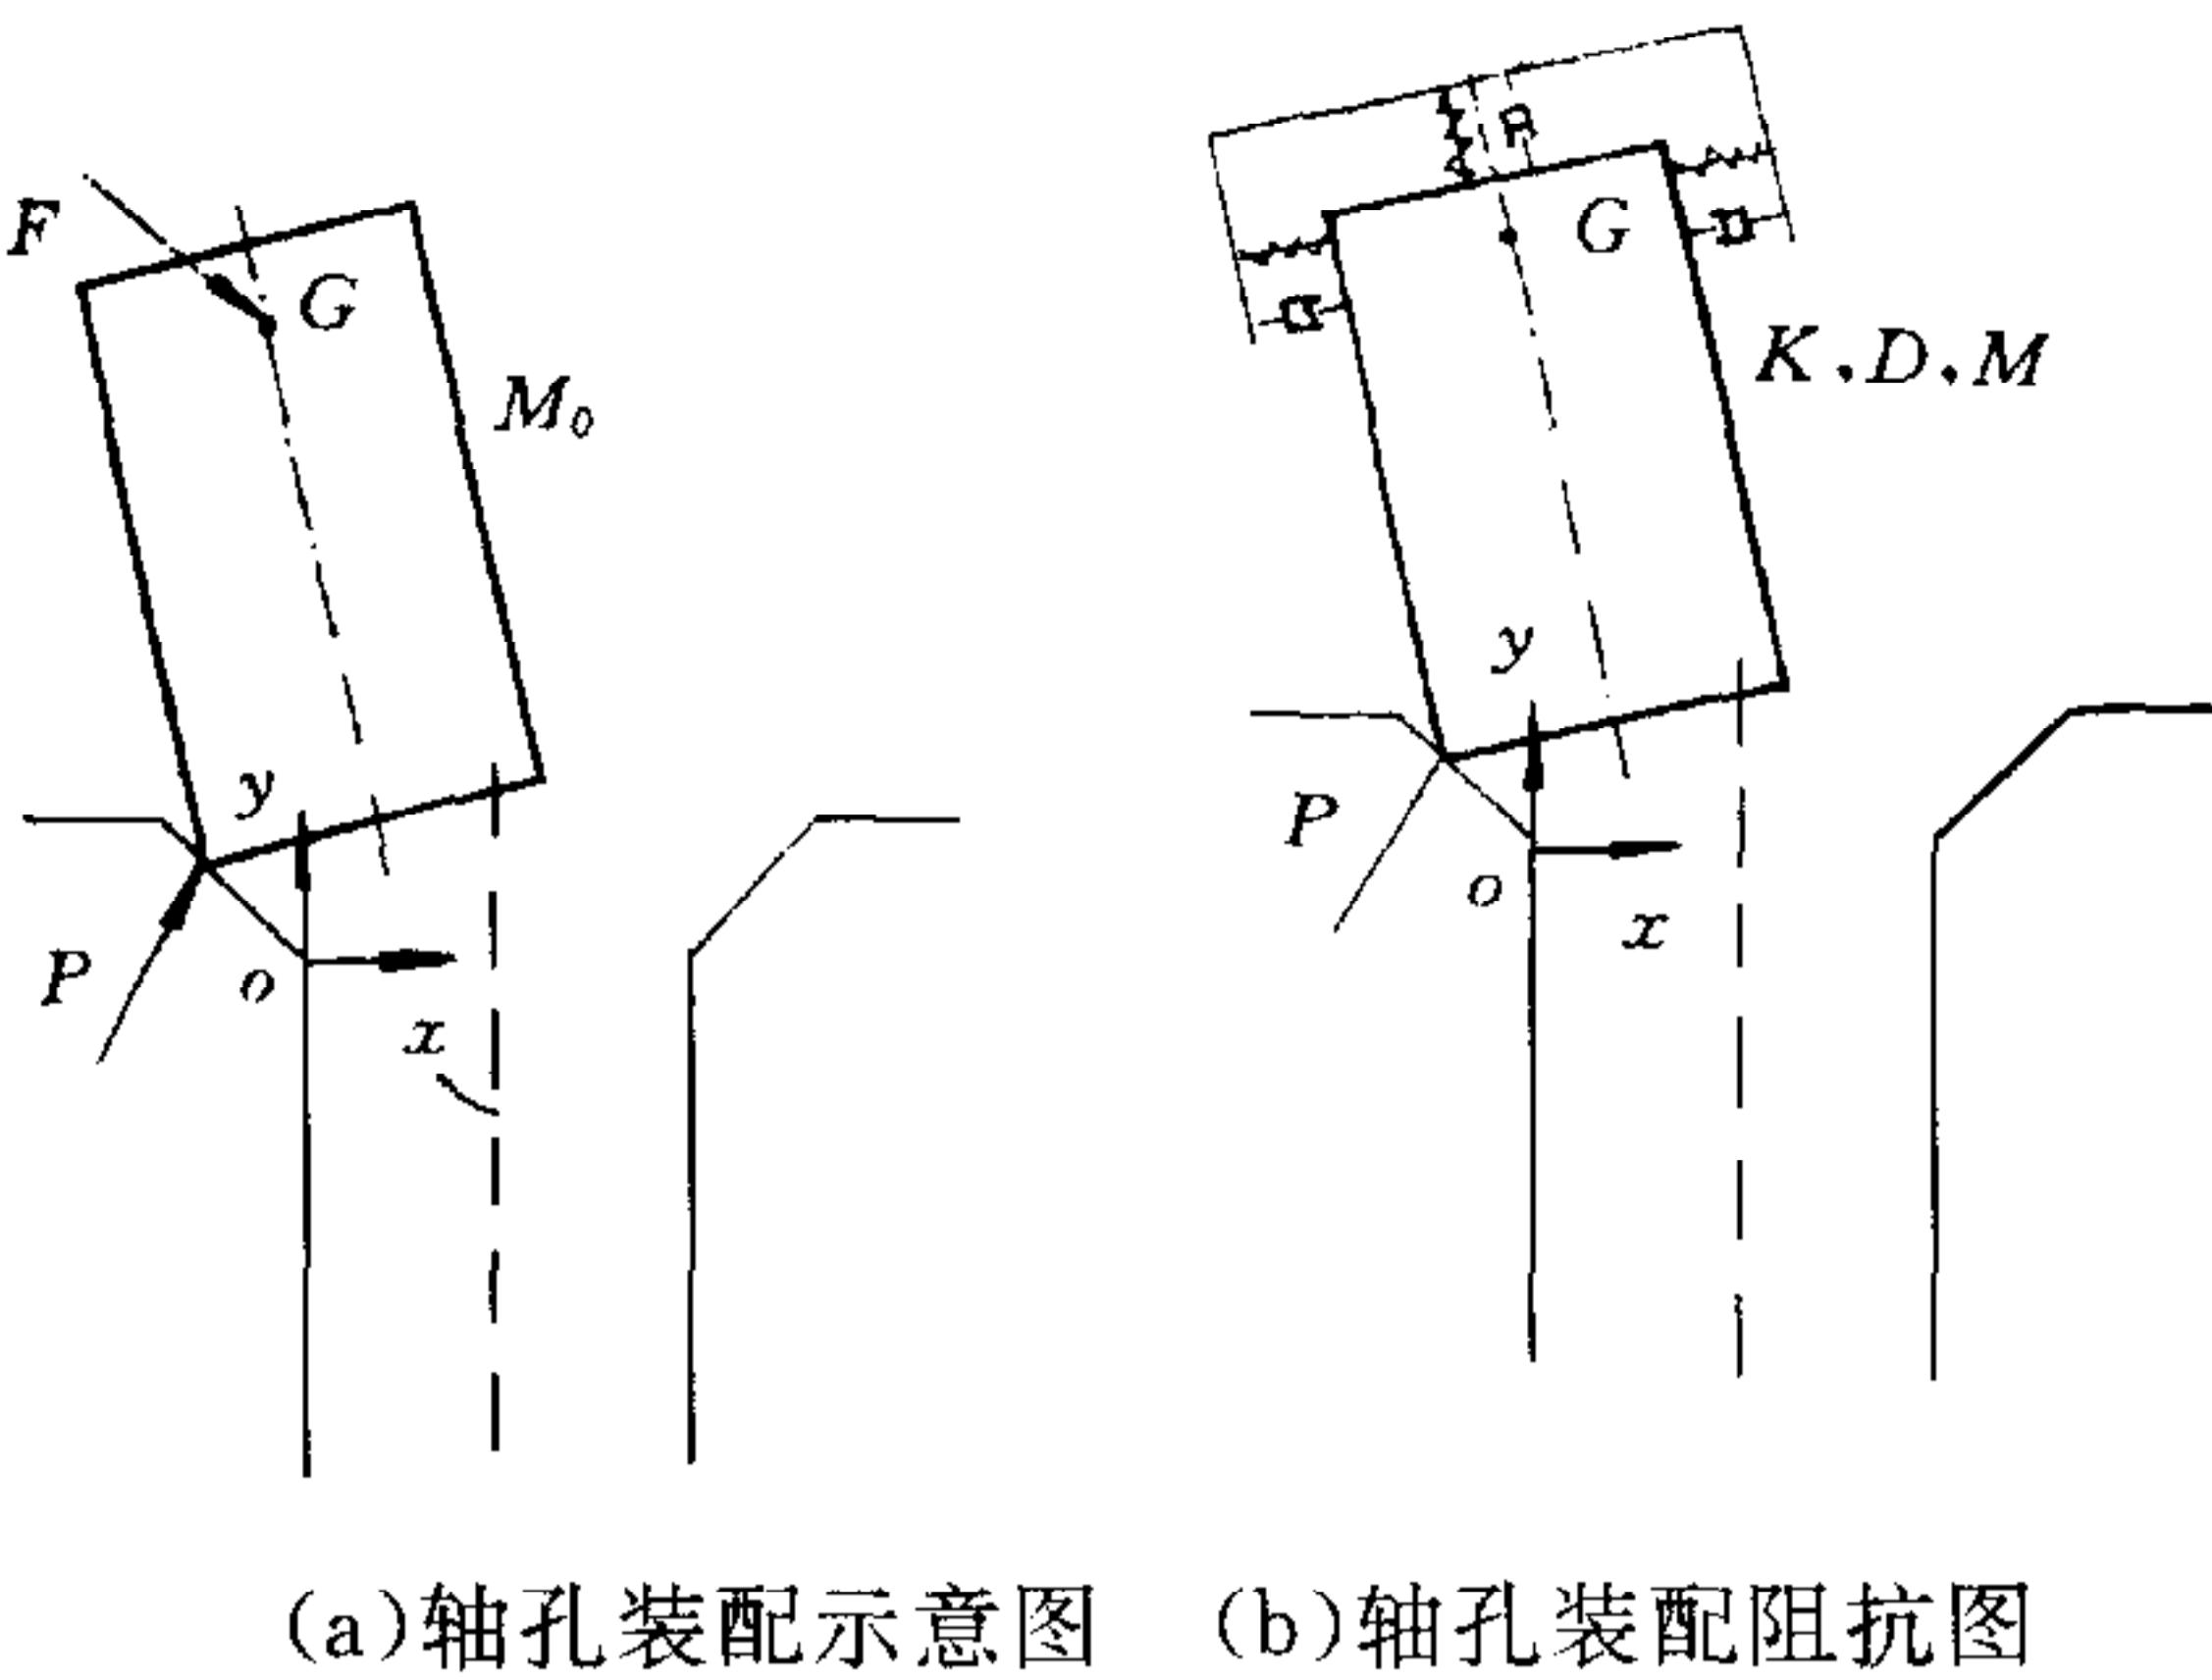
$$\ddot{x} f_1 + \ddot{\theta} f_2 + f_3 = 0, \quad \ddot{x} g_1 + \ddot{\theta} g_2 + g_3 = 0. \quad (6)$$

外力 F_n 由式 $F_n = (m_x \ddot{x} + d_x \dot{x} + k_x x - d_x \dot{x}_d - k_x x_d) / K_1$ 确定.

在装配过程中, 取命令轨迹为 $x_d = x_0 = -H_{A0} - L_G \sin \theta_0 + r \cos \theta_0$, $y_d = y_0 + \dot{y}_{dt} = (L_G \cos \theta_0 + r \sin \theta_0 + H_{A0} \tan \alpha) + \dot{y}_{dt}$, $\theta_d = 0$. 初始条件为 $x(0) = r \cos \theta(0) - L_G \sin \theta(0) - H_A(0)$, $\dot{x}(0) = \dot{x}_0$, $\theta(0) = \theta_0$, $\dot{\theta}(0) = \dot{\theta}_0$, 可求解过程状态. 当 $y_A = 0$ 时, 进入一点接触阶段.

3.2 一点接触

如图2(b), 质心 G 点的位置为



(a) 轴孔装配示意图 (b) 轴孔装配阻抗图

图1 轴孔装配示意图和阻抗图

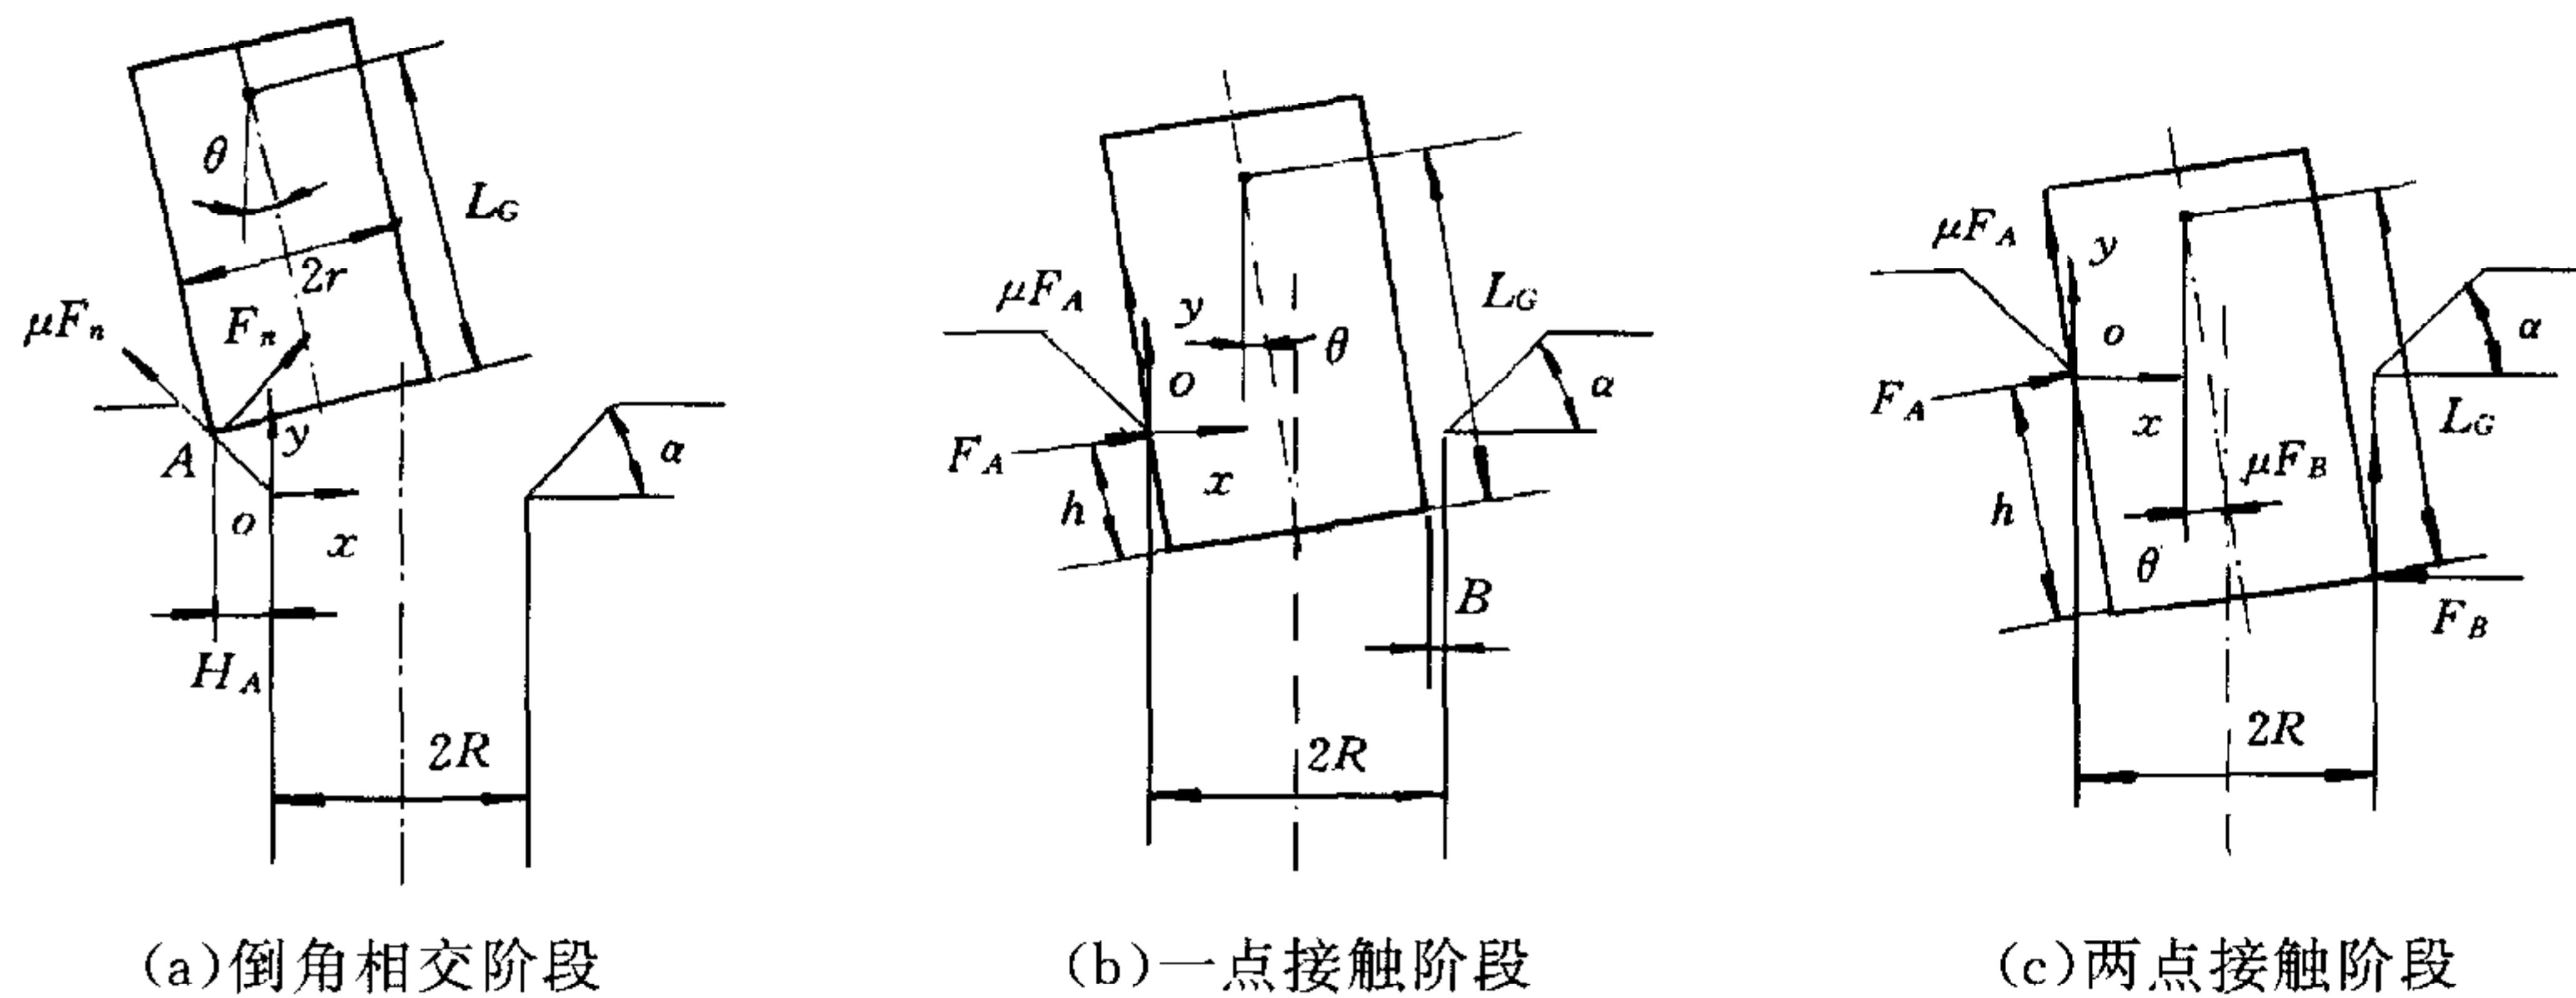


图2 轴孔接触的三个阶段

$$x = r\cos\theta - (L_G - h)\sin\theta, \quad y = (L_G - h)\cos\theta + r\sin\theta. \quad (7)$$

由动力学关系(2), 此时 $P = (K_4, K_5, K_6)^T F_n$, 其中 $K_4 = \cos\theta - \mu\sin\theta$, $K_5 = \sin\theta + \mu\cos\theta$, $K_6 = L_G - h - \mu r$. 代入几何约束(7)直至其二阶导数, 消去 F_n 得到一个形如式(6)的方程. 外力 $F_A = (m_x \ddot{x} + d_x \dot{x} + k_x x - d_x \dot{x}_d - k_x x_d)/K_4$. 初始条件已由前一阶段确定, 可求解得过程状态. 当 $B = 2R - x - r\cos\theta - L_G \sin\theta = 0$ 时, 进入两点接触阶段.

3.3 两点接触

如图2(c), 质心 G 点的位置为

$$x = 2R - A_2, \quad y = A_1 + (2L_G - h)\cos\theta. \quad (8)$$

由动力学关系(2), 此时 $P = (K_4 F_A - F_B, K_5 F_A + \mu F_B, (L_G - h - \mu r) F_A - (L_G K_4 - r K_5) F_B)^T$, 其中 $K_4 = \cos\theta - \mu\sin\theta$, $K_5 = \sin\theta + \mu\cos\theta$. 消去 F_A, F_B , 代入约束(8)直至其求二阶导数得

$$f_1(\theta) \ddot{\theta} + f_2(\theta, t) = 0. \quad (9)$$

相应地外力为

$$\begin{aligned} F_A &= \frac{1}{\mu K_4 + K_5} \{ \ddot{\theta} (\mu m_x A_1 + m_y G_2) + \dot{\theta}^2 (\mu m_x A_2 + m_y G_1) + \dot{\theta} (\mu d_x A_1 + d_y G_2) + \\ &\quad \mu k_x x + k_y y - \mu (d_x \dot{x}_d + k_x x_d) - (d_y \dot{y}_d + k_y y_d) \}, \\ F_B &= \frac{1}{\mu K_4 + K_5} \{ \ddot{\theta} (-K_5 m_x A_1 + K_4 m_y G_2) + \dot{\theta}^2 (-K_5 m_x A_2 + K_4 m_y G_1) + \\ &\quad \dot{\theta} (-K_5 d_x A_1 + K_4 d_y G_2) - K_5 k_x (x - x_d) + K_4 k_y (y - y_d) + K_5 d_x \dot{x}_d - K_4 d_y \dot{y}_d \}. \end{aligned}$$

初始条件已由前一阶段确定. 当插入到指定深度时, 插孔结束. 若在某一时刻 $F_B = 0$, 此时又回到一点接触状态, 可由3.2节解出.

4 梯度跟踪与渐进学习的机制

4.1 梯度跟踪

为实施阻抗学习, 需要一个用于评价控制性能的指标. 在机器人化装配中, 控制目标是机器人把轴插入孔中受到最小的来自孔壁的反作用力, 同时避免卡阻和楔紧. 即需要控

制器紧紧跟踪名义轨迹同时产生尽可能小的反作用力. 从而可取控制器的强化(性能)函数为

$$r = \rho_1(x - x_d)^2 + \rho_2(y - y_d)^2 + \rho_3(\dot{x} - \dot{x}_d)^2 + \rho_4(\dot{y} - \dot{y}_d)^2 + \rho_5\theta^2 + \rho_6\dot{\theta}^2 + \rho_7(p_x^2 + p_y^2) + \rho_8 p_\theta^2, \quad (10)$$

其中 ρ_i 为权参数. 现在的问题是学习式(3)中的阻抗参数 K, D, M , 使 r 取最小值.

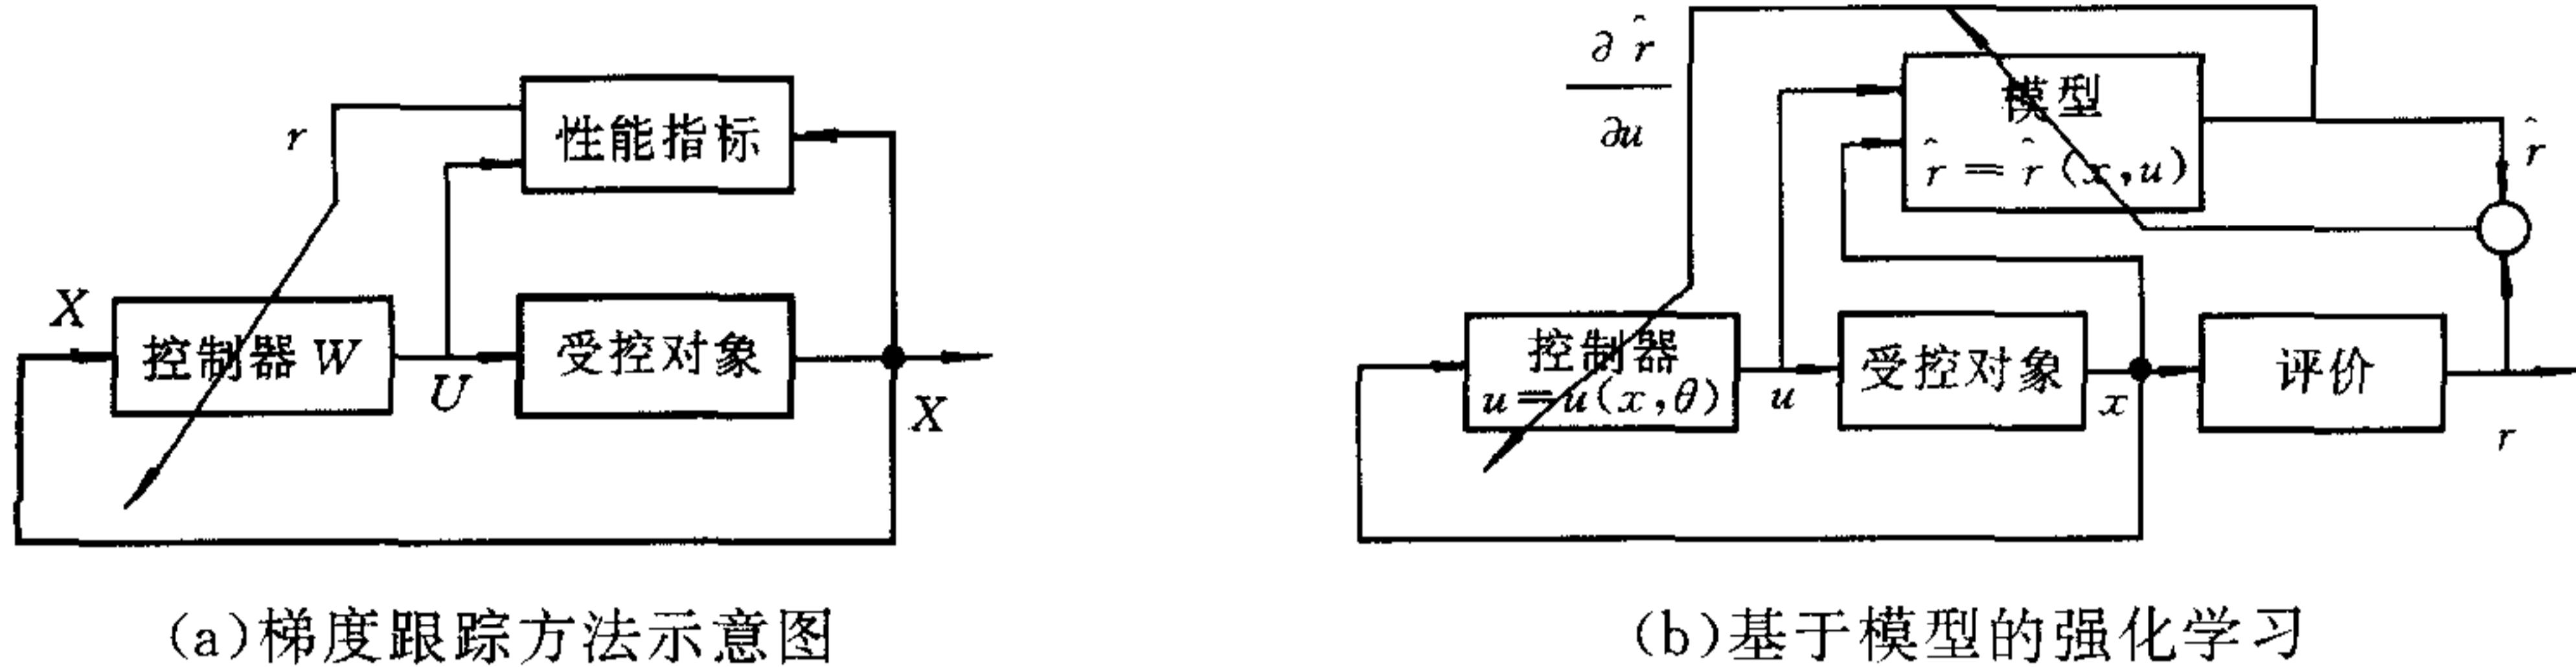


图3 梯度跟踪与强化学习

阻抗参数的学习采用强化学习形式,多数强化学习算法是基于梯度跟踪方法. 图3(a)为学习反馈控制律的梯度跟踪方法的示意图. $W = (w_1, \dots, w_n)^\top$ 是一组控制参数, U 为控制输入, r 为性能指标, X 为反馈信号. 于是, 梯度跟踪的通用规则可表达为

$$\Delta W = -\alpha (\partial r / \partial W)^\top = -\alpha (\partial U / \partial W)^\top (\partial r / \partial U)^\top, \quad (11)$$

式中 α 为学习率.

为了把梯度跟踪规则应用到阻抗控制问题中,并推导出阻抗的学习算法,这里重写式(3)的阻抗控制律,用 \bar{M} 来替代惯性矩阵的逆阵 M^{-1}

$$F = M_0 \bar{M} K \Delta X + M_0 \bar{M} D \Delta \dot{X} + (M_0 \bar{M} - I) P. \quad (12)$$

由式(4), $\bar{M} = \text{diag}(\bar{m}_x, \bar{m}_y, \bar{m}_\theta)$. 通过采用梯度跟踪规则(11), 得到如下的阻抗参数学习规则

$$(\Delta k_x, \Delta k_y, \Delta k_\theta)^\top = -\alpha_K M_0 \bar{M} \text{diag}(\partial r / \partial f_x, \partial r / \partial f_y, \partial r / \partial f_\theta) \Delta X, \quad (13)$$

$$(\Delta d_x, \Delta d_y, \Delta d_\theta)^\top = -\alpha_D M_0 \bar{M} \text{diag}(\partial r / \partial f_x, \partial r / \partial f_y, \partial r / \partial f_\theta) \Delta \dot{X}, \quad (14)$$

$$(\Delta \bar{m}_x, \Delta \bar{m}_y, \Delta \bar{m}_\theta)^\top = -\alpha_M M_0 \text{diag}(\partial r / \partial f_x, \partial r / \partial f_y, \partial r / \partial f_\theta) (K \Delta X + D \Delta \dot{X} + P), \quad (15)$$

其中 r 由式(10)定义; f_x, f_y, f_θ 为受控力对质点 G 的分量; $\alpha_K, \alpha_D, \alpha_M$ 为学习率.

4.2 内模型的局部渐进学习

图3(b)是基于模型的强化学习框图,它采用一个附加的可微网络来预测强化函数(性能指标). 一旦该模型被辨识,梯度跟踪规则于是适用于过程. 通过对内模型输出 \hat{r} 相对于控制 U 进行微分,式(11)中的 $\partial r / \partial U$ 由 $\partial \hat{r} / \partial U$ 代替,得到

$$\Delta \hat{W} = -\alpha (\partial U / \partial W)^\top (\partial \hat{r} / \partial U)^\top. \quad (16)$$

前面已得到了对象的动力学,但对强化的导数仍很难求出,或即使能求出,计算量也非常惊人. 我们仍需要用神经网络来学习内模型. RBFN 与函数逼近理论相吻合,也适应于多变量函数的逼近,且可采用线性优化学习算法获得最优解. 与全局方法相比,局域逼近方法学习速度快,且仅需训练网络输入空间的一部分. 当新的样本提供给网络时,网络仅在样本点邻近修正,使网络的权值在其他区域不变. 而 RBFN 的基函数只覆盖很小的局部区域,该领域的扩展由单元的方差参数来确定,但往往需要更多的网络资源. RBFN 更适合于在线或序列自适应调整,对用于调整的信号出现的次序不敏感^[10].

5 数值仿真

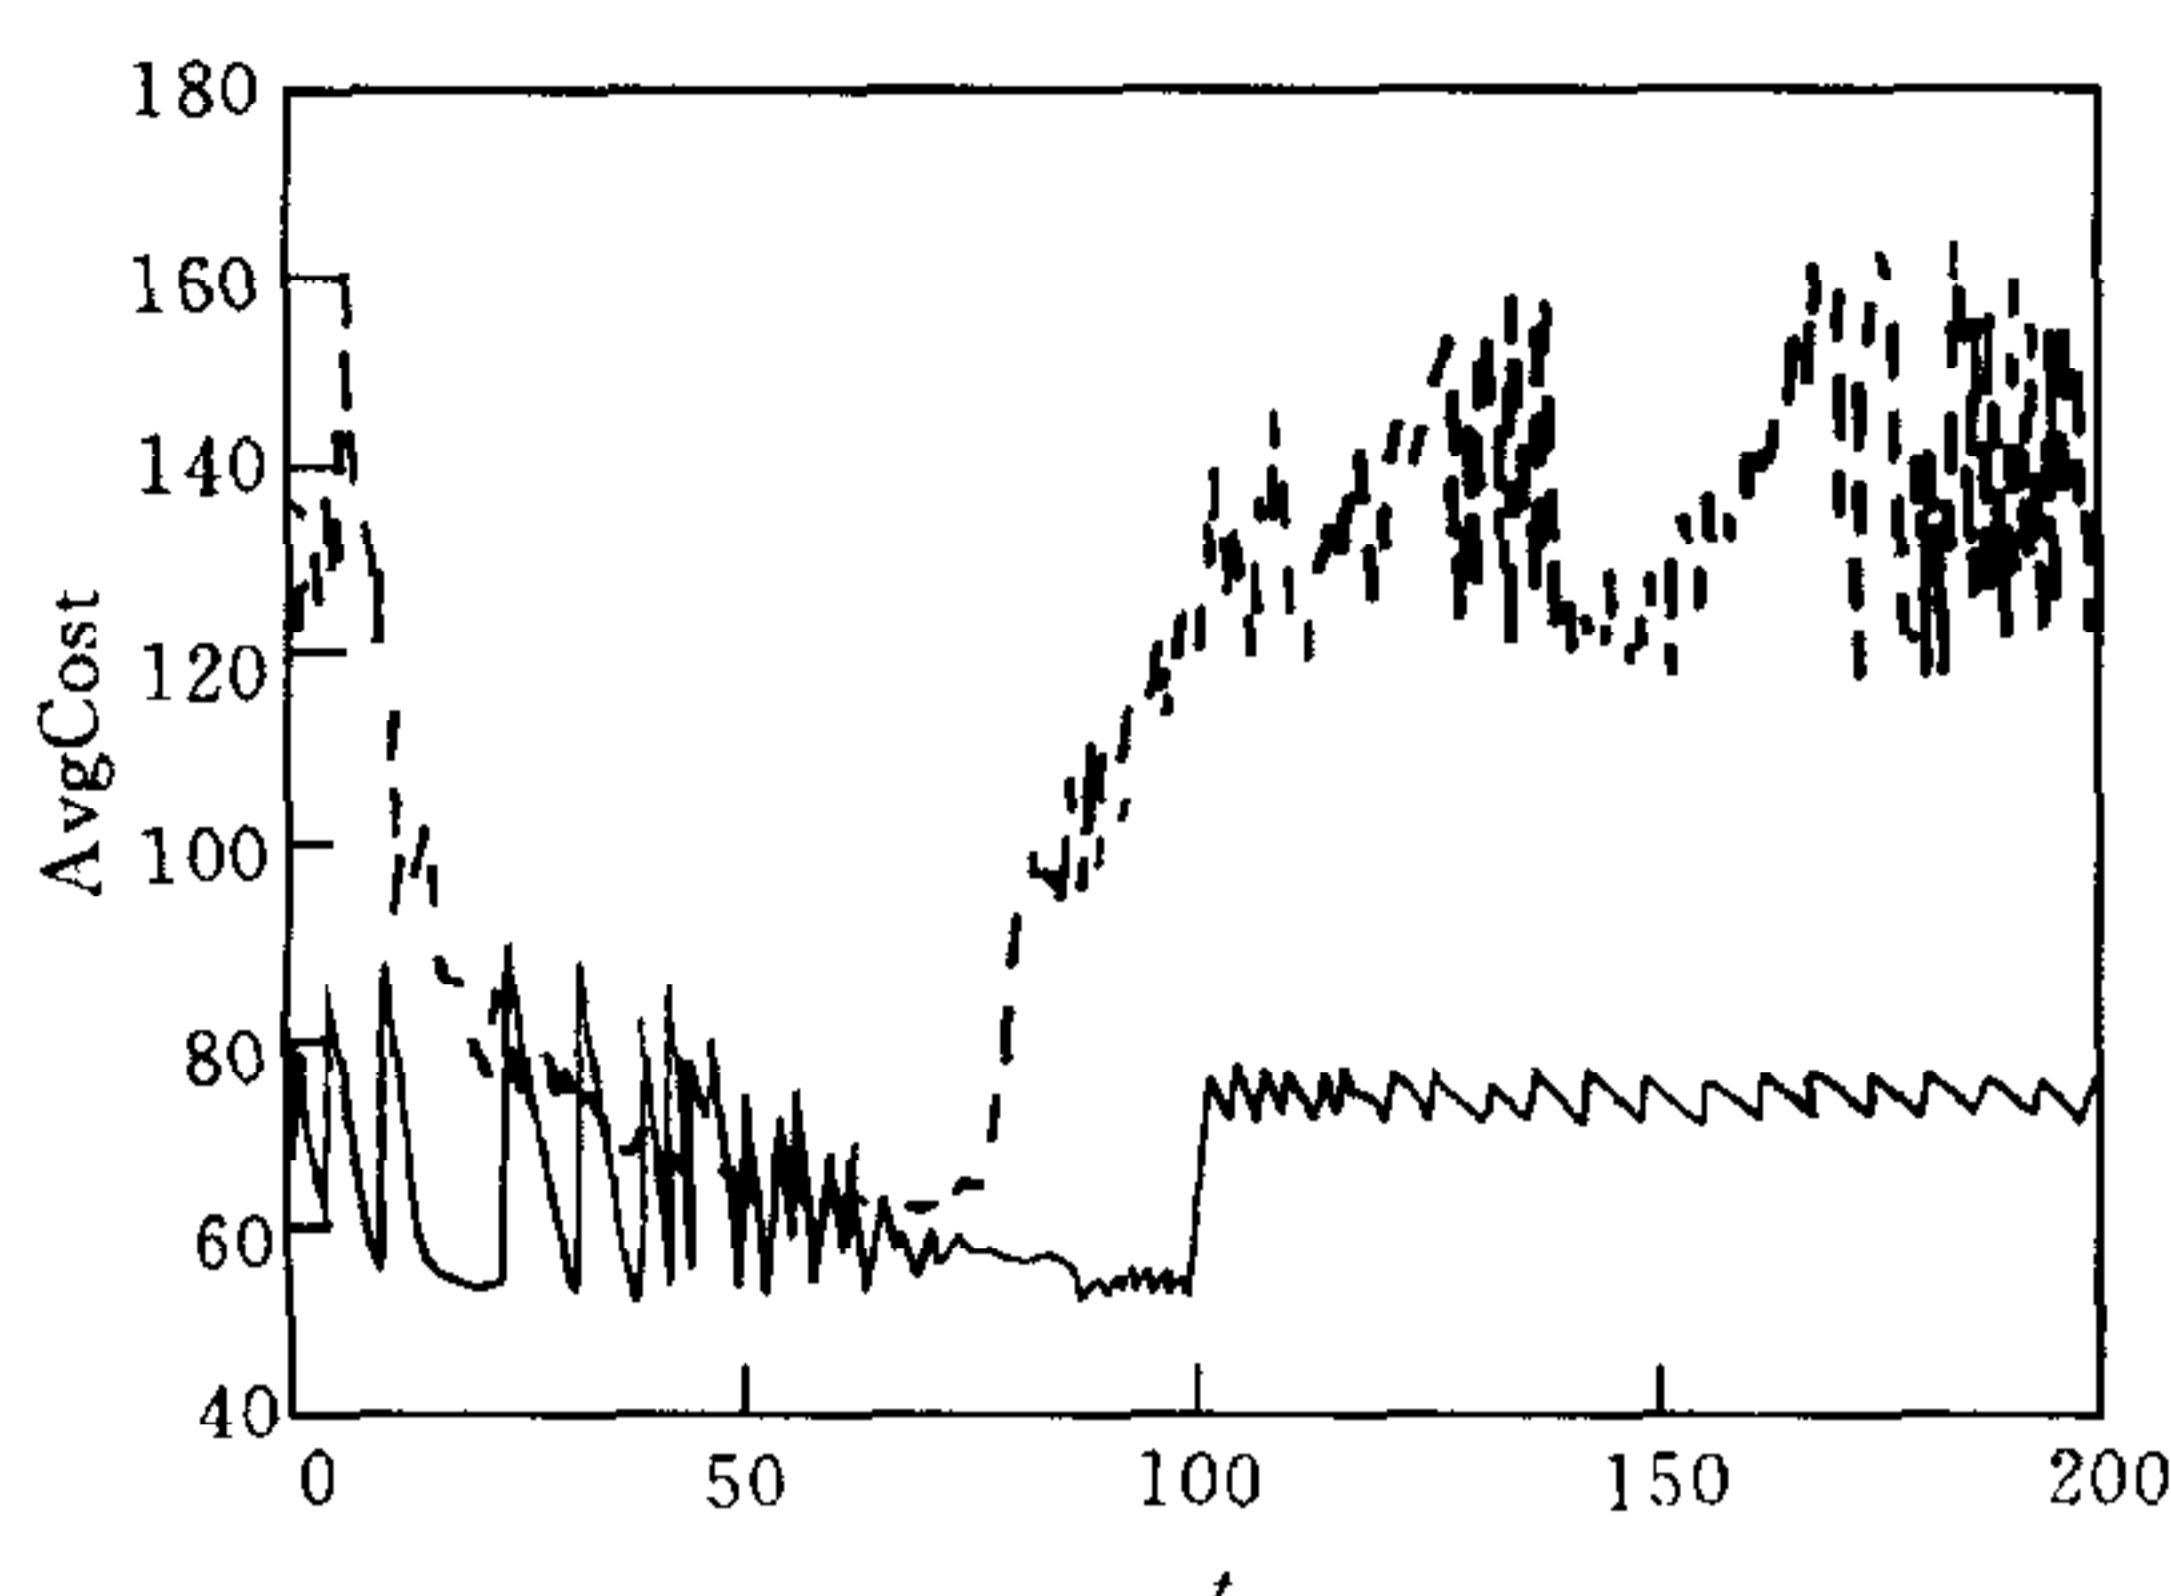


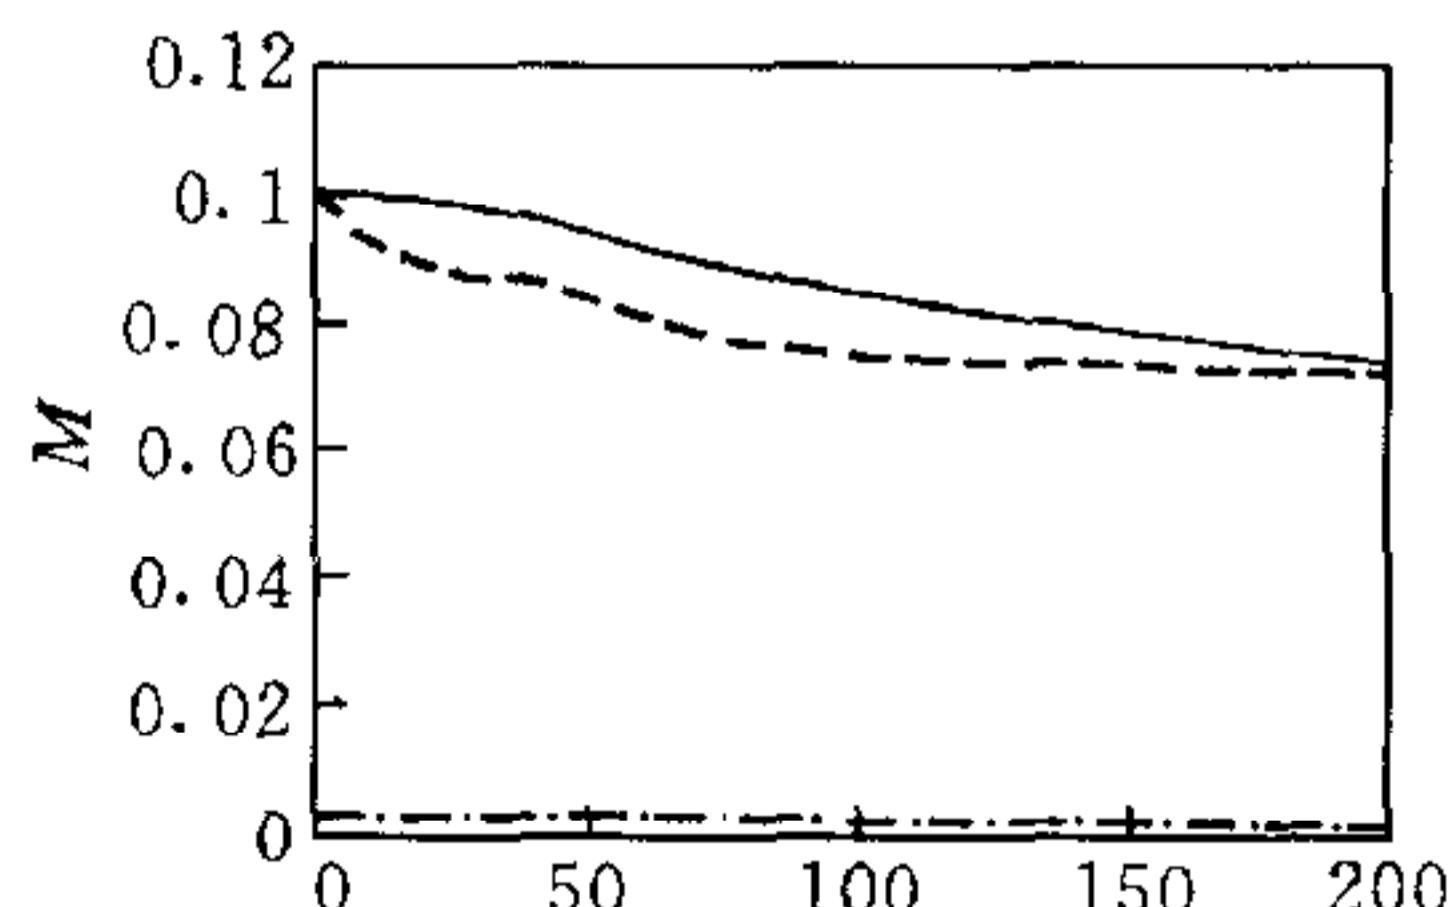
图4 漐进学习和非漐进学习的平均代价函数 \bar{r} 随迭代次数的演化过程

图4为漐进学习和非漐进学习的平均代价函数 \bar{r} 随迭代次数的演化过程.虚线为非漐进学习,实线为漐进学习.从图4可见,在非漐进学习开始时,收敛得很快,而在约75次迭代后,平均代价函数值开始增大并大幅振荡,有不稳定的趋势(或即使收敛其过程也非常缓慢),这对机器人会造成极大的损伤.采用漐进学习时,其稳定性和收敛性就好得多.

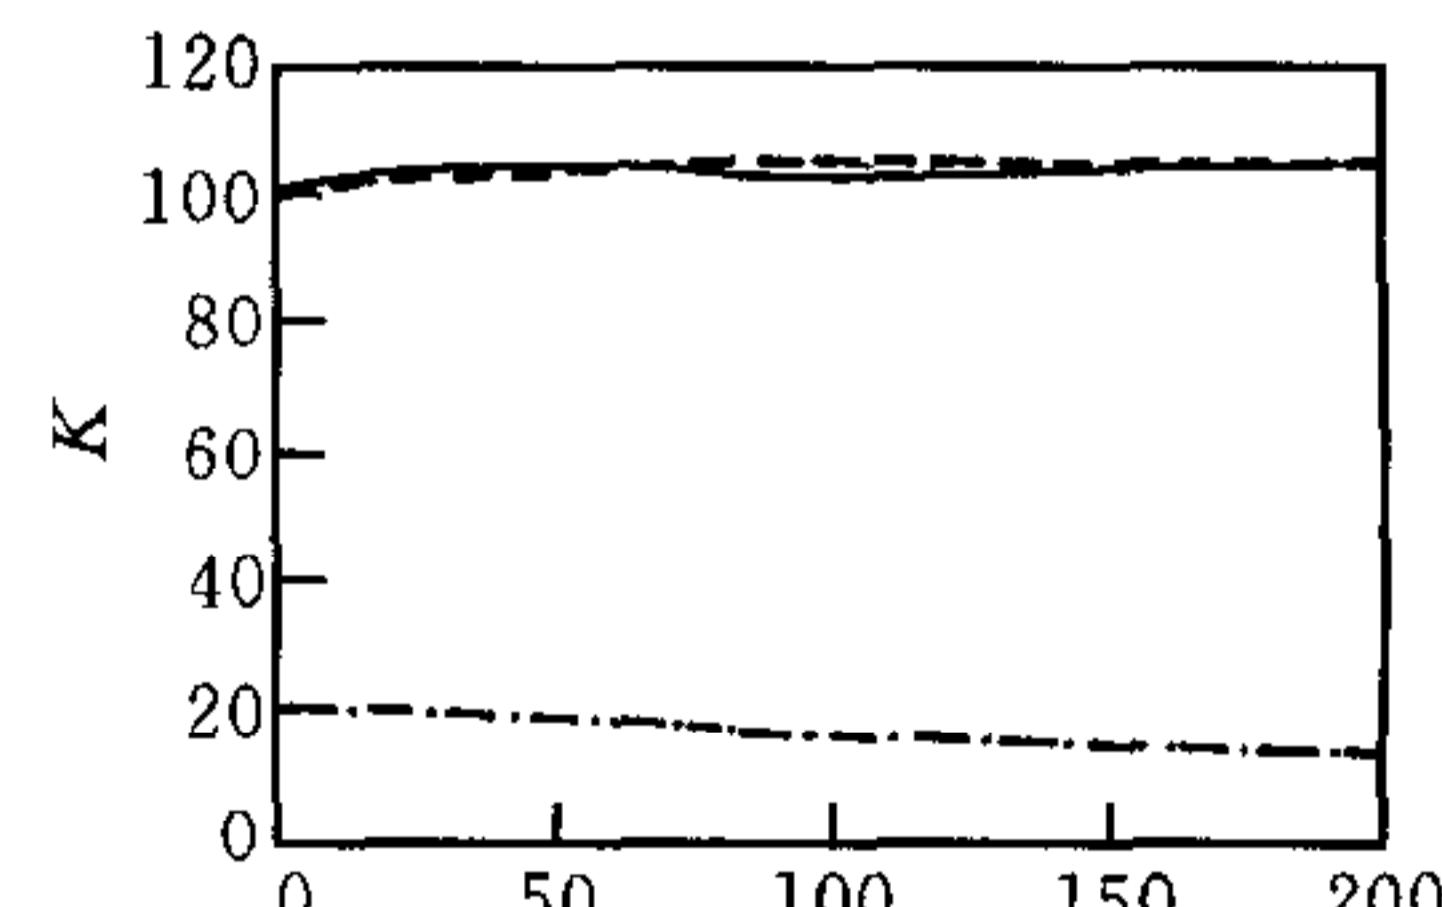
作者还对有关的单项指标,如环境力水平分量 \bar{P}_x ,竖直分量 \bar{P}_y 、力矩 \bar{P}_θ 、轴倾角平均值 $\bar{\theta}$ 、质心速度偏差 $\bar{V}-V_d$ 的演化

过程进行了大量仿真研究.结果表明,漐进学习的效果比非漐进学习的效果要好,对机器人和工件的损伤要小.限于篇幅,仿真曲线从略.

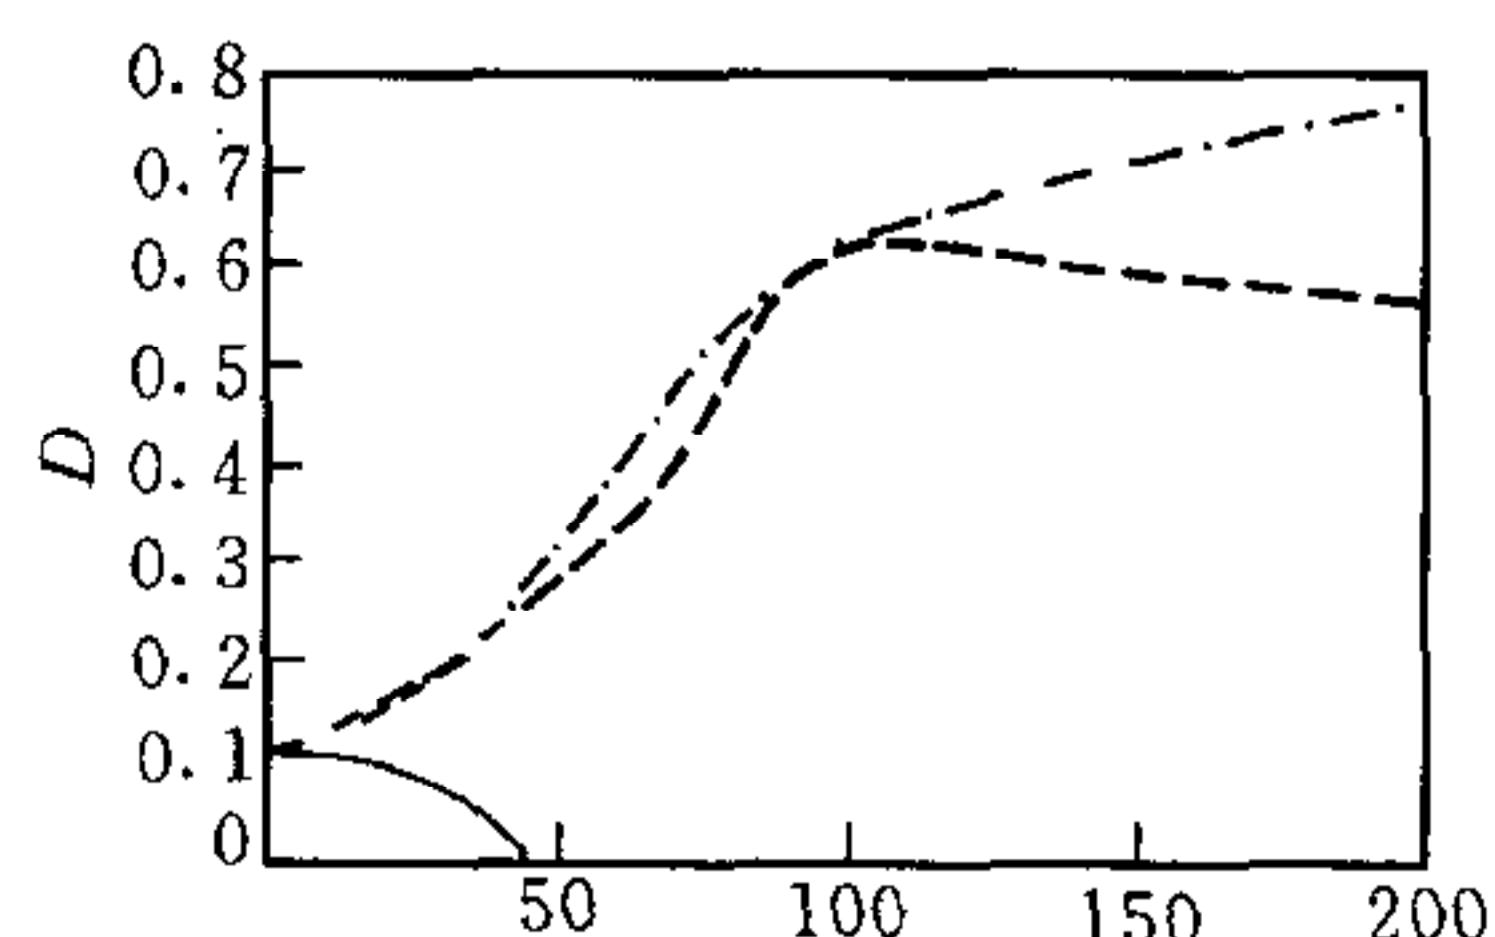
图5(a)~(c)为漐进学习的阻抗随迭代次数的演化.其中实线为 x 分量、虚线为 y 分量、点划线为 θ 分量.阻抗的变化规律取决于代价函数的权系数的取法.必须指出,众多的学习率中只要有任何一个选择得不合理,都有可能使装配过程的学习难以继续,学习过程也只得中断而失败.



(a)惯性 M 随迭代次数的演化



(b)刚度 K 随迭代次数的演化



(c)阻尼 D 随迭代次数的演化

图5 漐进学习的阻抗随迭代次数的演化

图6为系统动力学特性(以倾角 θ 的变化过程为例)在学习前后的效果比较.点划线为学习前的动力学关系,虚线为非漐进学习,实线为漐进学习的结果.可见学习前,装配过程表现出明显的大幅度的振荡,特别是倾角出现负值,这对装配极为不利,还可能会使模型

动力学失效。经过学习,振荡都大大减弱。但采用渐进学习的效果明显优于非渐进学习,轴的倾角比非渐进学习时小。此外,我们还对倾角角速度 $\dot{\theta}$ 、质心水平方向位置 x 、质心水平方向速度 \dot{x} 、质心竖直方向位置 y 、质心竖直方向速度 \dot{y} 的动力学特性进行了仿真研究。结果表明,采用渐进学习的效果明显优于非渐进学习的效果。限于篇幅,仿真曲线从略。

6 结束语

本文对基于阻抗控制的机器人轴孔装配动态过程进行了仿真研究。理论分析和大量仿真结果表明,只要代价函数的权系数和学习率选择合理,渐进学习和非渐进学习都能取得理想的结果。采用非渐进学习时,机器人起初承受较大的平均代价和单项指标,而且过程演化中振荡较大。而采用渐进学习,从整个学习过程来看,机器人的代价值和振荡都较小。渐进学习方法更适合于实时应用,它将会减小对机器人和工件的损伤。

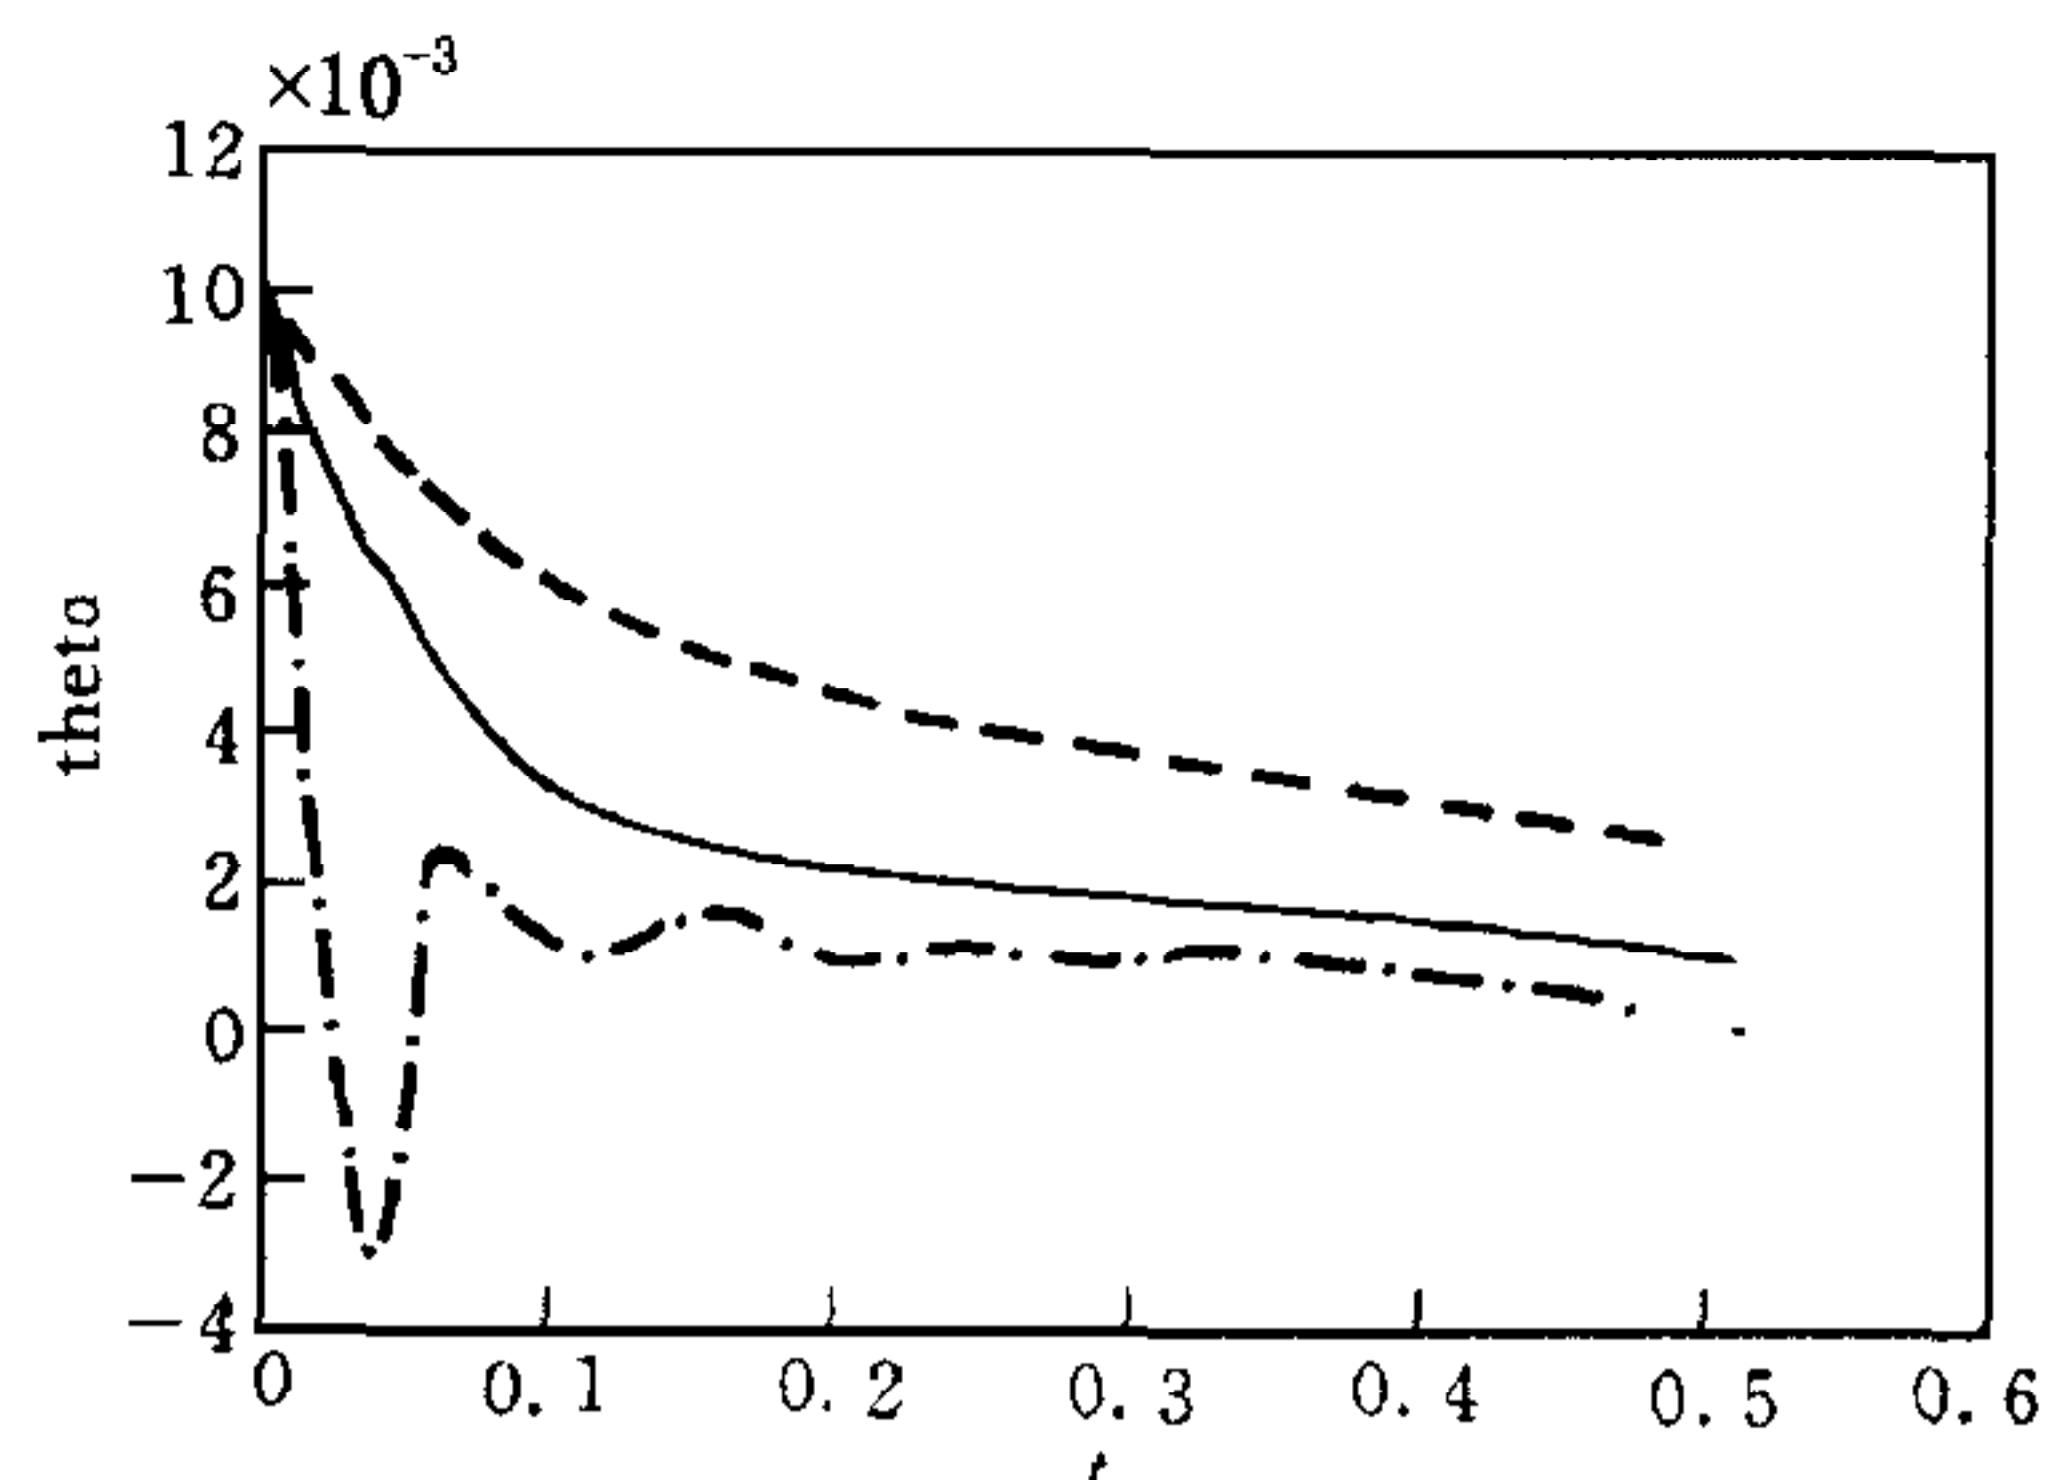


图6 学习前后倾角 θ 的变化过程

参 考 文 献

- 1 Yang B H, Asada H. Progressive learning and its application to robot impedance learning. *IEEE Trans. Neural Networks*, 1996, 7(4): 941~951
- 2 Sanger T D. Neural network learning control of robot manipulator using gradually increasing task difficulty. *IEEE Trans. Neural Networks*, 1994, 5(3): 323~333
- 3 Sanger T D. A tree-structure algorithm for reducing computation in networks with separable basis functions. *Neural Computation*, 1991, 3(1): 67~78
- 4 Yang B H, Asada H. Adaptive reinforcement learning and its application to robot compliance learning. *J Robot Mechatronics*, 1995, 7(3): 250~262
- 5 Yang B H, Asada H. Reinforcement Learning of Assembly Robot. In *Experimental Robotics III*, Yosikawa T and Miyazaki F, Eds. New York: Springer-Verlag, 1994
- 6 Hogan N. Impedance control: An approach to manipulation: Part I - III. *ASME J. Dynamic Syst., Measurement, Control*, Mar 1985, 107: 1~4
- 7 Chan S P, HC Liaw. Generalized impedance control of robot for assembly tasks requiring compliant manipulation. *IEEE Trans. Indu. Electronics*, 1996, 43(4): 453~461
- 8 Asada H, Kakumoto Y. The dynamic analysis and design of a high-speed insertion hand using the generalized centroid and virtual mass. *ASME J. DSMC*, 1990, 112: 646~652
- 9 Whitney D E. Quasi-static assembly of the compliantly supported rigid parts. *Trans. ASME J. Dynamic Systems, Meas. and Contr.*, 1982, 104(1): 65~77
- 10 Fabri S, Kadirkamanathan V. Dynamic structure neural networks for stable adaptive control of nonlinear systems. *IEEE Trans. on Neural Networks*, 1996, 7(5): 1151~1167

黄心汉 教授、博士生导师,1946年生。现为华中理工大学控制科学与工程系智能与控制工程研究所所长,主要研究领域为智能控制及机器人的理论与应用技术。

杜克林 博士,1971年生。现在华中理工大学控制科学与工程系工作,主要从事机器人动力学、控制与装配技术研究。