

文章编号 1004-924X(2006)03-0422-04

扫描隧道显微镜微位移工作台的 神经网络 PID 控制方法研究

魏 强^{1,2}, 张玉林¹, 于欣蕾¹, 郝慧娟¹, 卢文娟¹

(1. 山东大学 控制科学与工程学院 电子束研究所, 山东 济南 250061;

2. 泰山学院 物理系, 山东 泰安 271021)

摘要:提出了一种基于神经网络理论的微位移工作台控制方案。该工作台以压电陶瓷作为微位移驱动元件,对伺服电机大位移进行位移补偿。分析了压电陶瓷微位移驱动器的原理,建立了工作台的数学模型。神经网络 PID 控制器对工作台进行闭环控制,利用 BP 网络的自学习和自适应能力,实时调整网络加权值,改变 PID 控制器的控制系数,减小工作台的位移误差。采用专用的压电陶瓷驱动电源对工作台的位移进行了实验,相对于常规 PID 控制器,微位移为 11.41 μm 时的响应时间从 1.5 s 缩短到 1 s,稳态位移误差从 3.13% 减小到 1.05%,工作台的稳定性和定位精度得以提高,改善了扫描隧道显微镜的工作性能。

关键词:扫描隧道显微镜;精密工作台;神经网络;PID 控制;自适应控制

中图分类号:TH742.9;TH703.6 **文献标识码:**A

Study on neural network PID control for micro-displacement stage of Scanning Tunneling Microscope

WEI Qiang^{1,2}, ZHANG Yu-lin¹, YU Xin-lei¹, HAO Hui-juan¹, LU Wen-juan¹

(1. *Institute of Electron Beam, School of Control Science and Engineering, Shandong University, Jinan 250061, China*; 2. *Department of Physics, Taishan University, Taian 271021, China*)

Abstract: A control scheme for micro-displacement stage of Scanning Tunneling Microscope (STM) based on the neural network was proposed, in which piezoelectric ceramics is used as the micro-displacement actuator of stage to compensate the rough displacement of the servo mechanism. The principle of the actuator was analyzed and the mathematical model was set up. With the stage controlled by the neural-network PID controller in close loop, the weights of BP network and the parameters of PID controller could be adjusted to reduce the displacement error of stage by the function of self-learning and adaptability in real time. Experiments of stage displacement using the special electronic ceramics power were conducted. The results show that the response time for a micro displacement of 11.41 μm is shortened from 1.5 s to 1 s, and the stable error is reduced from 3.13% to 1.05%. The stability and positioning precision are improved and the performance of Scanning Tunneling Microscope is

收稿日期:2005-09-02;修订日期:2005-10-16.

基金项目:国家自然科学基金重大研究计划资助项目(No. 90307003);国家自然科学基金资助项目(No. 10572078);山东省自然科学基金资助项目(No. Y2003G03)

enhanced compared with the traditional PID controller.

Key words: Scanning Tunneling Microscope(STM); precision stage; PID control; neural network; adaptive control

1 引 言

扫描隧道显微镜 (STM) 是上世纪 80 年代发展起来的一种表面分析和三维加工工具,其工作台具有纳米级分辨率。普通的机械位移装置,由于存在摩擦、间隙、爬行等缺点,很难达到这一精度要求,所以目前 STM 一般采用由伺服电机驱动的粗位移工作台和由压电陶瓷驱动的微位移工作台相配合的位移方式。这种结构能够实现工作台的微量位移、精确定位和误差补偿,保证分析或加工样品的尺寸精度和表面质量,但同时要求控制系统响应速度快、跟踪平稳并且精确度高。在 STM 工作过程中,微位移工作台受非线性、时变不确定性等因素的影响,机械参数会发生变化,此时采用常规的 PID 控制很难实现良好的控制效果。为解决这一问题,作者基于神经网络理论,设计了一种自动调整 PID 控制器参数的方案,以适应 STM 微位移工作台参数变化的要求。

2 STM 微位移工作台

STM 的基本原理是利用量子理论中的隧道效应,将原子线度的极细探针和被研究物质的表面作为两个电极,当样品与针尖的距离非常接近时(通常 $< 1 \text{ nm}$),在外加电场的作用下,电子会穿过两个电极之间的势垒流向另一电极,形成隧道电流。这一电流值与两电极之间的距离呈指数关系,从而使得 STM 具有极高的纵向分辨率(优于 0.01 nm)^[1-2]。常规的伺服电机驱动和精密丝杠传动方式,由于存在螺纹空程和传动摩擦,其定位精度一般只能达到微米级,不能精确地把探针驱动到距样品表面纳米级的间隙中。因此,寻求能满足 STM 微量位移的驱动和传动方式,使工作台具有纳米级的位移分辨率,是 STM 纳米加工技术的重点课题之一。

压电陶瓷是近年来发展起来的新型微位移材料,具有分辨率高、频响高、易于控制等优点,在微位移和定位装置中得到了广泛的应用^[3]。基于二

次精密定位工作原理^[4],采用伺服电机粗位移和压电陶瓷微位移的组合方式,不仅实现了工作台的快速移动,而且利用压电陶瓷来补偿粗工作台的位移偏差,显著地提高了系统的调整速度和灵敏度,达到了高精度的位移要求,适用于 STM 的纳米级的微定位。本文仅研究由压电陶瓷驱动的微位移工作台的控制问题。

微位移工作台利用了压电陶瓷的电致伸缩效应原理,其物理模型可简化为质量-弹簧-阻尼




图 1 微位移驱动器简化运动模型

Fig. 1 Model of micro-displacement stage

二阶运动机构^[5],如图 1 所示。图中, k_1 为传动部件刚度, k_2 为柔性铰链弹性导轨刚度, m 为运动机构的运动质量, μ 为阻尼系数, $x(t)$ 为输入位移, $y(t)$ 为输出位移。系统动力学方程可表达为:

$$m\ddot{y}(t) + \mu\dot{y}(t) + (k_1 + k_2)y(t) = k_1 x(t), \quad (1)$$

经过拉氏变换,得到微位移工作台的传递函数为:

$$G_p(s) = \frac{Y(s)}{X(s)} = \frac{k\omega^2}{s^2 + 2\xi\omega s + \omega^2}, \quad (2)$$

其中: k 为放大倍数且 $k = k_1 / (k_1 + k_2)$, ξ 为阻尼比且 $\xi = \mu / (2m\omega)$, ω 为无阻尼自然角频率且 $\omega = [(k_1 + k_2) / m]^{1/2}$;




图 2 STM 微位移工作台控制结构框图

Fig. 2 Block diagram of STM stage control system

为保证微位移工作台的位移精度,一般采用

闭环控制系统,原理框图如图 2 所示。当 STM 工作在恒流模式下时^[6], r 为针尖与样品表面之间的距离设定值, y 为实际值。当针尖遇到样品表面凸起时, y 减小, $e=r-y$ 增大, 在控制器的作用下, 驱动电源输出 u 减小, 压电陶瓷收缩, 使 y 增大。遇到凹处时, y 的变化方向正好相反。重复该过程, 直至 e 等于零或处于允许误差范围内, 计算机记录并显示驱动电压值 u , 则 u 的变化反映出样品表面该点高度。当针尖沿 x 、 y 方向扫描时, 就能够描绘出样品表面的形貌特征。闭环控制由于其反馈量能对实际位移进行修正, 有效地减小或消除了工作台的位移误差, 已经在 STM 系统中获得应用^[7]。

3 微位移工作台的神经网络 PID 控制

数字 PID 控制是一种在生产中普遍采用的控制方法, 经典增量式数字 PID 控制算法^[8]可表示为:

$$u(k) = u(k-1) + K_p[e(k) - e(k-1)] + K_i e(k) + K_d[e(k) - 2e(k-1) + e(k-2)], \quad (3)$$

其中: $e(k)$ 为系统偏差, $e(k) = r(k) - y(k)$, $r(k)$ 为输入设定值, $y(k)$ 为系统输出; K_p 、 K_i 、 K_d 分别为 PID 控制器的比例、积分和微分系数。

常规 PID 控制器算法简单、不要求被控对象有精确的数学模型, 鲁棒性能好, 但是, 控制器系数的整定和选取在很大程度上依赖于操作人员的经验, 对于具有时滞、非线性、时变不确定性系统, PID 的适应性较差。STM 系统包含有 A/D 和 D/A 转换及驱动电压电路, 是一个滞后系统^[9]。此外, 外部干扰以及样品表面不同区域电特性的不同和功函数的一致性, 使得工作台的机械参数甚至模型结构都可能发生变化^[10]。因此, 要求 PID 控制器的系数在形成控制量的过程中得到准确而又实时的在线调整。BP 神经网络为这一问题提供了解决方案。

3.1 BP 神经网络

神经网络(NN-Neural Network)是一种采用拓扑结构组成的活性网络, 具有学习、记忆、计算以及各种智能处理能力, 在不同程度和层次上模仿了人脑神经系统的功能, 它的出现, 推动了包括 PID 控制在内的各种控制理论的发展及其应用。误差反向传播(BP-Back Propagation)神经网络

是一种有隐含层的多层前馈网络。输入信号从输入层经隐含层, 传向输出层, 在输出端产生输出信号, 在此过程中网络的权值是固定的。如果输出值与设定值有偏差, 则两者之间的误差信号由输出层逐层向前传播, 同时调节网络的权值, 使得网络的实际输出接近直至等于设定值^[11]。正是由于 BP 神经网络具有逼近任意非线性函数的能力, 使得它并不依赖于模型, 而且结构和学习算法简单明确, 易于编程。

3.2 神经网络 PID 控制

基于神经网络的 STM 微位移工作台 PID 控制系统如图 3 所示。神经网络根据系统运行状态, 通过自学习和修正网络权值, 在线调整 PID 控制器的系数, 达到指定性能指标下的最优化。

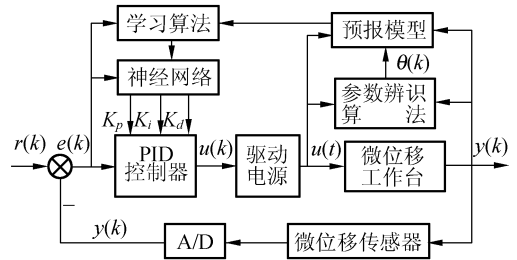


图 3 STM 微位移工作台神经网络 PID 控制结构框图

Fig. 3 Block diagram of neuron PID control system for STM stage

BP 神经网络采用三层(如 3-5-3)结构, 如图 4 所示, 三层分别用 I、J、P 表示。




图 4 三层 BP 神经网络结构

Fig. 4 BP neural network with three-layers

输入层的三个输入分别为:

$$\left. \begin{aligned} x_1^I(k) &= e(k) - e(k-1) \\ x_2^I(k) &= e(k) \\ x_3^I(k) &= e(k) - 2e(k-1) + e(k-2) \end{aligned} \right\}, \quad (4)$$

输出层的输出即为PID控制器的3个系数 K_p 、 K_i 、 K_d 。

3.2.1 STM微位移工作台模型

利用 z 变化理论^[12],把式(2)写成差分方程形式:

$$y(k) = -a_1 y(k-1) - a_2 y(k-2) + bu(k-1), \quad (5)$$

其中: $a_1 = -2e^{(-\xi\omega T_s)} \cos(\omega T_s \sqrt{1-\xi^2})$, $a_2 = e^{(-2\xi\omega T_s)}$, $b = [k\omega e^{(-\xi\omega T_s)} \sin(\omega T_s \sqrt{1-\xi^2})] / \sqrt{1-\xi^2}$, T_s 是采样周期。

3.2.2 神经网络PID控制算法

BP网络的输入如式(4)。

隐含层的输入输出为:

$$\left. \begin{aligned} \text{net}_j^I(k) &= \sum_{i=1}^3 \omega_{ji} o_i^I(k) \\ o_j^I(k) &= f_1(\text{net}_j^I(k)), (j=1, \dots, 5) \end{aligned} \right\}, \quad (6)$$

其中: ω_{ji} 是输入层节点 i 到隐含层节点 j 的加权系数, f_1 是隐含层激活函数,取为正负对称的Sigmoid函数。

输出层的输入输出为:

$$\left. \begin{aligned} \text{net}_p^O(k) &= \sum_{j=1}^5 \omega_{pj} o_j^I(k) \\ o_p^O(k) &= f_2(\text{net}_p^O(k)), (p=1, 2, 3) \end{aligned} \right\}, \quad (7)$$

其中: ω_{pj} 是隐含层节点 j 到输出层节点 p 的加权系数, f_2 是输出层激活函数,由于PID控制器系数不能为负值,所以 f_2 取为非负的Sigmoid函数;

输出层的输出为PID控制器的系数,即:

$$\left. \begin{aligned} K_p(k) &= o_1^O(k) \\ K_i(k) &= o_2^O(k) \\ K_d(k) &= o_3^O(k) \end{aligned} \right\}, \quad (8)$$

把式(4)和(8)代入式(3),则得到PID控制器的输出 $u(k)$ 。

取BP网络的性能指标函数^[13]为:

$$J_1 = \frac{1}{2} [r(k+1) - y(k+1)]^2, \quad (9)$$

用BP学习算法来修正加权系数,使 J_1 达到最小,得到输出层的加权系数修正公式为:

$$\left. \begin{aligned} \omega_{pj}(k+1) &= \omega_{pj}(k) + \eta \delta_p o_j^I(k) + \alpha \Delta \omega_{pj}(k) \\ \delta_p &= e(k+1) \frac{\partial y(k+1)}{\partial u(k)} \frac{\partial u(k)}{\partial o_p^O(k)} f_2'(\text{net}_p^O(k)) \end{aligned} \right\}, \quad (10)$$

其中: η 为学习速率, α 为加快算法收敛速度而添

加的惯性系数, $\Delta \omega_{pj}(k)$ 是上一采样时刻的加权系数变化量。

根据式(3)和(8),得出:

$$\left. \begin{aligned} \frac{\partial u(k)}{\partial o_1^P(k)} &= x_1(k) \\ \frac{\partial u(k)}{\partial o_2^P(k)} &= x_2(k) \\ \frac{\partial u(k)}{\partial o_3^P(k)} &= x_3(k) \end{aligned} \right\}, \quad (11)$$

隐含层的加权系数修正公式为:

$$\left. \begin{aligned} \omega_{ji}(k+1) &= \omega_{ji}(k) + \eta \delta_j o_i^I(k) + \alpha \Delta \omega_{ji}(k) \\ \delta_j &= f_1'(\text{net}_j^I(k)) \sum_{p=1}^3 \delta_p \omega_{pj}(k) \end{aligned} \right\}, \quad (12)$$

其中: η 、 α 、 $\Delta \omega_{ji}(k)$ 的定义同式(10)。

3.2.3 参数辨识和预报模型算法

在式(10)中,第 k 个采样时刻 $y(k+1)$ 的值是未知的,需要采用辨识算法和预报模型预测出其估计值 $\hat{y}(k+1)$ 。

微位移工作台的离散传递函数表达式(5)写成向量形式为:

$$y(k) = \boldsymbol{\varphi}^T(k-1) \boldsymbol{\theta}(k), \quad (13)$$

其中:输出向量 $\mathbf{y} = [y(k)]$,参数向量 $\boldsymbol{\theta}(k) = [a_1 \ a_2 \ b]^T$,观测向量 $\boldsymbol{\varphi}(k-1) = [-y(k-1) \ -y(k-2) \ u(k-1)]^T$ 。

采用递推最小二乘算法对 $\hat{\boldsymbol{\theta}}$ 进行在线辨识^[14]:

$$\left. \begin{aligned} \hat{\boldsymbol{\theta}}(k) &= \hat{\boldsymbol{\theta}}(k-1) + K(k) [y(k) - \boldsymbol{\varphi}^T(k) \hat{\boldsymbol{\theta}}(k-1)] \\ K(k) &= P(k-1) \boldsymbol{\varphi}(k) [\boldsymbol{\rho} + \boldsymbol{\varphi}^T(k) P(k-1) \boldsymbol{\varphi}(k)]^{-1} \\ P(k) &= \frac{1}{\rho} [\mathbf{I} - K(k) \boldsymbol{\varphi}^T(k)] P(k-1) \end{aligned} \right\}, \quad (14)$$

其中: ρ 是遗忘因子,选取 $\rho = 0.95$, $\hat{\boldsymbol{\theta}}$ 初始值设为 $\hat{\boldsymbol{\theta}}(0) = [0.5 \ 0.5 \ 0.5]$,估计得到驱动器参数 ξ , ω , k ,进而得到 \hat{a}_1 , \hat{a}_2 , \hat{b} 。

这样,得到了一步预报输出:

$$\hat{y}(k+1) = \boldsymbol{\varphi}^T(k) \hat{\boldsymbol{\theta}}(k), \quad (15)$$

则式(10)中的 $\partial y(k+1) / \partial u(k)$ 可用 $\partial \hat{y}(k+1) / \partial u(k)$ 来代替,用于计算加权系数的修正值。

4 实验结果分析

实验中所使用的驱动电源为压电陶瓷专用电源,采用专用运算放大电路,由计算机控制的16位数模转换器程控调节,输出具有高稳定性和高