

基于物理引导的 RBF 神经网络逆模型在 ZTT 运动平台前馈控制中的应用

吴聪懿¹ 徐云浪² 陈椿元³ 金煜¹ 杨晓峰^{1†}

(1. 复旦大学 工程与应用技术研究院, 上海 200433)

(2. 中南大学 机电工程学院, 长沙 410083)

(3. 上海隐冠半导体技术有限公司, 上海 200131)

摘要 精密运动平台是半导体设备的核心部件,其运动性能直接决定了整个系统的基础性能.在工程应用中,运动平台的非线性特性对精密运动控制产生显著影响,例如柔性导向、线缆力和磁浮补偿等因素引入的非线性力.前馈控制器能够有效补偿非线性扰动和轨迹偏差.然而,传统的逆模型前馈方法需要耗费大量精力来准确建立被控对象的逆模型,而流行的迭代学习前馈方法则对运动工况的重复性要求较高.此外,自适应前馈控制在参数调整过程中可能导致系统暂态响应的不稳定性.为了解决这些问题,本文提出了一种基于物理引导的径向基函数(RBF)神经网络逆模型前馈控制器.该方法利用 RBF 神经网络优秀的非线性函数逼近能力,并通过梯度下降法自动优化模型,显著减少了建模的工作量.此外,我们在 RBF 神经网络逆模型中嵌入了加速度前馈的先验经验,从而大幅降低了跟踪误差,提高了系统的响应速度.

关键词 RBF 神经网络, 前馈, 非线性, 精密运动台, 解耦控制

中图分类号:TP13

文献标志码:A

Physics Guided RBF Neural Networks for Inversion-based Feedforward Control Applied to ZTT Stage

Wu Congyi¹ Xu Yunlang² Chen Chunyuan³ Jin Yu¹ Yang Xiaofeng^{1†}

(1. Academy of Engineering and Technology, Fudan University, Shanghai 200433, China)

(2. College of Mechanical and Electrical Engineering, Central South University, Changsha 410083, China)

(3. Shanghai Yinguan Semiconductor Technology Co., Ltd., 200131, China)

Abstract The precision motion platform is a fundamental component of semiconductor equipment, with its motion performance serving as the foundation for the entire system. In engineering applications, the nonlinear characteristics of the moving platform, such as the nonlinear forces introduced by flexible steering, cable forces, and maglev compensation, significantly impact precision motion control. Traditional feedforward control methods, such as the inverse model feedforward approach, require substantial energy to accurately construct the inverse model of the object plant. Meanwhile, the iterative learning feedforward method demands high repeatability of motion conditions. Additionally, adaptive feedforward control can lead to instability in the system's transient response during parameter adjustments. To address these challenges, this paper proposes an inverse model feedforward controller based on a physically guided radial basis function (RBF) neural network. This approach leverages the RBF neural network's superior nonlinear function approximation capabilities and employs the gradient descent method for automatic model optimization, thereby significantly reducing the modeling workload. Furthermore, by incor-

porating prior experience of acceleration feedforward into the RBF neural network inverse model, the proposed method effectively reduces tracking error and enhances the system's response speed.

Key words RBF neural networks, feedforward, nonlinear, precision motion stage, decoupled control

引言

针对中美半导体领域不断升级的争端,半导体国产化进程势在必行.精密运动台作为光刻^[1]、键合^[2]及量检测设备的核心零部件之一,其控制性能直接影响整机设备的产能和表现.运动控制过程中,反馈控制确保闭环的稳定性和抗干扰性,前馈控制则用于补偿扰动力和参考轨迹.因此,一个好的前馈控制器设计可以有效处理实际应用中存在的扰动,极大提高运动响应速度和控制精度.

前馈控制的主要方法包括逆模型前馈控制^[3]、迭代学习控制前馈^[4,5]和自适应前馈控制.在工程应用中,最广泛使用的是逆模型前馈控制方法中的加速度前馈控制器^[6].这是因为在连续域中,刚体模型的理想前馈模式为二阶加速度前馈.为了进一步提升逆模型前馈控制器的性能,通常需要建立能够充分逼近被控对象实际行为的逆模型.而模型的不确定性超出一定范围时,该方法反而会使控制性能发生恶化^[7].Ko 等^[8]通过结合逆模型前馈和反馈控制,实现了相互增强,解决了逆模型前馈因模型不确定性引入的跟踪误差问题,同时克服了纯反馈控制的带宽限制.Li 等^[9]提出了一种基于数据驱动的零相位误差跟踪前馈控制策略,通过将传统的零相位误差逆模型与对称 FIR 滤波器构成的增益补偿滤波器相结合,构建出一种精度更高的逆模型.自适应前馈能够跟踪并感知系统特性的变化,从而自动调整参数.Madsen 等^[10]提出了一种基于扩展广义麦克斯韦-滑移摩擦模型的自适应前馈摩擦补偿器,用于补偿库仑摩擦和粘性摩擦的时变.Tan 等^[11]提出了一种自适应前馈方法,当线路输入电压变化时,该方法能够调整滑膜控制器的迟滞调制器的迟滞带.自适应前馈控制的不足之处在于参数调整的暂态响应可能会引起系统的不稳定性.迭代学习控制(ILC)是一种专门针对重复性任务的控制策略.该方法通过利用先前运行的数据,逐步修正控制输入,以在固定时间间隔内补偿重复

干扰,从而改善瞬态响应和跟踪性能^[12].然而,传统的 ILC 对运动工况具有严格重复性要求^[13].为了解决该问题,许多学者进行了算法优化:Meng 和 Sun 等^[14-16]重点研究了系统初始值设置不匹配对迭代学习稳定性造成的影响;Boeren 等^[17]提出了一种频域 ILC 方法,使其在不同任务下也能实现高效的运动性能;Maeda 等^[18]则将 ILC 与扰动观测器相结合,以解决系统中存在的非重复性扰动问题.

在纳米级跟踪性能要求下,工程应用中的柔性导向和线缆力等非线性扰动常常成为限制运动台响应速度和控制精度的关键因素.此外,为了满足各种测试工况的需求,运动台必须在不同轨迹下始终保持良好的性能表现.针对上述需求,本文开发了一种基于物理引导的 RBF 神经网络逆模型(PG-RBFNN)前馈控制器.在 RBF 神经网络隐藏层中嵌入加速度前馈模型,不仅能够充分发挥先验物理经验的优势,还能有效整合神经网络在逼近非线性模型方面的能力.本文的主要贡献在于:

(1)利用 RBF 神经网络的非线性函数逼近能力^[19],无需建立被控对象的物理逆模型,从而简化了物理模型构建过程,并能够适应不同的模型,显著减少了工作量;

(2)在 RBF 神经网络逆模型中嵌入加速度前馈的先验经验,大幅降低了跟踪误差,提高了系统的响应速度;

(3)通过在仿真实验中输入不同的参考轨迹验证本文提出的前馈控制方法在运动轨迹变化时的鲁棒性;

(4)本文提出的前馈控制器结构简洁,操作便捷,适用于不同的被控对象及运动轨迹,具有良好的工程应用前景.

1 基于音圈电机的 ZTT 精密运动台

如图 1 所示,本文研究的对象是以音圈电机为驱动、柔性簧片为导向的 ZTT 运动平台.该平台能

够实现三个自由度(Tip、Tilt 和 Z)的调节,具备毫米级的运动行程,同时支持纳米级的分辨率、精度和重复性.这种运动装置在半导体工艺控制中有广泛应用,例如临界尺寸和薄膜厚度的测量.其在焦平面直线度、平面度和名义入射角(AOI)方面表现出优秀的性能.




图1 ZTT精密运动平台实物图
Fig.1 ZTT precision motion stage

1.1 受控对象建模

为了实现垂直方向的三自由度运动和精确测量,该平台配备了三个垂直音圈电机和三个垂直测量传感器.音圈电机通过产生垂直方向的作用力,实现 z 、 rx 和 ry 方向的运动.控制器负责输出控制信号,以调节驱动器提供给电机的电流,从而控制电机的输出力.为限制运动平台在垂直运动时的水平位移变化,系统采用柔性簧片作为导向机构,确保平台仅在垂直方向上运动.为了精确测量平台在垂直方向的位移变化,我们在动子和定子部分安装了高精度光栅尺作为测量传感器.此外,为了减小电机动子和被测物体重力对控制精度的影响,通常会设计重力补偿模块.

根据图2所示电机和传感器分布图,系统的执行器输入 $\mathbf{u}(x)$ 可以表达为:

$$\mathbf{u}(t) = \begin{bmatrix} F_z(t) \\ T_x(t) \\ T_y(t) \end{bmatrix} = \mathbf{B} \begin{bmatrix} F_{z1}(t) \\ F_{z2}(t) \\ F_{z3}(t) \end{bmatrix} \quad (1)$$

同理,传感器输出 $\mathbf{y}(t)$ 可以表达为:

$$\mathbf{y}(t) = \begin{bmatrix} z(t) \\ \theta_x(t) \\ \theta_y(t) \end{bmatrix} = \mathbf{M} \begin{bmatrix} z_1(t) \\ z_2(t) \\ z_3(t) \end{bmatrix} \quad (2)$$

其中, F_z 、 T_x 和 T_y 为逻辑轴输入, z 、 θ_x 和 θ_y 为逻辑轴输出, \mathbf{B} 和 \mathbf{M} 分别为出力转换矩阵和测量转换矩阵.

理想情况下,经过解耦后,运动台的传递函数矩阵可表达为:

$$\mathbf{P}_{\text{stage}} = \begin{bmatrix} \frac{1}{ms^2} & 0 & 0 \\ 0 & \frac{1}{J_x s^2} & 0 \\ 0 & 0 & \frac{1}{J_y s^2} \end{bmatrix} \quad (3)$$

其中, m 为运动质量, J_x 和 J_y 分别为 rx 和 ry 方向的转动惯量.

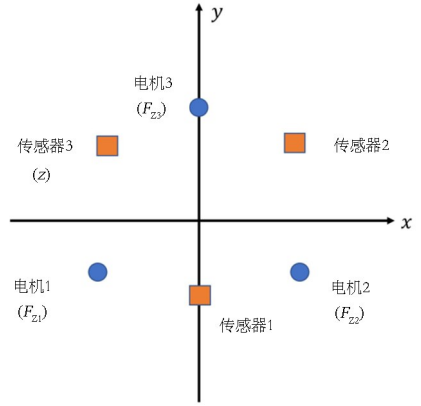


图2 电机传感器位置分布图(F_{z1} 、 F_{z2} 、 F_{z3} 分别为三个电机垂向出力; z_1 、 z_2 、 z_3 分别为三个垂向传感器测量到的位移)
Fig.2 The position distribution diagram of the motors and sensors (F_{z1} 、 F_{z2} 、 F_{z3} and is the vertical output of the three motors, respectively; z_1 、 z_2 、 z_3 and are the displacements measured by the three vertical sensors, respectively)

如图3所示,解耦后的系统可以作为三个单输入单输出(SISO)系统进行控制.其中包括三个反馈控制器 C_z 、 C_{θ_x} 、 C_{θ_y} 和三个前馈控制器 FF_z 、 FF_{θ_x} 、 FF_{θ_y} .此外, r_z 、 r_{θ_x} 、 r_{θ_y} 为三个自由度的参考轨迹.

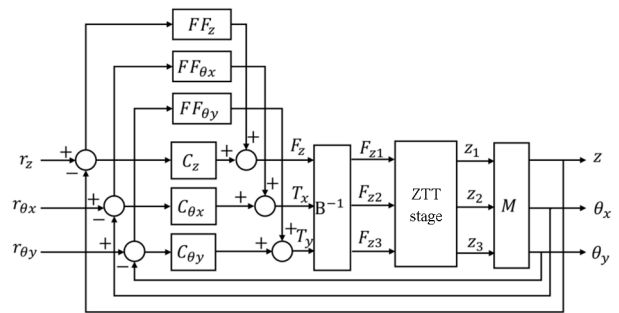


图3 控制结构
Fig.3 Control structure

1.2 标准控制器设计

工业中常用的反馈控制器为标准的PID结构^[20]:

$$H_{ctrl}(s) = K_p \left(\frac{s + 2\pi f_i}{s} \right) \left(\frac{s}{2\pi f_d} + 1 \right) \times \left(\frac{(2\pi f_{lp})^2}{s^2 + 2\beta_{lp}(2\pi f_{lp})s + (2\pi f_{lp})^2} \right) \quad (4)$$

K_p 的数值根据控制带宽 f_{bw} 设计决定:

$$K_p = \frac{m(2\pi f_{bw})^2}{\alpha} \quad (5)$$

其中, m 为运动质量; α 为 PID 频率比; f_i 为积分频率; f_d 为微分频率; f_{lp} 为二阶低通滤波器的滤波频率; β_{lp} 为低通滤波器的阻尼比。

在精密运动平台的控制中, 我们往往可以将被控对象简化为刚体模型^[21], 其传递函数可以表达为

$$G_p = \frac{1}{ms^2} \quad (6)$$

若忽略扰动和噪声的影响, 跟踪误差可以表达为

$$e = \frac{1 - G_p FF}{1 + G_p H_{ctrl}} \quad (7)$$

假设前馈控制器等于被控对象的逆模型, 即

$$FF = (G_p)^{-1} = ms^2 \quad (8)$$

可以得到

$$e \equiv 0 \quad (9)$$

因此工程上常用的前馈控制器是加速度前馈^[22], 其主要作用是减小加速度阶段的跟踪误差, 从而缩短系统的稳定时间。

根据上述分析, ZTT 运动台三个逻辑轴方向的加速度前馈控制器可表达为:

$$\begin{cases} FF_z(s) = ms^2 \\ FF_{\theta_x}(s) = J_x s^2 \\ FF_{\theta_y}(s) = J_y s^2 \end{cases} \quad (10)$$

1.3 非线性扰动问题

本文研究的 ZTT 运动台采用簧片作为柔性导向, 实现了垂直方向上的三个自由度运动。在电机驱动过程中, 需要克服柔性导向的回复力。随着运动行程的增大, 柔性件的刚度也随之增加。此外, 在毫米级的运动范围内, 容易出现非线性变形。为了消除运动台负载的重力作用对运动性能带来的影响, ZTT 运动台内部还设计了磁浮重力补偿模块^[23]。

在工程应用中, 磁浮重力补偿机制在不同位置表现出不同的补偿效果, 并且不同批次的补偿器之间也存在差异。如图 4 所示, 磁浮重力补偿器的使用还会引入系统的非线性扰动。此外, 运动平台内部不可避免地存在线缆和气管, 这些线缆和气管在运动

过程中产生的拉扯也会对运动性能产生影响。

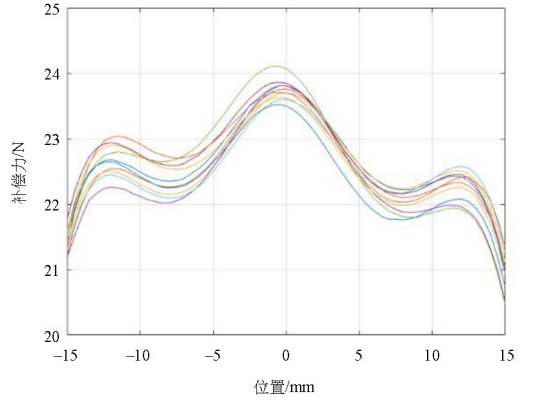


图 4 十个不同批次的磁浮重力补偿器在不同位置的力补偿曲线
Fig. 4 Force compensation curves of ten different batches of maglev gravity compensators at different positions

2 神经网络前馈控制

为了映射系统中的非线性部分, 本文利用 RBF 神经网络的自学习能力建立系统模型, 从而避免了物理建模中复杂的数学分析, 为工程应用带来了极大的便利。

2.1 RBF 神经网络

如图 5 所示, RBF 神经网络结构主要包含输入层、隐含层和输出层^[24]。其中, 网络输入为 $\mathbf{x} = [x_i]^T$, 隐含层输出为 $\mathbf{h} = [h_j]^T$, 网络输出为 $\mathbf{y} = [y_k]^T$ 。RBF 神经网络的隐含层神经元激活函数采用径向基函数, 该函数具有非线性映射能力, 其表达式为:




图 5 RBF 神经网络结构示意图
Fig. 5 Schematic diagram of the structure of the RBF neural network

$$h_j(t) = \exp\left(-\frac{\|x(t) - c_j\|^2}{2b_j^2}\right), j = 1, \dots, m \quad (11)$$

其中, $\mathbf{c} = [c_{ij}] = \begin{bmatrix} c_{11} & \dots & c_{1m} \\ \vdots & \ddots & \vdots \\ c_{n1} & \dots & c_{nm} \end{bmatrix}$ 为隐含层的中心

向量; b_j 为高斯基函数的宽度, 是一个正标量; $\|x(t) - c_j(t)\|$ 为输入向量与中心向量之间的欧

式距离; n 是输入参数的个数; m 是隐含层节点的数量. 网络输出由加权函数实现:

$$y_k(t) = \sum_{j=1}^m \omega_{jk} h_j(t), k = 1, \dots, q \quad (12)$$

其中, $\mathbf{w} = [\omega_{jk}] = \begin{bmatrix} c_{11} & \cdots & c_{1q} \\ \vdots & \ddots & \vdots \\ c_{m1} & \cdots & c_{mq} \end{bmatrix}$ 为输出层的权值; q 为输出的个数.

2.2 RBF 神经网络逆模型逼近

RBF 神经网络模型逼近的基本原理是通过不断调整权重和参数最小化损失函数, 从而实现对目标函数的有效逼近. 图 6 为使用 RBF 神经网络对模型进行逼近的结构图, 其误差指标为:

$$E(t) = \frac{1}{2} [y(t) - y_k(t)]^2 \quad (13)$$

其中, y 为模型实际输出, y_k 为 RBF 网络输出.




图 6 RBF 神经网络逼近

Fig. 6 RBF neural network approximation

在神经网络前馈控制器的设计中, 我们需要对系统的逆模型进行逼近, 其结构如图 7 所示. 此时的误差指标可表达为:

$$E(t) = \frac{1}{2} [u(t) - u_k(t)]^2 \quad (14)$$

其中, u 为模型实际输出, u_k 为 RBF 网络输出.




图 7 RBF 神经网络逆模型逼近

Fig. 7 RBF neural network inverse model approximation

根据梯度下降法, 权值调节步骤如下:

$$\Delta \omega_j(t) = -\eta \frac{\partial E}{\partial \omega_j} = \eta [u(t) - u_k(t)] h_j \quad (15)$$

$$\omega_j(t) = \omega_j(t-1) + \Delta \omega_j(t) + \alpha [\omega_j(t-1) - \omega_j(t-2)] \quad (16)$$

$$\Delta b_j = -\eta \frac{\partial E}{\partial b_j} = \eta [u(t) - u_k(t)] \omega_j h_j \frac{\|x - c_j\|^2}{b_j^3} \quad (17)$$

$$b_j(t) = b_j(t-1) + \Delta b_j + \alpha [b_j(t-1) - b_j(t-2)] \quad (18)$$

$$\Delta c_{ji} = -\eta \frac{\partial E}{\partial c_{ji}} = \eta [u(t) - u_k(t)] \omega_j h_j \frac{x_j - c_{ji}}{b_j^2} \quad (19)$$

$$c_{ji}(t) = c_{ji}(t-1) + \Delta c_{ji} + \alpha [c_{ji}(t-1) - c_{ji}(t-2)] \quad (20)$$

其中, $\eta \in (0, 1)$ 为学习速率, $\alpha \in (0, 1)$ 为动量因子.

2.3 PG-RBFNN 模型

在运动控制过程中, 加速度前馈能够有效降低加减速阶段的跟踪误差. 基于这一点, 我们将先验物理经验融入到神经网络模型中, 构建了一种混合的神经网络结构 PG-RBFNN. 如图 8 所示, 这种结构不仅发挥了神经网络对任意非线性函数的逼近能力, 还利用加速度前馈信息增强了对轨迹的跟踪能力. 在这种结构下, 网络输出更新为:

$$u_k(t) = \sum_{j=1}^m \omega_{jk} h_j(t) + ma(t), k = 1, \dots, q \quad (21)$$

其中, $a(t)$ 为轨迹加速度信号.

由于 PG-RBFNN 的设计评价标准与 RBFNN 一致, 都是通过最小化模型实际输出 u 与 RBF 网络输出 u_k 之间的差异来实现, 因此两者的损失函数相同.




图 8 PG-RBFNN 逆模型网络结构

Fig. 8 Structure of PG-RBFNN inverse model

3 仿真结果

经过物理解耦后, ZTT 运动台可以被分解为三个方向的单输入单输出 (SISO) 模型. 现将 Z 方

向的模型表示为如下二阶非线性系统:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = \alpha(x_1) + \beta(x_1) + \frac{1}{m}u \\ y = x_1 \end{cases} \quad (22)$$

其中, u 为控制输入, y 为系统输出, x_1 为位移, x_2 为速度, $\alpha(x_1) = A \sin(Bx_1 + C)$ 表示为磁浮补偿扰动, $\beta(x_1) = a + bx_1 + cx_1^2 + dx_1^3$ 表示为柔性导向带来的非线性扰动, A, B, C, a, b, c, d 为系数. 在 Simulink 中可使用 S 函数来快速建立上述非线性状态空间方程.

考虑使用结构为 3-5-1 的 RBF 网络, 取网络输入为 $\mathbf{x} = [u, y, a]^T$, 令 $\mathbf{b} = [b_1 \ b_2 \ b_3 \ b_4 \ b_5]^T$, $\mathbf{c} =$

$$\begin{bmatrix} c_{11} & c_{12} & c_{13} & c_{14} & c_{15} \\ c_{21} & c_{22} & c_{23} & c_{24} & c_{25} \\ c_{31} & c_{32} & c_{33} & c_{34} & c_{35} \end{bmatrix}, \mathbf{w} = [\omega_1 \ \omega_2 \ \omega_3 \ \omega_4 \ \omega_5]^T,$$

RBF 模型的 网络输出为 $\mathbf{u}_k(t) = \mathbf{w}^T \mathbf{h} = \omega_1 h_1 + \omega_2 h_2 + \omega_3 h_3 + \omega_4 h_4 + \omega_5 h_5$, PG-RBFNN 模型的 网络输出为 $\mathbf{u}_k(t) = \mathbf{w}^T \mathbf{h} + m a(t)$. 损失函数定义为:

$$\begin{aligned} E(t) &= \frac{1}{2} [u(t) - u_k(t)]^2 \\ &= \frac{1}{2} [F_z(t) - F_{zk}(t)]^2 \end{aligned} \quad (23)$$

为了验证模型在不同测试工况下的有效性, 本文采用了两种不同的参考轨迹进行验证. 两种测试轨迹的具体参数如表 1 所示, 轨迹路径如图 9 所示.

测试 1 的跟踪误差曲线如图 10 所示, 相关数据见表 2. 仿真结果显示, 当在 PID 反馈控制中结合 RBFNN 前馈控制时, 控制误差降低至 45.45%; 而在 PID 反馈控制中加入 PG-RBFNN 前馈控制后, 控制误差进一步降低至原先的 3.56%. 从图 11 和表 2 中可以看出, 测试 2 的仿真结果与测

试 1 一致, 这表明本文提出的前馈控制方法在不同轨迹下均表现出良好的效果.

此外, 由于 ZTT 运动平台已在三个自由度上进行解耦, Rx/Ry 方向的运动控制可以参考 Z 轴.

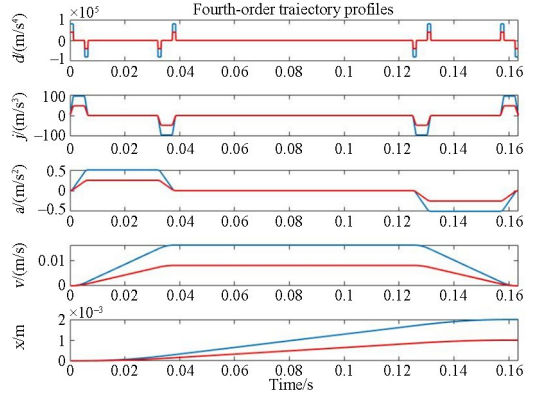


图 9 四阶轨迹(蓝色:测试 1;红色:测试 2)

Fig. 9 Fourth-order trajectories (blue: Test 1; Red: Test 2)




图 10 测试 1 跟踪误差(蓝色实线:PID;蓝色长虚线:PID+RBFNN;蓝色短虚线:PID+PG-RBFNN;红色实线:参考轨迹)

Fig. 10 Test 1 tracking error (solid blue line: PID; Long blue dotted line: PID+RBFNN; Short blue dotted line: PID+PG-RBFNN; Red Implementation: Reference Track)




图 11 测试 2 跟踪误差(蓝色实线:PID;蓝色长虚线:PID+RBFNN;蓝色短虚线:PID+PG-RBFNN;红色实线:参考轨迹)

Fig. 11 Test 2 tracking error (solid blue line: PID; Long blue dotted line: PID+RBFNN; Short blue dotted line: PID+PG-RBFNN; Red Implementation: Reference Track)

表 1 两种测试工况轨迹参数

Table 1 Two types of trajectory parameters for test conditions

参数/[单位]	测试 1	测试 2
Djerk/[m/s ⁴]	8000	4000
Jerk/[m/s ³]	100	50
Acc/[m/s ²]	0.5	0.25
Vel/[m/s]	0.016	0.008
Pos/[m]	0.002	0.001

表2 三种不同控制器类型轨迹跟踪误差数据

Table 2 Trajectory tracking error data for three different controller types

控制器类型	控制误差(三倍标准差/mm)	
	测试 1	测试 2
PID	0.0506	0.0253
PID+RBFNN	0.0230	0.0115
PID+PG-RBFNN	0.0018	0.0009

4 结论

本文研究了径向基函数(RBF)神经网络逆模型在多输入多输出非线性位移台运动控制中的前馈信号应用. 与传统逆模型前馈控制器相比,RBF神经网络凭借其卓越的非线性函数逼近能力,无需构建被控对象的物理逆模型,从而简化了模型构建过程,并能够适应不同的模型,显著减少了工作量. 此外,本文在RBF神经网络逆模型中嵌入了加速度前馈的先验经验,大幅降低了跟踪误差,提高了系统的响应速度. 通过输入不同的参考轨迹,验证了本文提出的前馈控制方法在运动轨迹变化时的鲁棒性. 该方法能够自适应被控对象的变化,并在不同轨迹的运动工况下显著降低跟踪误差,为工程应用提供了便利的使用条件.

参考文献

[1] SONG F Z, LIU Y, DONG Y, et al. Motion control of wafer scanners in lithography systems: from setpoint generation to multistage coordination [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 7508040.

[2] HE Y B, CHEN X, GAO J, et al. Development of high performance bonding machines with improved motion control and intelligent fine tuning algorithm [C]//2015 IEEE 17th Electronics Packaging and Technology Conference (EPTC). Singapore: IEEE, 2015.

[3] BUTTERWORTH J A, PAO L Y, ABRAMOVITCH D Y. Analysis and comparison of three discrete-time feedforward model-inverse control techniques for nonminimum-phase systems [J]. *Mechanics*, 2012, 22(5): 577-587.

[4] Bristow D A, Tharayil M, Alleyne A G. A survey of iterative learning control [J], *IEEE Control Systems Magazine*, 2006, 26(3): 96-114.

[5] 王俊杰, 陈国兴, 步石, 等. 多轴精密运动台前馈控制器参数整定方法[J]. *电子工业专用设备*, 2023, 52(6): 67-73.

WANG J J, CHEN G X, BU S, et al. Parameter tuning method for multi-axis precision motion platform feedforward controller [J]. *Equipment for Electronic Products Manufacturing*, 2023, 52(6): 67-73. (in Chinese)

[6] BOERLAGE M, STEINBUCH M, LAMBRECHTS P, et al. Model-based feedforward for motion systems [C]//Proceedings of 2003 IEEE Conference on Control Applications. New York: IEEE, 2003: 1158-1163.

[7] DEVASIA S. Should model-based inverse inputs be used as feedforward under plant uncertainty? [J]. *IEEE Transactions on Automatic Control*, 2002, 47(11): 1865-1871.

[8] KO P J, WANG Y P, TIEN S C. Inverse-feedforward and robust-feedback control for high-speed operation on piezo-stages [J]. *International Journal of Control*, 2013, 86(2): 197-209.

[9] LI M, ZHU Y, YANG K M, et al. An integrated model-data-based zero-phase error tracking feedforward control strategy with application to an ultra-precision wafer stage [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(5): 4139-4149.

[10] MADSEN E, ROSEN LUND O S, BRANDT D, et al. Adaptive feedforward control of a collaborative industrial robot manipulator using a novel extension of the generalized Maxwell-Slip friction model [J]. *Mechanism and Machine Theory*, 2021, 155: 104109.

[11] TAN S C, LAI Y M, TSE C K, et al. Adaptive feedforward and feedback control schemes for sliding mode controlled power converters [J]. *IEEE Transactions on Power Electronics*, 2006, 21(1): 182-192.

[12] SAAB S S, SHEN D, ORABI M, et al. Iterative learning control: practical implementation and automation [J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(2): 1858-1866.

[13] AHN H S, CHEN Y Q, MOORE K L. Iterative learning control: brief survey and categorization [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 2007, 37(6): 1099-1121.

[14] MENG D Y, JIA Y M, DU J P. Robust consensus

- tracking control for multiagent systems with initial state shifts, disturbances, and switching topologies [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(4): 809–824.
- [15] SUN M X, WU T, CHEN L J, et al. Neural AILC for error tracking against arbitrary initial shifts [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(7): 2705–2716.
- [16] SUN M X, WANG D W. Iterative learning control with initial rectifying action [J]. *Automatica*, 2002, 38(7): 1177–1182.
- [17] BOEREN F, BAREJA A, KOK T, et al. Frequency-domain ILC approach for repeating and varying tasks: with application to semiconductor bonding equipment [J]. *IEEE/ASME Transactions on Mechatronics*, 2016, 21(6): 2716–2727.
- [18] MAEDA G J, MANCHESTER I R, RYE D C. Combined ILC and disturbance observer for the rejection of near-repetitive disturbances, with application to excavation [J]. *IEEE Transactions on Control Systems Technology*, 2015, 23(5): 1754–1769.
- [19] 柴杰, 江青茵, 曹志凯. RBF神经网络的函数逼近能力及其算法[J]. *模式识别与人工智能*, 2002, 15(3), 310–316.
- CHAI J, JIANG Q Y, CAO Z K. Function approximation capability and algorithms of RBF neural networks [J]. *Pattern Recognition and Artificial Intelligence*, 2002, 15(3), 310–316.
- [20] BUTLER H. Position control in lithographic equipment: an enabler for current-day chip manufacturing [J]. *IEEE Control Systems Magazine*, 2011, 31(5): 28–47.
- [21] 戴泳爻, 李鑫, 朱煜, 等. 超精密运动系统跟踪误差定量分析[J]. *中国电机工程学报*, 2019, 39(16): 4910–4918, 4993.
- DAO L Y, LI X, ZHU Y. Quantitative analysis on tracking errors in ultra-precision motion systems [J]. *Proceedings of the CSEE*, 2019, 39(16): 4910–4918, 4993.
- [22] DAI L Y, LI X, ZHU Y, et al. The generation mechanism of tracking error during acceleration or deceleration phase in ultraprecision motion systems [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(9): 7109–7119.
- [23] 李哲. 磁浮式补偿器结构设计及特性研究[D]. 哈尔滨工业大学, 2013.
- LI Z. Research on structure design and properties of magnetic compensation system [D]. Harbin: Harbin Institute of Technology, 2013.
- [24] FEI J T, WANG T T. Adaptive fuzzy-neural-network based on RBFNN control for active power filter [J]. *International Journal of Machine Learning and Cybernetics*, 2019, 10(5): 1139–1150.