

基于模糊推理和 Jordan 神经网络的 磁悬浮球位置补偿控制研究

李孝茹, 陈士松, 黄之文

(上海理工大学 机械工程学院, 上海 200093)

摘要: 针对欠训练 Jordan 神经网络(Jordan neural network, JNN)输出不确定性导致的控制系统动态性能不佳的问题, 提出了一种基于模糊推理(fuzzy inference, FI)和 JNN 的磁悬浮球位置补偿控制新方法, 构建了包含基础控制、JNN 控制和 FI 的三模块控制框架。基础控制模块采用适应性强的 PID 控制器; JNN 控制模块实现磁悬浮球系统的在线辨识与补偿; FI 模块动态调整神经网络控制器的输出, 以抑制欠训练 JNN 带来的不确定性影响。实验结果表明, 与传统神经网络补偿控制方法相比, 在跟踪阶跃信号和方波信号时, 超调量分别减小了 39.79% 和 60.61%, 调节时间分别减小了 19.52% 和 48.47%。该方法在保证稳态精度的同时, 显著提升了控制系统的动态性能。

关键词: 模糊推理; Jordan 神经网络; 位置补偿控制; 磁悬浮球

中图分类号: TP 273.1

文献标志码: A

Position compensation control of maglev ball system by fuzz inference and Jordan neural network

LI Xiaoru, CHEN Shisong, HUANG Zhiwen

(School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: To address the issue of poor dynamic performance in control systems caused by the output uncertainty of insufficiently trained Jordan neural network (JNN), a novel position compensation control method of maglev ball based on fuzzy inference (FI) and JNN was proposed. A three-module control framework was designed, consisting of a basic control module, a JNN control module, and a FI module. The basic control module adopted a highly adaptable PID controller to provide baseline control performance. The JNN control module performed real-time identification and compensation for the maglev ball system. The FI module dynamically adjusted the output of the neural network controller to

收稿日期: 2024-06-17

基金项目: 国家自然科学基金资助项目(51775323); 上海市在线检测与控制技术重点实验室开放基金资助项目(Z2022304013)

通信作者: 李孝茹(1980—), 女, 高级实验师。研究方向: 测试计量、智能控制与工业人机交互技术。E-mail: lixiaoru206@126.com

引文格式: 李孝茹, 陈士松, 黄之文. 基于模糊推理和 Jordan 神经网络的磁悬浮球位置补偿控制研究[J]. 上海理工大学学报, 2025, 47(3): 299-308.

Citation: LI Xiaoru, CHEN Shisong, HUANG Zhiwen. Position compensation control of maglev ball system by fuzz inference and Jordan neural network[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(3): 299-308.

suppress the uncertainty introduced by insufficiently trained JNN. The experimental results show that, compared with the traditional neural network compensation control method, the proposed method reduces overshoot by 39.79% and 60.61% and shortens the settling time by 19.52% and 48.47% when tracking step and square wave signals. The proposed method significantly enhances the dynamic performance of the control system while maintaining steady-state accuracy.

Keywords: *fuzzy inference; Jordan neural network; position compensation control; maglev ball*

近年来,具有无摩擦、低噪声、少污染等特点的磁悬浮技术逐渐应用于多个领域,如磁悬浮车辆、磁悬浮电机、磁悬浮轴承和磁悬浮球^[1]等。磁悬浮球系统的复杂非线性、强时变性导致对其进行实时高精度控制的难度大,故该系统常被用于进行各种先进控制方法的测试与验证。学者们针对该系统提出了许多控制方法^[2-3],如PID(proportional-integral-derivative)控制、鲁棒控制、模糊控制、LQR(linear quadratic regulator)控制。但这些传统控制方法在实际应用时,难以满足较高的精度要求,具有一定的局限性。

神经网络具有强大的自学习能力,被证明能够逼近任意非线性函数,并被成功应用于非线性系统的实时控制中,如汽车系统、机器人系统及电液伺服系统等复杂非线性控制系统。朱坚民等^[4]使用神经网络在线实时补偿PID控制量,显著提升了磁悬浮球位置控制系统的稳态性能,验证了在传统控制方法中引入神经网络在线补偿的有效性。谢莉莉等^[5]基于RBF(radial basis function)神经网络和滑模变结构原理设计了一种变结构控制器,仿真结果表明,小球能够较快达到稳定位置,控制系统具有较好的稳态特性和抗干扰特性。沈昕璐等^[6]在经典PID控制器的基础上,引入模糊神经网络对球杆系统进行在线辨识和控制补偿,仿真和实验结果均表明,该策略使得控制系统具有较好的稳态性能。Wei等^[7]提出了一种基于反向传播神经网络的在线前馈补偿控制器,降低了磁悬浮球系统位置控制的稳态误差。Sun等^[8]提出了一种基于RBF神经网络的监督控制方法,在磁悬浮系统的跟踪控制中取得了优异的稳态性能。虽然神经网络利用强大的自学习能力,可以在一定程度上有效提高控制系统的稳态性能,但其控制精度严重依赖被控对象逆模型的建模精度。

当跟踪阶跃信号和方波信号时,控制初期或

跟踪信号跃变瞬间缺乏足够的样本来充分训练神经网络,难以准确地建立被控对象逆模型,从而导致此时控制系统的动态性能较差。Jordan神经网络(Jordan neural network, JNN)因其直接反馈网络内部状态至输入,不仅能够在有限的控制输入下增加网络学习的样本数据量,而且可以利用其内部反馈信息,更加有效地学习到控制系统在时序间的关联性^[9]。近年来,有不少国内外学者将JNN运用到控制领域以提升控制系统的综合性能^[10]。但在跟踪信号跃变瞬间,其依然缺乏有效的训练数据来快速训练网络,使得JNN的输出具有不确定性,进而导致控制系统的动态性能难以得到保证。

模糊推理(fuzzy inference, FI)作为一种智能决策算法,具有释义明确、推理可靠等优点,常用于解决不确定性推理问题。Mousavi等^[11]应用双模糊逻辑系统来推理具有不确定输入的控制系统的内部动态,从而提高了自主水下车辆的控制稳定性。Gu等^[12]将FI引入到聚类任务的不确定问题中,并通过实验研究证明了所提出的基于FI方法的可行性和有效性。在控制系统的不确定性推理方面,Zhang等^[13]利用FI来解决电力系统改革中的不确定决策问题,有效提高了改革评价的稳健性。陈奇等^[14]针对粉末定量称重系统中的非线性和滞后问题,提出了Smith预估模糊PID控制算法,提高了系统的称重精度和稳定性。Sajan等^[15]使用FI系统来处理地下水质量的不确定评估,有效改善了地下水安全的管理。Tang等^[16]将FI应用于神经网络控制的不确定性问题中,提高了磁悬浮球位置控制的动态性能。Xiao等^[17]使用模糊逻辑来估计手术数据的不确定性,从而提高了手术机器人的能效。这些研究表明,FI具有解决JNN控制不确定性的潜力,但目前仍缺乏相关研究。

为了提高磁悬浮球系统的位置控制动态性能,本文提出了一种基于FI和JNN的磁悬浮球位置补偿控制新方法。该方法包括基础控制模块、

JNN 控制模块和 FI 模块。当 JNN 未充分训练时, FI 模块会对 JNN 控制模块的输出进行自适应抑制, 以减少此时 JNN 输出不确定性对于控制系统的影响。最后, 基于磁悬浮球位置控制系统进行仿真与实验研究。

1 控制原理与算法

磁悬浮球系统运行过程中, 被控系统含有丰富的状态量, 普通神经网络及递归神经网络并不能将这些含有丰富信息的状态量有效地转化为正确的控制量, JNN 恰好具有处理这类问题的能力。将控制结构中的基础网络转换成 JNN, 在 JNN 的基础上将 FI 机制引入其中, 通过设定好的模糊规则对 JNN 前馈补偿控制器的输出控制量作出适当的调整, 抑制欠训练 JNN 控制器在跟踪信号变化剧烈阶段的作用效果, 从而提升控制系统的动态性能。

1.1 控制原理

本文提出的基于 FI 的 JNN 补偿控制原理如图 1 所示, 其控制结构主要由 3 部分组成: 基础控制模块、FI 模块和 JNN 控制模块。其中: 基础控制模块选用的是适应性好且具有较强鲁棒性的 PID

控制器; FI 模块由规则库、模糊化接口、解模糊化接口及模糊推理器组成; JNN 控制模块由网络结构相同的辨识器和控制器组成。通过将采集到的被控系统的输出量 y 和输入量 u 实时喂入 JNN 辨识器进行学习, 利用 JNN 辨识器输出量 u_1 与总控制量 u 之间的误差 e_1 来反向传播更新 JNN 辨识器参数, 建立被控系统的动力学逆模型, 并将 JNN 输出层神经元作为该被控系统在那个时刻的状态量。而后, JNN 辨识器参数会将该时刻训练好的参数 ω 及学习到的状态量 s 动态传递给 JNN 控制器。在控制初期及跟踪信号跃变时, 单纯的 JNN 控制器仍然面临着缺乏有效训练样本的问题, 无法快速建立被控对象的精确逆模型, 这时候的 JNN 控制器的输出是不准确的。故将 FI 与 JNN 相结合, 模糊推理器会根据误差 e 与误差变化率 $\dot{e}$ 推断出动态调节因子 p , $p \in (0, 1]$ 。控制系统基于 p 对 JNN 控制器的输出 u_{JNN} 作出自适应调整。JNN 控制器会根据接收到的期望输出 r 进行前向运算, 产生前馈控制量 u_{JNN} , u_{JNN} 经 FI 模块自适应调整后与 PID 控制器输出 u_{PID} 共同作用于被控系统。图 1 中基于 FI 的 JNN 补偿控制结构不仅有效保证了控制系统的稳态性能, 而且显著提高了其动态性能。




图 1 基于 FI 的 JNN 补偿控制结构框图

Fig.1 Block diagram of compensation control for JNN based on FI

1.2 控制算法

1.2.1 控制量计算

控制系统的总控制量计算如下:

$$u = u_{PID} + u_p \tag{1}$$

式中: u_{PID} 为 PID 控制器的输出; u_p 为 JNN 控制

器自适应调整后的输出。

$$u_{PID} = k_p e(t) + k_i \sum_{i=0}^t e(i) \Delta t + k_d \frac{[e(t) - e(t-1)]}{\Delta t} \tag{2}$$

式中: t 为当前采样时刻; $t-1$ 为上一个采样时刻; Δt 为采样时间间隔; e 为误差; k_p 、 k_i 、 k_d 分

别为比例、积分、微分系数。

$$u_p = pu_{JNN} \quad (3)$$

式中： p 为模糊推理器的输出，即动态调节因子； u_{JNN} 为JNN控制器的输出。

JNN控制器结构如图2所示，本文使用的JNN只含有一个隐含层。




图2 JNN 结构图

Fig.2 JNN structure diagram

将JNN第 n 层的输入定义为 $I^n (n=I, II, III)$ ，第 n 层的输出定义为 O^n 。

JNN控制器的输出控制量 u_{JNN} 计算如下。

输入层：将跟踪目标 r 和上一个时刻控制系统的状态量 s 作为神经网络控制器的输入，即

$$O^I = I^I = \begin{bmatrix} r \\ s \end{bmatrix} \quad (4)$$

隐含层：由于这里只是浅层的神经网络，无需过多考虑梯度消失问题，故隐含层直接采用Sigmoid函数作为激活函数，隐含层神经元输出计算为

$$I^{II} = O^I \omega^I + b^I \quad (5)$$

$$O^{II} = 1 / [1 + \exp(-I_j^{II})] \quad (6)$$

式中： ω^I 为隐含层权值； b^I 为隐含层的偏置； I^{II} 为隐含层神经元输入； O^{II} 为隐含层神经元输出。

输出层：通过将隐含层得到的输出进行线性加权来计算结果，输出层采用的激励函数为线性激活，其计算为

$$O^{III} = I^{III} = O^{II} \omega^{II} + b^{II} \quad (7)$$

$$u_{JNN} = O^{III} \quad (8)$$

式中： ω^{II} 为输出层的权值； b^{II} 为输出层神经元偏置； O^{III} 为输出层输出。

控制系统通过模糊推理器计算出动态调节因

子 p ， p 作用于 u_{JNN} ，最终与PID控制器一起进行前馈补偿控制。

1.2.2 神经网络训练

将被控系统输出量 y 作为JNN辨识器的输入，JNN辨识器进行前向计算得到 u_1 。利用损失函数计算出 u_1 和 u 之间的损失值，然后基于该损失值使用梯度下降算法更新网络参数。

JNN训练过程中损失函数 L 的定义如下：

$$L = \frac{1}{2}(u - u_1)^2 \quad (9)$$

JNN的训练是为了建立精确的被控系统逆模型，目标是减小损失值，其参数 ω^I 、 ω^{II} 、 b_j^I 和 b^{II} 的训练过程为

$$\begin{cases} \delta^{III} = \frac{\partial L}{\partial O^{III}} = -(u - u_1) \\ \frac{\partial L}{\partial b^{II}} = \delta^{III} \\ \frac{\partial L}{\partial \omega^{II}} = \delta^{III} O^{II} \\ \delta^{II} = \frac{\partial L}{\partial I^{II}} = O^{II}(1 - O^{II})\delta^{III}\omega^{II} \\ \frac{\partial L}{\partial b^I} = \delta^{II} \\ \frac{\partial L}{\partial \omega^I} = \delta^{II} O^I \end{cases} \quad (10)$$

式中： δ^{III} 为损失函数对输出层输出 O^{III} 求导； δ^{II} 为损失函数对隐含层输入 I^{II} 求导。

综上所述，神经网络权值和偏置的更新公式如下：

$$\omega(t+1) = \omega(t) - \alpha \frac{\partial L}{\partial \omega} + \beta[\omega(t) - \omega(t-1)] \quad (11)$$

$$b(t+1) = b(t) - \alpha \frac{\partial L}{\partial b} + \beta[b(t) - b(t-1)] \quad (12)$$

式中： α 为学习率； β 为动量因子。

在控制过程中，使用的是上个时刻训练完成的JNN来进行下一个时刻的前馈补偿控制，即控制器的训练是有一定的迟滞的，故加入动量因子项的目的是为了使控制器具有一定的预测作用，使控制系统能够获得更好的控制效果。

2 模糊推理器

模糊推理器结构如图1模糊推理模块所示，主要由4部分组成：模糊化接口、模糊推理引擎、规则库以及解模糊化接口。控制系统的误差 e 和误差变化率 $\dot{e}$ 反映了控制器的控制效果，也直

接反映了磁悬浮球系统的控制状态。因此, 选用 e 和 $\dot{e}$ 作为模糊推理器的输入, e 和 $\dot{e}$ 的取值范围分别为 $(-10,10)$ 、 $(-20,20)$ 。模糊输出变量 p^* 用于计算最终的动态调节因子 p , p 的作用是对神经网络控制器的输出进行自适应调整, 以抑制神经网络控制器的不确定性对于控制系统的影响。将输入变量划分为 7 个模糊子集, 分别为: 负大 (NB)、负中 (NM)、负小 (NS)、零 (ZE)、正小 (PS)、正中 (PM)、正大 (PB); 将输出变量划分为 5 个模糊子集, 分别为: 小小 (SS)、小大 (SB)、中 (M)、大小 (BS)、大大 (BB)。

为避免模糊推理器输出抖动所造成的不稳定现象, 选用较为平滑的高斯型隶属度函数来模糊化输入, 其能较好地平滑模糊推理输出^[18], 故设定模糊集 E 和模糊集 $\dot{E}$ 包含 5 个高斯型、1 个 Z 型、1 个 S 型隶属度函数。三角形隶属度函数具有结构简单、便于运算的优点, 被广泛运用于大型系统的实时计算中, 为加快实时控制中反模糊化的运算速度, 故设计模糊集 P 包含 3 个三角形、1 个 Z 型、1 个 S 型隶属度函数。

模糊规则是模糊推理器最重要的部分, 它由一系列的模糊条件语句组成, 模糊推理器的输入为误差和误差变化率, 通过模糊规则转化为模糊输出。使用 if-then 语言描述的模糊逻辑如下:

if $E = A_m$ and $\dot{E} = B_n$, then $P = C_{mn}$ (13)

式中: A_m 、 B_n 为定义在模糊输入论域上的模糊集; C_{mn} 为定义在输出论域上的模糊集。

针对欠训练神经网络导致控制输出的不确定性, 采用模糊推理决策来抑制此时神经网络的补偿输出, 其模糊规则的具体设计依据如下:

a. 在控制初期和跟踪信号跃变瞬间, 用于训练神经网络的有效样本较少, 神经网络辨识器难以快速收敛, 故其前馈效果较差, 控制系统误差较大。此时, 神经网络辨识器尚未准确建立被控系统的逆模型, 这也意味着此时神经网络控制器的输出具有很强的不确定性。因此, 为了减少这种不确定性对于控制系统的影响, 需要减少 FI 的输出, 即增加对神经网络控制器输出的抑制。控制误差的绝对值越大, FI 的输出值应该越小。

b. 当跟踪信号剧烈变化时, 磁悬浮球系统的状态会发生显著变化。神经网络逆模型并不能在此时快速地收敛, 需要一定的时间来适应控制系统状态的变化。此时, 误差变化率的绝对值较

大, 需要适当削弱神经网络的控制作用, 即减少 FI 的输出。故误差变化率的绝对值越大, FI 的输出值应该越小。

c. 随着采样的增加, 神经网络逆模型越来越准确, 神经网络控制器的前馈控制效果也越来越好, 控制系统的误差和误差变化率较小。此时, 应增加 FI 的输出值, 减少对神经网络控制器输出的调整。故误差和误差变化率的绝对值越低, FI 的输出应该越小。

根据以上的专家经验, 使用模糊语言及模糊逻辑将上述准则转化为模糊规则表, 见表 1。

表 1 模糊规则

Tab.1 Fuzzy rule

$\dot{E}$	E						
	NB	NM	NS	ZE	PS	PM	PB
NB	SS	SS	SB	SB	SB	SS	SS
NM	SS	SB	M	M	M	SB	SS
NS	SS	M	M	BS	M	M	SS
ZE	SS	M	BS	BB	BS	M	SS
PS	SS	M	M	BS	M	M	SS
PM	SS	SB	M	M	M	SB	SS
PB	SS	SS	SB	SB	SB	SS	SS

p^* 的第 1 条模糊规则 R_1 可以表示为

$R_1 = [(u_{NB}(E) \times u_{SS}(p^*)) \cdot [u_{NB}(\dot{E}) \times u_{SS}(p^*)]]$ (14)

模糊规则共计 49 条, 对应 49 个模糊关系, 对这些模糊关系同时进行并运算, 得到 p^* 的模糊关系式如下:

$R = R_1 \cup R_2 \cup \dots \cup R_{49} = \bigcup_{i=1}^{49} R_i$ (15)

根据 FI 合成原则, 得到 p^* 对应的模糊集如下:

$p^* = (E \times \dot{E}) \circ R$ (16)

本文的模糊推理器采用重心法进行反模糊化。模糊推理得到输出 p^* , p^* 经增益模块 G 放大后得到 p_G 。在误差和误差变化率变化剧烈的情况下, 模糊推理的输出抖动亦较为明显, 此时会导致控制系统的紊乱, 为避免系统出现不稳定状态, 加入饱和块对模糊推理模块输出的变化率进行一定的限制。 p_G 到 p 的计算过程如下:

$p(k) = \begin{cases} p_G(k), & |p_G(k) - p_G(k-1)| \leq \xi \\ p(k-1) + \xi, & p_G(k) - p_G(k-1) > \xi \\ p(k-1) - \xi, & p_G(k) - p_G(k-1) < -\xi \end{cases}$ (17)

式中： ξ 为模糊推理器输出的变化率限制参数， p 的变化率不超过 ξ 。

3 磁悬浮球控制系统

磁悬浮球系统实验平台主要由以下几个部分组成：光源、电磁铁、磁悬浮钢球、光电位置传感器、计算机等，具体实验环境如图3所示。通过在Matlab/Simulink软件平台上编写相应的C-Mex程序来实现磁悬浮球的位置控制，每个控制周期内控制系统的输出量通过研华公司的PCI-1711数据采集与控制卡完成。




图3 磁悬浮球系统实验平台
Fig.3 Experimental platform for the maglev ball system

磁悬浮球系统的工作原理如图4所示。磁悬浮球上下的位移会间接影响光电位置传感器受到光照的面积，进而影响硅光电池的照度。磁悬浮球的位移信号 x 通过光电位置传感器转换成相对应的电压信号 U_{out} ，然后再经过信号调理以及A/D转换处理后进入计算机。计算机通过对比采集到的实时位置信号与期望信号，经控制器计算出前馈控制量。计算机将此控制量通过D/A转换得到 U_{in} ，再经过功率放大器处理得到所需的电流。电流大小的改变会影响电磁绕组所产生的电




图4 磁悬浮球系统原理图
Fig.4 Schematic diagram of the maglev ball system

磁吸力 F ，以此来实现磁悬浮球的控制。

4 实验研究

由于实际硬件的要求，需要对控制系统加入额外值为5的外部补偿量。通过多次的调整及对比，确定一组最优的PID实验参数，其值如下： $k_p=1.05$ 、 $k_i=0.003$ 、 $k_d=16$ 。

4.1 实验结果

4.1.1 连续阶跃信号跟踪结果

在连续阶跃信号跟踪实验中，跟踪信号每10s阶跃一次，需要先选取一组较优的JNN超参数。在动量因子 β 固定的情况下，学习率 α 在0.018~0.027之间变化，变化步长为0.001。对每个 α 进行5组仿真，求得超调量均值，将其作为衡量连续阶跃信号实验跟踪效果的指标。同理，在 α 固定的情况下， β 在0.026~0.035之间变化，变化步长为0.001。对每个 β 也进行5组仿真实验，求得其超调量均值。图5和图6分别给出了学习率和动量因子与控制系统超调量之间的关系，最优JNN超参数为： $\alpha=0.021$ ， $\beta=0.032$ 。




图5 学习率和控制系统超调量的关系
Fig.5 Relationship between learning rate and overshoot of control system




图6 动量因子和控制系统超调量的关系
Fig.6 Relationship between momentum factor and overshoot of control system

图7是参考信号Ref为连续阶跃信号时基于FI的JNN补偿控制结果。由图7可知，跟踪连续

阶跃信号时, 控制系统的超调量为 0.115 mm, 调节时间为 0.202 s。




图7 连续阶跃信号跟踪实验结果

Fig.7 Experimental results of continuous step signal tracking

图 8 为动态调节因子 p 的变化曲线。由图 8 可知: 在控制初期, 模糊推理器对 JNN 控制器的抑制作用最高达到了 28.1%; 在控制后期, 当连续阶跃信号跃变时, 模糊推理器对 JNN 控制器的抑制作用最高达到了 6.9%。




图8 连续阶跃信号跟踪实验中动态调节因子变化曲线

Fig.8 Variation curve of adjustment factor in continuous step signal tracking experiment

4.1.2 方波信号跟踪结果

在方波信号跟踪实验中, 先选取一组较优的 JNN 超参数, 其选取方法与连续阶跃信号跟踪实验的处理方法类似。学习率在 0.016~0.025 之间变化, 变化步长为 0.001; 动量因子在 0.036~0.045 之间变化, 变化步长为 0.001。学习率和动量因子与控制系统超调量之间的关系如图 9 和图 10 所示, 最优 JNN 超参数为: $\alpha=0.021$, $\beta=0.040$ 。

图 11 是参考信号为方波信号时基于 FI 的 JNN 补偿控制实验结果。可见, 跟踪方波信号时, 控制系统的超调量为 0.128 mm, 调节时间为 0.152 s。

图 12 为方波信号实验中动态调节因子 p 的变化曲线。在初期控制阶段, 模糊推理器对 JNN




图9 学习率和控制系统超调量的关系

Fig.9 Relationship between learning rate and overshoot of control system




图10 动量因子和控制系统超调量的关系

Fig.10 Relationship between momentum factor and overshoot of control system




图11 方波信号跟踪实验结果

Fig.11 Experimental results of square signal tracking

控制器的抑制作用最高达到了 25.2%; 在控制后期, 当方波信号跃变时, 模糊推理器模对 JNN 控制器的抑制作用最高达到了 7.6%。

图 13 给出了模糊推理器输出的变化率限制参数 ξ 对超调量的影响。结果表明: 在方波信号的跟踪实验中, 对模糊推理器输出变化率的限制过大或过小都会影响控制系统的超调量, 实验中 ξ 最优值为 0.004。

4.2 结果分析

为进一步验证本文所提出的基于 FI 的 JNN 补偿控制的实时性和有效性, 对 PID、JNN+PID 以




图 12 方波信号跟踪实验中动态调节因子变化曲线

Fig.12 Variation curve of adjustment factor in square signal tracking experiment




图 13 方波信号跟踪实验中变化率限制参数对超调量的影响

Fig.13 Effect of rate-limit parameter on overshoot in square wave signal tracking experiment

及 FI+JNN+PID 这 3 种控制结构进行对比实验。实验中 3 种控制结构所用到的 PID 控制器的控制参数相同, JNN 结构及其超参数也相同。

4.2.1 连续阶跃信号实验对比分析

3 种控制结构在连续阶跃信号跟踪实验中的控制结果如图 14 所示, 其动态性能对比见表 2。结果表明: 当只有传统的 PID 控制器作用于被控系统




图 14 连续阶跃信号跟踪实验控制结果对比

Fig.14 Comparison of control results in continuous step signal tracking experiments

统时, 控制系统超调量为 0.557 mm, 达到稳态的调节时间为 0.623 s; JNN 控制器使得超调量有所减小, 为 0.191 mm, 调节时间明显缩小, 为 0.251 s, 但控制状态不稳定; 引入模糊推理器对 JNN 控制器输出进行自适应调整后, 超调量减小到 0.115 mm, 调节时间缩短到 0.202 s, 控制系统的动态性能明显提升。

表 2 连续阶跃信号跟踪实验动态性能对比

Tab.2 Comparison of dynamic performance in continuous step signal tracking experiments

控制结构	超调量/mm	调节时间/s
PID	0.557	0.623
JNN+PID	0.191	0.251
FI+JNN+PID	0.115	0.202

图 15 对比了 JNN+PID 和 FI+JNN+PID 控制结构中 PID 控制器 (PIDC) 和 JNN 控制器 (JNNC) 的输出电压变化。结果表明, 引入 FI 后 JNN 能够更加快速地到达收敛状态, 进而提升了控制系统的动态特性。此外, 在引入 FI 模块前后, 稳态时 JNN 控制器的输出控制量并没有改变, 这也保证了控制系统的稳态性能。




图 15 连续阶跃信号跟踪实验控制量对比

Fig.15 Comparison of control quantities in continuous step signal tracking experiments

4.2.2 方波信号实验对比分析

3 种控制结构在方波信号跟踪实验中的控制结果如图 16 所示, 其动态性能对比见表 3。可以看出, 3 种控制结构均能实现方波信号的稳定控制。当只有传统的 PID 控制器作用于被控系统时, 控制系统超调量为 0.715 mm, 调节时间为 2.132 s。JNN 控制器使得控制系统超调量减小, 为 0.325 mm, 但控制状态不稳定; 调节时间明显缩小, 为 0.295 s。引入模糊推理器对 JNN 控制器输出进行自适应调整后, 超调量减小至 0.128 mm, 调节时间缩短至 0.152 s, 控制系统的动态性能大幅提升。




图 16 方波信号跟踪实验控制结果对比

Fig.16 Comparison of control results in square wave signal tracking experiments

表 3 方波信号跟踪实验动态性能对比

Tab.3 Comparison of dynamic performance in square wave signal tracking experiments

控制结构	超调量/mm	调节时间/s
PID	0.715	2.132
JNN+PID	0.325	0.295
FI+JNN+PID	0.128	0.152

图 17 给出了方波信号跟踪实验中 JNN+PID 和 FI+JNN+PID 控制结构的 PIDC 和 JNNC 的输出电压变化。结合图 16 和图 17, 可以看出, 当跟踪信号跃变时, 控制系统误差较大, 在引入 FI 模块后, FI 抑制了 JNN 控制器的输出, PID 控制器的输出显著增加, 控制系统的稳定性主要由 PID 控制器保证。当 JNN 训练完成时, PID 控制器的输出将逐渐接近 0, 控制系统的稳定性主要由 JNN 控制器保证。此外, 当跟踪信号突然跃变时, FI 模块有效地调整了 JNN 控制器的输出, 保证了稳态精度。因此, 引入 FI 后, JNN 能够更快到达稳定状态。




图 17 方波信号跟踪实验控制量对比

Fig.17 Comparison of control quantities in square wave signal tracking experiments

为了进一步验证 FI+JNN+PID 控制结构的鲁棒

性, 添加一段幅值为 0.4、持续时间为 0.1 s 的定值信号来模拟系统受到干扰的情况, 实验结果如图 18 所示。结果表明, 系统能够较快地恢复稳定, 鲁棒性能较好。




图 18 方波信号鲁棒性实验

Fig.18 Robustness experiment of the square wave signal

5 结 论

为了应对欠训练 JNN 输出不确定性所导致的控制系统动态性能不佳问题, 提出了一种基于 FI 和 JNN 的磁悬浮球位置补偿控制新方法。该方法引入 FI 模块, 根据误差及误差变化率动态调整 JNN 控制器的输出, 以抑制欠训练 JNN 带来的不确定性影响。实验结果表明, 所提出的方法相较于传统神经网络补偿控制方法, 在相同的参数条件下跟踪阶跃信号和方波信号时, 超调量分别减小了 39.79% 和 60.61%, 调节时间分别减小了 19.52% 和 48.47%。在保障控制系统稳态精度的前提下, 控制系统的动态品质得到显著改善。

本文控制方法无须建立被控对象的精确数学模型, 且能够抑制神经网络在线建模的不确定性, 较适用于具有复杂非线性、高度不确定性的强时变控制系统。控制器结构清晰、推理可靠, 简化了 PID 参数整定过程, 便于实际工程应用。

参考文献:

[1] VO A T, TRUONG T N, KANG H J. A novel fixed-time control algorithm for trajectory tracking control of uncertain magnetic levitation systems[J]. *IEEE Access*, 2021, 9: 47698–47712.

[2] EKINCI S, IZCI D, KAYRI M. An effective controller design approach for magnetic levitation system using novel improved manta ray foraging optimization[J]. *Arabian*

- [Journal for Science and Engineering](#), 2022, 47(8): 9673–9694.
- [3] CHEN C, XU J Q, JI W, et al. Sliding mode robust adaptive control of maglev vehicle's nonlinear suspension system based on flexible track: design and experiment[J]. [IEEE Access](#), 2019, 7: 41874–41884.
- [4] 朱坚民, 沈正强, 李孝茹, 等. 基于神经网络反馈补偿控制的磁悬浮球位置控制[J]. 仪器仪表学报, 2014, 35(5): 976–986.
- [5] 谢莉莉, 刘春生. 磁悬浮球系统的神经网络辨识及变结构控制[J]. [计算机测量与控制](#), 2007, 15(11): 1525–1527.
- [6] 沈昕璐, 莫鑫, 周亚南. 基于模糊神经网络的磁悬浮球位置控制研究[J]. [农业装备与车辆工程](#), 2018, 56(5): 59–64.
- [7] WEI Z X, HUANG Z W, ZHU J M. Position control of magnetic levitation ball based on an improved adagrad algorithm and deep neural network feedforward compensation control[J]. [Mathematical Problems in Engineering](#), 2020, 2020(1): 8935423.
- [8] SUN Y G, XU J Q, LIN G B, et al. RBF neural network-based supervisor control for maglev vehicles on an elastic track with network time delay[J]. [IEEE Transactions on Industrial Informatics](#), 2022, 18(1): 509–519.
- [9] WYSOCKI A, ŁAWRYŃCZUK M. Jordan neural network for modelling and predictive control of dynamic systems[C]//[Proceedings of 2015 20th International Conference on Methods and Models in Automation and Robotics](#). Miedzydroje, Poland: IEEE, 2015: 145–150.
- [10] DAS D, DAS A K, PAL A R, et al. Meta-heuristic algorithms-tuned Elman vs. Jordan recurrent neural networks for modeling of electron beam welding process[J]. [Neural Processing Letters](#), 2021, 53(2): 1647–1663.
- [11] MOUSAVI A, MARKAZI A H. Adaptive fuzzy sliding-mode control of under-actuated systems with unknown input gain function[J]. [Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science](#), 2024, 238(12): 5455–5468.
- [12] GU S H, CHOU Y X, ZHOU J, et al. Takagi-Sugeno-Kang fuzzy clustering by direct fuzzy inference on fuzzy rules[J]. [IEEE Transactions on Emerging Topics in Computational Intelligence](#), 2024, 8(2): 1264–1279.
- [13] ZHANG C H, LU W H, XU Z S, et al. Evaluating power system reform proposals based on the evidential reasoning algorithm with hesitant fuzzy information[J]. [Applied Intelligence](#), 2023, 53(21): 26079–26097.
- [14] 陈奇, 袁旭军, 张荣福, 等. Smith 预估模糊 PID 控制算法及其在粉末定量称重中的应用[J]. [光学仪器](#), 2024, 46(2): 28–35.
- [15] SAJAN R I, CHRISTOPHER V B. A fuzzy inference system for enhanced groundwater quality assessment and index determination[J]. [Water Quality Research Journal](#), 2023, 58(3): 230–246.
- [16] TANG J W, HUANG Z W, ZHU Y D, et al. Neural network compensation control of magnetic levitation ball position based on fuzzy inference[J]. [Scientific Reports](#), 2022, 12(1): 1795.
- [17] XIAO Y N, ZENG T, LING C J. RETRACTED ARTICLE: soft computing-enabled fuzzy-based approach to design access control mechanism for tele-robotic surgeries[J]. [Soft Computing](#), 2024, 28(S2): 737.
- [18] SONG S, ZHANG B Y, SONG X N, et al. Fractional-order adaptive neuro-fuzzy sliding mode H_∞ control for fuzzy singularly perturbed systems[J]. [Journal of the Franklin Institute](#), 2019, 356(10): 5027–5048.

(编辑: 董 伟)