

DOI:10.19651/j.cnki.emt.2211473

基于CMAC神经网络的超磁致伸缩非线性控制^{*}

潘明健¹ 安坤¹ 李健宏¹ 王奇¹ 孟江²

(1. 中北大学电气与控制工程学院 太原 030051; 2. 中北大学机械工程学院 太原 030051)

摘要: 对于超磁致伸缩材料固有的迟滞非线性特性,本文提出一种基于小脑模型神经网络(CMAC)前馈逆补偿与PID相结合的复合控制方法。首先利用CMAC神经网络学习获得超磁致伸缩致动器(GMA)的迟滞逆模型进行补偿,再利用CMAC模型在线快速学习适应的能力,结合PID控制器降低跟踪控制时的误差和扰动,从而实现GMA的精密控制。通过MATLAB建立了CMAC前馈逆补偿控制器和CMAC-PID复合控制模型,最后通过仿真实验验证所提方法的有效性。结果表明,提出的利用CMAC神经网络逼近的迟滞模型具有令人满意的精度,在CMAC-PID复合控制方案的作用下,系统的期望位移与实际位移相对误差值最大值仅2.39%,平均相对误差值不到0.5%。说明该控制策略能适应控制对象的非线性变化,有效地提高GMA的跟踪精度。

关键词: 超磁致伸缩;迟滞非线性;CMAC神经网络

中图分类号: TN389.1; TB381 **文献标识码:** A **国家标准学科分类代码:** 510

Nonlinear control of giant magnetostriction based on CMAC neural network

Pan Mingjian¹ An Kun¹ Li Jianhong¹ Wang Qi¹ Meng Jiang²

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China;

2. School of Mechanical Engineering, North University of China, Taiyuan 030051, China)

Abstract: For the inherent hysteresis nonlinearity of magnetostrictive materials, this paper presents a composite control method based on CMAC (cerebellar model neural network) feedforward inverse compensation and PID. Firstly, CMAC neural network is used to learn and obtain the hysteresis inverse model of giant magnetostrictive actuator (GMA) for compensation, and then the CMAC model is used to learn and adapt online quickly, and PID controller is used to reduce the error and disturbance during tracking control, so as to realize the precision control of GMA. CMAC feedforward inverse compensation controller and CMAC-PID compound control model are established by MATLAB. Finally, the effectiveness of the proposed method is verified by simulation experiments. The results show that the proposed hysteresis model approximated by CMAC neural network has satisfactory accuracy. Under the action of CMAC-PID composite control scheme, the maximum relative error between the expected displacement and the actual displacement of the system is only 2.39%, and the average relative error is less than 0.5%. It shows that the control strategy can adapt to the nonlinear change of the control object and effectively improve the tracking accuracy of GMA.

Keywords: giant magnetostriction; hysteresis nonlinearity; CMAC

0 引言

超磁致伸缩致动器(giant magnetostrictive actuator, GMA)作为一种常见的定位致动器,具有响应速度快、位移较大、输出力较高、没有疲劳极限等优点,在精密工业、光学技术以及微型机电系统等领域具有广阔的应用前景。然而,由于超磁致伸缩材料(GMM)固有的迟滞非线性,将导致压电执行器的开环控制不准确,降低跟踪性能,还可能导

致系统中出现不希望出现的振荡,甚至闭环系统也不稳定^[1]。

在众多迟滞模型之中,Preisach模型在GMA非线性控制领域中使用最为经典,因为它能准确地描述智能材料的磁滞特性。该模型的原理较为简单,并且可以更直接的通过数学公式表达^[2]。曹祎等^[3]采用Jiles-Atherton物理模型对磁致伸缩材料进行磁滞建模,该模型能够反映驱动磁场特性,但其参数辨识复杂,导致建模精度可能下降。Wang等^[4]利用循环神经网络搭建PI模型对GMA建

收稿日期:2022-09-20

^{*} 基金项目:国家自然科学基金(61774138)、山西省自然科学基金面上项目(201801D121184)资助

模,PI模型虽然由经典 Preisach 模型发展而来,但其建模复杂程度也因此提高。因此选用 Preisach 模型在特定频率 1Hz 下对 GMA 进行迟滞建模。

目前对致动器的位移控制依然以 PID 控制器为主。虽然是工业控制中应用最广泛的一种基本控制律,但如果仅仅依靠常规 PID 对非线性较强的系统进行控制,并不能满足精密致动的要求。王丽梅等^[5]提出基于径向基函数(RBF)神经网络整定 PID 控制,丰少伟等^[6]提出采取遗传算法整定 PID 控制,何忠波等^[7]提出将模型预测控制与滑模控制相结合的控制。虽然可以有效提升跟踪能力,但滞后现象依然明显存在。

为了提高 GMA 的运动精度,有许多侧重于通过使用基于迟滞模型逆模型的前馈补偿器的方法来消除迟滞引起的影,由于建模的不精确性和复杂的计算,这些方法往往导致 GMA 的控制器设计上的困难^[8]。Janaideh 等^[9]提出基于 Prandtl-Ishlinskii 逆模型的率相关的开环补偿, Yu 等^[10]则采用了动态递归神经网络进行前馈控制。Zhang 等^[11]提出一种自适应神经数字隐式逆运动控制方案,解决了非对称滞后非线性系统的高精度位置数字控制问题。他们均取得良好的控制效果,但也存在着自适应能力一般,或者建模复杂,计算量较大等问题。而且超磁致伸缩材料的迟滞非线性较强,可能会受环境与自身等因素影响,因此要求超磁致伸缩执行器的控制器拥有快速的自适应能力。

小脑模型关节控制器(CMAC)由 Albus 在 1975 年首次提出,系旨在模拟人类小脑的信息存储和学习结构。CMAC 属于联想记忆神经网络的范畴,具有强大非线性映射能力,是基于表格查询式输入、输出的局部神经网络模型,能够快速学习任意多维非线性映射^[12-13]。Saliyah 等^[14]首先提出了由 CMAC 逼近迟滞模型的可行性。胡世峰等^[15]提出了一种基于 CMAC 神经网络逼近的迟滞逆模型的前馈逆补偿控制策略,在非线性较小的系统取得了较好的跟踪控制效果。谢日时^[16]提出利用 CMAC 在线学习的能力来控制,其网络是在控制工作进行时开始学习,需要经过一定周期能够适应实现稳定控制。因此在可行条件下,先通过 CMAC 神经网络建立迟滞逆模型,再通过边控制边学习是实现 GMA 精密控制的可选选择。

1 扩展 Preisach 迟滞模型

Preisach 模型是最常用的基于算子表达迟滞特性的模型之一,其经典数学表达式为:

$$y(t) = \iint_{\alpha \geq \beta} \mu(\alpha, \beta) \gamma_{\alpha\beta}[u(t)] d\alpha d\beta \quad (1)$$

式中: $u(t)$ 为输入信号, $y(t)$ 为输出信号, $\mu(\alpha, \beta)$ 为权重函数, $\gamma_{\alpha\beta}[u(t)]$ 为算子,在极化的方向上取值 0 或 1。

$$\gamma_{\alpha\beta}[u(t)] = \begin{cases} 1, & u(t) > \beta \\ -1, & u(t) < \alpha \\ \theta, & \beta \leq u(t) \leq \alpha \end{cases} \quad (2)$$

模型的输出是并联连接的几个算子和加权函数的总和,实现 Preisach 模型中积分器的概念。图形描述如图 1 所示。




图 1 $u(t)$ 的电压从 β_0 单调增加到 α' , 然后单调减小到 β'




图 2 在上升阶段和下降阶段施加的电压 $u(t)$

Preisach 输出可以表示为以下公式:

$$f(t) = \iint_{S^-} \mu(\alpha, \beta) d\alpha d\beta \quad (3)$$

其中, S^+ 表示图 1 中灰色阴影区域。Preisach 函数 $F(\alpha', \beta')$ 被定义为:

$$F(\alpha', \beta') = f_{\alpha'} - f_{\alpha'\beta'} = \iint_{S_{\Delta}(\alpha', \beta')} \mu(\alpha, \beta) d\alpha d\beta \quad (4)$$

$f_{\alpha'}$ 表示为输入从 $\beta_0 = 0$ 增加到 α' 的输出,也就是图 1 中的 $f_{\alpha'} = \iint_{S_{\Delta}(\alpha', \beta_0)} \mu(\alpha, \beta) d\alpha d\beta = F(\alpha', \beta_0)$, $f_{\alpha'\beta'}$ 表示为输入从 α' 下降到 β' 的输出,也就是 $f_{\alpha'\beta'} = \iint_{S^+(t)} \mu(\alpha, \beta) d\alpha d\beta = F(\alpha', \beta')$ 。此外,如果存在如图 2(a) 所示的 $u(t)$ 进入上升阶段的一系列输入,则 $f(t)$ 可以根据式(3)重写为以下表达式:

$$f(t) = [F(\alpha_1, \beta_0) - F(\alpha_1, \beta_1)] + [F(\alpha_2, \beta_1) - F(\alpha_2, \beta_2)] + \dots + [F(\alpha_n, \beta_{n-1}) - F(\alpha_n, \beta_n)] + F(u(t), \beta_n) = \sum_{k=1}^n [F(\alpha_k, \beta_{k-1}) + F(\beta_k, \alpha_k)] + F(\alpha_{n+1}, \beta_n) \quad (5)$$

为了简化上面的表达式,扩展的 Preisach 函数被重新定义以满足输入变量的反交换性:

$$F'(\alpha, \beta) = \begin{cases} F(\alpha, \beta), & \alpha > \beta \\ 0, & \alpha = \beta \\ -F(\alpha, \beta), & \alpha < \beta \end{cases} \quad (6)$$

于是,式(5)可以写为:

$$f(t) = \sum_{k=1}^n [F'(\alpha_k, \beta_{k-1}) - F'(\beta_k, \alpha_k)] + F'(\alpha_{n+1}, \beta_n) = \sum_{k=1}^{2n-1} F'(v_k, v_{k-1}) \quad (7)$$

连续施加的电压存储在 $V = \{v_0, v_1, \dots, v_{2n-1}, v_{2n}\} = \{\beta_0, \alpha_1, \dots, \beta_n, \alpha_{n+1}\}$, 并且 V 的最后一个分量是 $v_{2n+1} = \alpha_n = u(t)$ 。

相似的,可以得到处于下降阶段的表达式:

$$f(t) = [F(\alpha_1, \beta_0) - F(\alpha_1, \beta_1)] + [F(\alpha_2, \beta_1) - F(\alpha_2, \beta_2)] + \dots + [F(\alpha_n, \beta_{n-1}) - F(\alpha_n, u(t))] = \sum_{k=1}^n [F'(\alpha_k, \beta_{k-1}) - F'(\beta_k, \alpha_k)] = \sum_{k=1}^{2n} F'(v_k, v_{k-1}) \quad (8)$$

式中: $u(t)$ 是 $\beta_n = u(t)$ 中存储的电压序列,即 $V = \{v_0, v_1, \dots, v_{2n-1}, v_{2n}\} = \{\beta_0, \alpha_1, \dots, \alpha_n, \beta_n\}$ 。

根据式(7)和(8)简化 $f(t)$, 并使用扩展的 Preisach 函数作为以下公式:

$$f(t) = \sum_{k=1}^m F'(v_k, v_{k-1}) \quad (9)$$

式中: m 是电压序列的长度。如果新的未知量 $u(t)$ 落在两个相邻电压之间,则更新的 m 将确定施加的电压 $u(t)$ 是处于上升还是下降序列。

2 小脑模型神经网络建模

CMAC (cerebellar model articulation controller) 神经网络是 J. S. Albus 在 1975 年最先提出来的,它是仿照小脑如何控制肢体运动的原理而建立的神经网络模型。CMAC 最初用来求解机械手的关节运动,其后用于机器人控制、模式识别、信号处理以及自适应控制等领域。CMAC 神经网络是一种表达复杂非线性函数的表格查询型自适应神经网络,该网络可通过学习算法改变表格中的内容具有信息分类存储的能力^[17]。

CMAC 神经网络的实现通过两层映射得到。第 1 层映射将输入映射到具有 m 维向量的内存存储空间 \mathbf{A} , 第 2 层映射将 \mathbf{A} 映射到相应内存地址的权值向量矩阵 \mathbf{W} 。

$$\mathbf{A} = [a_1, a_2, \dots, a_m]^T \quad (10)$$

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \dots \\ \vdots & \vdots & \vdots \\ w_{n1} & w_{n2} & \dots \end{bmatrix} \quad (11)$$

关于 CMAC 概念映射方法,采用把输入空间 S 在区间 $[S_{\min}, S_{\max}]$ 上分成 $N + 2C$ 个量化区间。

$$v_i = \begin{cases} S_{\min}, & i = 1, 2, \dots, N \\ v_{i-1} + \frac{S_{\max} - S_{\min}}{N-1}, & i = C+1, \dots, C+N \\ S_{\max}, & i = N+C+1, \dots, N+2C \end{cases} \quad (12)$$

式中: S_{\min} 和 S_{\max} 为输入空间的下限和上限。CMAC 实际

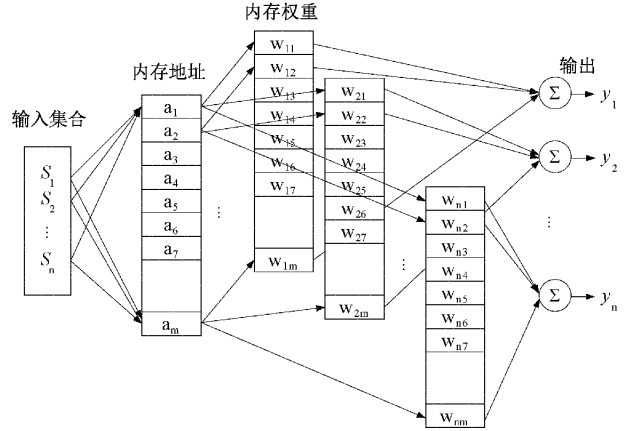


图 3 CMAC 结构示意图

映射的方法为:

$$a_i = \begin{cases} 1, & S_i \in [v_i, \dots, v_{i-C}], i = C+1, \dots, C+N \\ 0, & \text{其他} \end{cases} \quad (13)$$

存储器激活的地址值为 1,其余的大部分地址值为 0。对于输入空间相近的输入, \mathbf{A} 中会有部分的单元被重叠激活,然后再映射到相应的权重向量 w 。输入越相近,重叠越多;距离远的点,则在 \mathbf{A} 中几乎不重叠,即只有相近的输入才会产生相近的输出。

在训练过程中,使用 CMAC 实际输出和期望输出之间的差来调整相应的内存权重。CMAC 神经网络建模的学习算法中记忆权重的更新规律可以表示为:

$$w_{ij}(k) = w_{ij}(k-1) + \Delta w_{ij}(k-1) = w_{ij}(k-1) + \frac{\lambda}{m} a_i [\hat{y}_i(k-1) - y_i(k-1)] \quad (14)$$

其中, k 表示样本数, \hat{y}_i 是状态 s 的期望输出, λ 是学习速率, m 是泛化常数。最后,每个状态的输出应该从激活权重的总和中获得。因此,CMAC 算法的输出为:

$$y_i = \sum_{j=1}^m a_j w_{ij} \quad (15)$$

为了验证使用 CMAC 神经网络对迟滞逆模型建模的可行性,首先对迟滞非线性模型主环进行建模,通过仿真结果验证模型可行性。利用磁场和磁场变化率作为 CMAC 神经网络的输入,GMA 的期望位移作为网络的输出,这样便可将磁滞回线的一对多映射关系转化为一对一关系。CMAC 输入变量为二维向量,取量泛化常数为 40,权矩阵存储空间为 2 400,学习速率为 0.5。训练结果如图 4 所示。

由图 4 所示,引入磁场变化率作为输入训练的 CMAC 神经网络模型可以成功逼近 GMA 的迟滞回线模型。因此可将基于 CMAC 的建模方法应用于 GMA 的迟滞逆模型的建模,在此基础上实现 GMA 的前馈逆补偿控制。由图 5 所示,CMAC 模型逼近的收敛速度极快,这是由于 CMAC 的每个神经元的输入输出是一种线性关系,总体可以看似一种表达非线性映射的表格系统。CMAC 网络的学习只

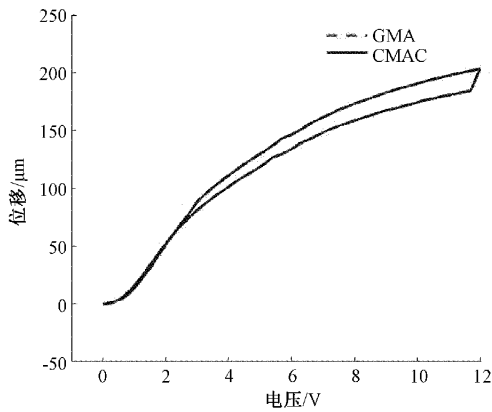


图4 CMAC超磁致伸缩致动器的迟滞模型逼近

在映射部分,因此与BP神经网络相比,拥有收敛速度快、记忆稳定、不易陷入局部极小值的优点。




图5 CMAC训练收敛曲线

3 CMAC-PID复合控制方案

图6为CMAC-PID复合控制方案的原理框图。该方案采用监督学习结构,由一个CMAC前馈控制器和一个PID控制器组成。PID反馈控制器是为了减小CMAC神经网络模型学习的误差,并且提高系统的响应速度和鲁棒性。其中期望信号 $r(t)$ 为离散状态, y 是系统的实际输出。设输入信号 $r(t)$ 为参考输入,与其变化率 $dr(t)/dt$ 一起作为CMAC前馈控制器的输入,得到CMAC的输出。训练后与PID控制器的输出相加,得到系统总的控制输入。即 $u(t)$ 为CMAC控制器和PID控制器共同作用下的输入信号。

$$u(t) = u_{\text{CMAC}}(t) + u_{\text{PID}}(t) \quad (16)$$

$$e(t) = r(t) - y(t) \quad (17)$$

CMAC神经网络是一种局部逼近神经网络,因此对于每个输入信号,只有少量的相应权值需要进行调整,从而相比全局逼近网络具有在线学习速度快的优点,这一点非常适合用于在线实时控制。作为前馈控制器,每一控制周期结束,CMAC会根据跟踪误差 $e(t)$ 再次进入学习过程。在线学习的目的是快速适应系统的动态变化,并且使误差尽可能地减小,这种方法的特点是学习和控制同时进行,使控

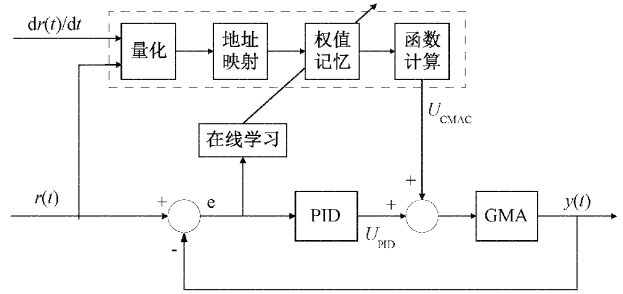


图6 CMAC-PID复合控制框图

制系统能够快速适应被控对象动态变化。CMAC在线控制的调整目标为:

$$E(k) = \frac{1}{2} (e(t))^2 \frac{1}{m} \quad (18)$$

CMAC神经网络在线学习的权值调整规则采用梯度下降法:

$$\Delta w_{ij}(k) = \eta \frac{e(t)}{m} a_i \quad (19)$$

$$w_{ij}(k) = w_{ij}(k-1) + \Delta w_{ij}(k) + \alpha (w_{ij}(k-1) - w_{ij}(k-2)) \quad (20)$$

式中: η 为网络学习速率, α 为惯性量,二者的一般取值为(0,1)。由于CMAC网络已经实现逼近逆模型,因此 η 和 α 的取值可以适当减小,将二者均取值为0.2。

4 系统仿真及结果分析

在建立描述GMA的Preisach迟滞模型作为受控对象,和CMAC前馈逆补偿控制器后,根据图6所示的原理框图,在Simulink中搭建系统模型进行仿真实验。

4.1 正弦信号跟踪

首先测试的信号为1 Hz的正弦信号,幅值为 $100 \mu\text{m}$,结果如下图所示。为了验证所设计的CMAC控制器的控制效果,还设计了传统的基于Preisach迟滞逆模型的前馈补偿控制器进行比较。

如图7、8所示,输入正弦信号,基于Preisach逆模型补偿所得的期望位移与实际位移绝对误差值最大达到 $1.45 \mu\text{m}$,平均误差为 $0.46 \mu\text{m}$,平均百分比误差为0.46%,系统的控制效果较好。

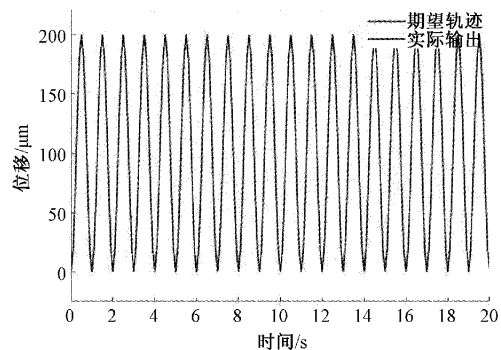


图7 基于Preisach逆模型的跟踪性能




图 8 基于 Preisach 逆模型的跟踪误差

如图 9、10 所示,输入正弦信号,CMAC-PID 控制器最初所得的期望位移与实际位移绝对误差值最大,达到 $2.39 \mu\text{m}$ 。可以明显的看到,随着正弦信号的周期性往复,CMAC 控制器能够在线快速学习继续提高精度。经过几个周期的学习,周期最大误差能够快速降到 $0.78 \mu\text{m}$,平均百分比误差能够稳定保持在 0.37% 左右。




图 9 基于 CMAC-PID 的跟踪性能




图 10 基于 CMAC-PID 的跟踪误差

该控制方案能够超越传统的基于 Preisach 逆模型的跟踪精度。这种快速在线学习提高精度的能力是传统逆补偿模型所不具备的优势。

4.2 均匀分布的随机数信号的跟踪

为了测试 CMAC-PID 控制器的自适应能力,设计了均匀分布的随机数信号进行跟踪实验,信号最大值为

$200 \mu\text{m}$ 。

如图 11、12 所示,输入均匀分布的随机数信号,基于 Preisach 逆模型补偿所得的期望位移与实际位移最大绝对误差值为 $2.97 \mu\text{m}$,平均误差值为 $0.54 \mu\text{m}$,平均百分比误差为 0.54% 。




图 11 基于 Preisach 逆模型的跟踪性能




图 12 基于 Preisach 逆模型的跟踪误差

如图 13、14 所示,输入均匀分布的随机数信号,基于 CMAC-PID 所得的期望位移与实际位移最大绝对误差值为 $2.05 \mu\text{m}$,平均误差值为 $0.42 \mu\text{m}$,平均百分比误差仅为 0.42% 。尽管信号数值是随机均匀分布生成的,但 CMAC 可以在线学习调整,从而实现快速适应系统的变化。随机数信号的跟踪误差略大于正弦信号的跟踪误差,总体上差别不大。

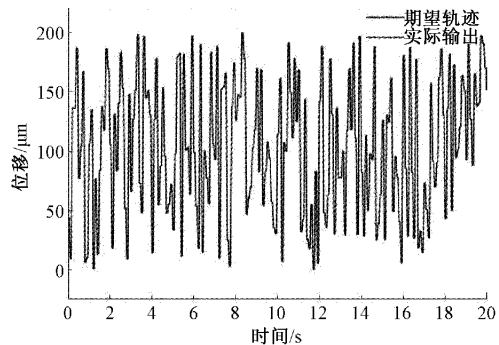


图 13 基于 CMAC-PID 的跟踪性能




图14 基于CMAC-PID的跟踪性能

4.3 系统的抗干扰特性

GMA在实际运用的过程中,不可避免地要遇到各种干扰,抗干扰性能也是评价控制系统的一个重要的指标。

为了测试CMAC-PID控制器的抗干扰特性,本文在GMA的动态响应进入稳定阶段时,在不同时间加入扰动输入 $d(t)$ 。扰动信号如图15所示。




图15 输入的干扰信号

如图16所示,系统即使受到干扰,也能够立即返回到稳定状态,几乎不受影响。这说明本控制方案具有良好的抗干扰能力。




图16 干扰信号下的控制性能

综上所述,在CMAC-PID的复合控制下,GMA实际输出对输入信号的跟踪效果较好,对于所使用的正弦信号和均匀分布的随机数信号,输出的最大相对误差只有最初的2.39%,平均相对误差更只有不到1%。每种输入信号与

其相对应的输出信号线性拟合后具有较强的线性关系。因此验证了CMAC前馈控制器不但对迟滞模型逼近的精度高,还可以在周期信号下继续在线学习,在随机信号下同样拥有较好的自适应能力,并且拥有强大的抗干扰能力。这说明CMAC前馈逆补偿控制器可以有效补偿GMA的迟滞特性。

5 结 论

本文对描述迟滞特性的Preisach模型进行分析,在此基础上进行扩张并建立迟滞非线性数学模型。提出了基于CMAC控制的迟滞非线性系统的神经网络模型结构,分析了CMAC神经网络的原理以及实现方式。将GMA的期望输出位移及其随时间变化率作为神经网络输入,磁化强度作为神经网络的输出,成功用其对迟滞回线逆模型进行建模。并且利用CMAC快速在线学习的能力,采用改进的Preisach模型作为被控对象,建立了基于CMAC前馈逆补偿和PID反馈控制相结合的复合控制系统。仿真结果表明:无论系统期望信号是正弦信号还是随机信号,20s控制周期的平均相对误差均在0.5%以下,基于CMAC-PID的复合控制能够实现GMA迟滞特性的精确跟踪控制。

参考文献

- [1] APICELLA V, CLEMENTE C S, DAVINO D, et al. Review of modeling and control of magnetostrictive actuators[C]. Actuators, MDPI, 2019, 8(2): 45.
- [2] GUO Y, MAO J, ZHOU K. Rate-dependent modeling and control of GMA based on Hammerstein model with Preisach operator [C]. 2012 IEEE International Conference on Mechatronics and Automation, IEEE, 2012: 343-347.
- [3] 曹祎,王路,雷民,等. 基于改进粒子群算法的电流互感器J-A模型参数辨识[J]. 电测与仪表, 2021, 58(5):8.
- [4] WANG Y, XU R, ZHOU M. Prandtl-ishlinskii modeling for giant magnetostrictive actuator based on internal time-delay recurrent neural network[J]. IEEE Transactions on Magnetics, 2018, PP(99):1-4.
- [5] 王丽梅,董桢吉. 超磁致伸缩致动器的基于RBF神经网络整定PID控制[J]. 组合机床与自动化加工技术, 2013(5):4.
- [6] 丰少伟,杨云生,张晶. 遗传算法整定PID参数的超磁致伸缩作动器控制策略研究[J]. 海军工程大学学报, 2017, 29(3):4.
- [7] 何忠波,荣策,周景涛,等. 叠堆式超磁致伸缩致动器的模型预测滑模控制[J]. 光学精密工程, 2018, 26(7):11.
- [8] SMITH R C, BOURON C, ZROSTLIK R. Partial

- and full inverse compensation for hysteresis in smart material systems [C]. American Control Conference, IEEE, 2002.
- [9] AL JANAIDEH M, ALJANAIDEH O. Further results on open-loop compensation of rate-dependent hysteresis in a magnetostrictive actuator with the Prandtl-Ishlinskii model [J]. Mechanical Systems and Signal Processing, 2018, 104: 835-850.
- [10] YU C, WANG C, DENG H, et al. Hysteresis nonlinearity modeling and position control for a precision positioning stage based on a giant magnetostrictive actuator [J]. RSC Advances, 2016, 6(64):59468-59476.
- [11] ZHANG X, LI B, LI Z, et al. Adaptive neural digital control of hysteretic systems with implicit inverse compensator and its application on magnetostrictive actuator [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020(99):1-14.
- [12] ALBUS J S. A new approach to manipulator control: The cerebellar model articulation controller (CMAC) [J]. Transactions of the Asme Journal of Dynamic Systems, 1975, 97(3):220-227.
- [13] LIN C S, CHIANG C T. Learning convergence of CMAC technique [J]. IEEE Transactions on Neural Networks, 1997, 8(6):1281-92.
- [14] SALIAH H H, LOWTHER D A. The use of neural networks in magnetic hysteresis identification [J]. Physica B Condensed Matter, 1997, 233(4):318-323.
- [15] 胡世峰, 朱石坚, 楼京俊, 等. 基于 CMAC 小脑神经网络的超磁致伸缩作动器高精度控制的仿真研究 [J]. 振动与冲击, 2009, 28(3):5.
- [16] 谢日时. 基于超磁致伸缩的汽车制动噪声主动控制研究 [D]. 杭州:浙江大学, 2019.
- [17] 韩力群. 神经网络理论、设计及应用(第 2 版) [M]. 北京:化学工业出版社, 2007.

作者简介

潘明健, 硕士研究生, 主要研究方向为 MEMS 器件智能控制。

E-mail:757828549@qq.com

安坤(通信作者), 副教授, 博士, 主要研究方向为 MEMS 器件系统设计等。

E-mail:ankun@nuc.edu.cn