

文章编号: 1673-3193(2024)05-0706-10

超磁致伸缩材料迟滞特性的新 Hammerstein 建模

李 宁¹, 安 坤¹, 郭立山¹, 李 森¹, 孟 江²

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

摘要: 超磁致伸缩材料(Giant Magnetostrictive Material, GMM)作为一种新型功能材料,因其具有磁-机耦合系数大、响应速度快、频响特性好等优点而被广泛应用于能量采集、微位移驱动、精密定位控制等领域,但材料复杂的迟滞非线性影响了其致动器的定位精度,为了辨识超磁致伸缩材料中存在的迟滞非线性,本文提出一种新 Hammerstein 模型建模方法。此方法的优点在于模型可以更好地逼近迟滞非线性,提供更高的精度,减少了串联环节的参数辨识工作量。首先,构建一个基于双曲函数的迟滞算子扩展空间的极限学习机模型,用其表示新 Hammerstein 模型中的静态非线性部分。其次,提取极限学习机模型的全连接层的权重和偏置参数用于构建新模型中的动态线性部分的状态空间方程,减少了传统模型中串联环节的模型参数辨识的工作。最后,建立了可以描述超磁致伸缩材料迟滞特性的新 Hammerstein 模型。新 Hammerstein 模型的建模相对误差为 0.86%~3.69%,平均绝对误差为 2.63%,比传统 Hammerstein 模型均方根误差低 0.8 μm 左右,平均绝对误差提高将近 4%。仿真结果证明了新 Hammerstein 模型对超磁致伸缩材料复杂迟滞特性建模的有效性。

关键词: 超磁致伸缩材料; 迟滞特性; 极限学习机; 迟滞算子; Hammerstein 模型

中图分类号: TP389.1; TB381 **文献标识码:** A **doi:** 10.3969/j.issn.1673-3193.2024.05.017

引用格式: 李宁,安坤,郭立山,等. 超磁致伸缩材料迟滞特性的新 Hammerstein 建模[J]. 中北大学学报(自然科学版), 2024, 45(5): 706-715.

LI Ning, AN Kun, GUO Lishan, et al. New Hammerstein modeling of hysteresis characteristics of giant magnetostrictive materials[J]. Journal of North University of China (Natural Science Edition), 2024, 45(5): 706-715.

New Hammerstein Modeling of Hysteresis Characteristics of Giant Magnetostrictive Materials

LI Ning¹, AN Kun¹, GUO Lishan¹, LI Sen¹, 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: Giant magnetostrictive material (GMM), as a new type of functional material, was widely used in energy harvesting, micro displacement driving, precision positioning control and other fields due to its advantages of large magneto mechanical coupling coefficient, fast response speed, and good frequency response characteristics. However, the complex hysteresis nonlinearity of the material affected the positioning accuracy of its actuator. In order to identify the hysteresis nonlinearity in GMM materials, this paper proposed a new

收稿日期: 2024-01-08

基金项目: 国家自然科学基金资助项目(61774138); 山西省面上自然科学基金资助项目(201801D121184)

作者简介: 李 宁(1998-), 男, 硕士生, 主要从事智能器件迟滞建模与控制等方面的研究。

通信作者: 安 坤(1975-), 女, 副教授, 博士, 主要从事智能微纳结构器件的研究。E-mail: ankun@nuc.edu.cn。

Hammerstein model modeling method. The advantage of this method was that the model could better approximate hysteresis nonlinearity, provide higher accuracy, and reduce the workload of parameter identification in the series link. Firstly, an extreme learning machine model was constructed based on hyperbolic functions to represent the static nonlinear part of the new Hammerstein model in the extended space of hysteresis operators. Secondly, the extracted weights and bias parameters of the fully connected layers of the extreme learning machine model was used to construct the state space equation of the dynamic linear part in the new model, which reduced the workload of identifying model parameters in the traditional model with serial links. Finally, a new Hammerstein model was established to describe the hysteresis characteristics of giant magnetostrictive materials. The modeling relative error percentage of the new Hammerstein model is 0.86% to 3.69%, and the average absolute error percentage is 2.63%, which is about 0.8 μm lower than the root mean square error of the traditional Hammerstein model, and the average absolute percentage error increases 4%. The simulation results demonstrate the effectiveness of the new Hammerstein model in modeling the complex hysteresis characteristics of giant magnetostrictive materials.

Key words: magnetostrictive materials; hysteresis characteristics; extreme learning machine; hysteresis operator; Hammerstein model

0 引言

近年来,一些先进的智能材料被广泛应用于精密定位技术,如压电陶瓷^[1]、磁致伸缩^[2]等材料为微位移执行器的发展提供了强劲动力。超磁致伸缩驱动器采用最先进的稀土合金材料,具备极短的反应时间、极大的伸缩系数、极高的定位精度和极强的功率密度,磁致伸缩材料在外激励磁场的作用下产生形变,并根据形变量进行精密驱动,其具有响应速度快、寿命长、形变灵敏以及功耗低等优点,在国防领域、科技等产业界受到高度重视,在精密定位领域同样具有极大的应用潜力。然而材料本身存在的迟滞非线性影响了系统的性能,不仅使得系统的控制精度下降^[3],引起误差和振荡,严重时甚至会导致系统的不稳定^[4]。

针对上述问题,国内外学者进行了大量研究,同时也提出了一些针对迟滞建模的理论和方法。通常迟滞模型分为静态模型和动态模型。其中,静态代表模型有 Preisach、PI、Bouc-Wen、MaxWell 等模型。Preisach 模型^[5-6]是一种非线性模型,特别适用于描述非线性系统,同时其具有数学表达简单、适用范围广以及可研究历史依赖的优点,广泛应用于材料迟滞建模的研究,但同时该模型中通常存在多个参数以及双重积分的计算,这就导致其模型和计算复杂性升高,在线实现困难,控制器设计困难,PI 模型^[7]通常用于在结构工程、材料科学以及控制工程中描述非线性弹性行为,它采用一组非线性算子

来模拟系统的非线性特性,但同样存在调参困难、对高度非线性或动态系统适用性不高等缺点,模型的在线可调整程度不高;Bouc-Wen 模型^[8]可以描述多种材料特性中的非线性滞回现象,同时具有良好的调节能力以及捕捉材料的历史依赖性的优点,但是其在参数的复杂性以及过拟合方面存在诸多问题;Maxwell 模型^[9]主要用于描述粘弹性材料的弹性行为,可以通过给出相应的表达式进行迟滞建模,虽然便于理解,但其本身是一个线性模型,对高应变和非线性材料的预测能力有限同时参数估计困难,需要复杂的实验和数据处理,不利于推广。上述方法多为率无关模型,通过对这些传统静态迟滞模型进行改进也可得到描述率相关的模型,但步骤较为繁琐。

为了考虑率相关问题,将系统的静态迟滞特性和率相关性由不同的部分表达,这类模型包括: Hammerstein 模型、三明治模型、Wiener 模型等。近年来,利用 Hammerstein 结构^[10]建立的动态迟滞模型广受学者们的关注,其由迟滞静态非线性和迟滞动态线性两部分构成。范家华等^[11]通过叠加一系列 Play 算子和使用自回归历遍(ARX)构建模型。Na 等^[12]利用 Preisach 算子来描述迟滞非线性部分,通过 Hankel 矩阵和盲目辨识方法确定线性传递函数。贾高欣等^[13]则利用广义 Bouc-Wen 模型加自回归历遍(ARX)构建模型。

上述方法通过对现有模型及算子进行调参或叠加针对压电陶瓷驱动器的迟滞特性进行建模,且都有较好的表现,但是通过上述方法建立的

Hammerstein 模型只能描述一些轻微的非线性过程,对于更加复杂严重的非线性过程,其精度和泛用性将会有所下降。

本文针对更加复杂的超磁致伸缩材料的迟滞特性建模问题,提出一种新 Hammerstein 模型建模方法,首先通过迟滞算子扩展输入空间,使神经网络可以更好地逼近迟滞特性,提供更高的精度,为之后构建动态线性部分提供良好的基础,之后通过提取训练好的神经网络全连接层的权重及偏置参数,构建动态线性部分,减少了模型参数辨识的工作。最后进行模型建模仿真,结果表明本方法模型简单、精度较高,更适用于复杂的迟滞特性建模。

1 Hammerstein 模型

Hammerstein 模型是一类具有特定结构的典型非线性模型,其由静态非线性环节 $N(\cdot)$ 和动态线性环节 $L(\cdot)$ 串联而成,其基本结构如图 1 所示。这种结构可以将非线性控制问题简化为线性模型的预测控制问题。




图 1 Hammerstein 模型结构

Fig. 1 Hammerstein model structure

图 1 中, x 、 y 、 v 以及 β 分别为系统的输入、输出、中间不可测变量以及输出端扰动。

静态非线性部分表示为

$$V(t) = N(X(t)), \quad (1)$$

式中: $X(t)$ 表示输入变量; $V(t)$ 表示静态非线性部分的输出; $N(\cdot)$ 表示非线性环节。

动态线性部分可表示为

$$Y(t) = L(H(v(t))), \quad (2)$$

式中: $v(t)$ 表示中间不可测变量,作为动态线性环节的输入; $Y(t)$ 表示输出信号; $H(\cdot)$ 表示滤波器,是动态环节的一部分; $L(\cdot)$ 表示整个动态环节。

整体模型的输出可表示为

$$Y(t) = L(H(V(t))) + N(X(t)) + \beta(t), \quad (3)$$

式中: $\beta(t)$ 表示输出端扰动。

针对这种串联结构 Hammerstein 模型的研究工作主要集中在以下两个方面:

1) 静态非线性环节的建模方法研究,研究的重

点在于提高精度以及泛用性。具体可以分为三类:① 使用基函数(如 Sigmoid 函数等)的线性组合,缺点是参数多、阶数高;② 采用非参数的形式,即多项式形式^[14],但是不适合于分段非线性问题;③ 采用模糊系统、神经网络等非线性模型^[15]建立非线性环节,存在非线性参数化复杂的问题。

2) Hammerstein 模型中串联环节带来的新问题,以及由于中间变量 v 无法测量造成的静态非线性环节 $N(\cdot)$ 和动态线性环节 $L(\cdot)$ 组合的辨识难度提高的问题。研究重点在于模型参数求解的问题。主要有两种解决方法:① 采用迭代法、随机法、频域法及盲辨识法等方法去辨识串联参数;② 使用组合信号、改进辨识算法^[16-17]等方法进行静态非线性环节和动态线性环节的参数的辨识。

针对上述两个问题进行 Hammerstein 模型的改进。1) 针对静态非线性环节的建模,采用神经网络建模的方法逼近迟滞非线性,针对存在的难于参数化的问题,通过构建迟滞算子扩展迟滞输入的空间,可以使神经网络具有更强的参数化能力,更灵活地进行非线性建模,从而成功降低参数化的难度。2) 针对串联环节辨识难度高的问题,本文提出将训练好的全连接层权重作为动态线性环节的参数,这种做法相当于利用神经网络学习到的非线性映射来近似系统的线性动态行为,具有更好的非线性拟合能力以及自适应性,同时减少了参数辨识的工作。

2 静态非线性环节

2.1 迟滞算子的构建

本文所研究的 GMM 的磁滞回线是不对称的,如图 2 所示,层层叠加的迟滞环造成了一个输入对应多个输出的问题,其中也存在多个上升支路以及下降支路。

迟滞算子的表达式如式(4)所示,是一种基于双曲函数的自构建迟滞算子。函数 f_1 和 f_2 是构建迟滞算子的两个基本方程,在这个算子中,所有的上升分支都是由 f_1 通过相应的转换来确定的,因此,函数 f_1 也被称为“一般升序函数”。

$$\begin{cases} f_1(x) = a_1 \left(1 - \sqrt{1 + \frac{x^2}{b_1^2}} \right) + c_1 x + d_1, \\ f_2(x) = a_2 \left(1 - \sqrt{1 + \frac{x^2}{b_2^2}} \right) + c_2 x + d_2. \end{cases} \quad (4)$$




图 2 超磁致伸缩材料的迟滞曲线

Fig. 2 Hysteresis curve of giant magnetostrictive materials

相应地, 函数 g_2 表达式为

$$g_2(x) = -f_2(-x) = -a_2 \left(1 - \sqrt{1 + \frac{x^2}{b_2^2}} \right) + c_2 x + d_2 \quad (5)$$

称为“一般降序函数”, 它是基本方程 f_2 围绕原点的对称函数, 相应的所有的下降分支都是由 g_2 通过相应的转换来确定的。

函数 f_1 和 f_2 的几何分析如图 3 所示, 函数 f_1 和 f_2 是直线方程和双曲线方程的和。直线斜率为 c (分别为 c_1 和 c_2), 其中参数 d (分别为 d_1 和 d_2) 用以调节曲线的位置, 双曲线方程由经典的参数 a 和 b (分别为 a_1, b_1 以及 a_2, b_2) 定义, 如图 3 所示(函数曲线加渐近线)。其中, 参数值可使用各类型拟合工具来确定, 也可以用渐近线的斜率和它们在 y 轴上的交叉点来计算。

本文在 Python 环境下搭建了迟滞算子, 对迟滞算子中主环的各个参数进行辨识, 其中各个参数的详细数据见表 1。

表 1 迟滞算子主环参数

Tab. 1 Main loop parameters of hysteresis operators

参数	上升曲线值	下降曲线值
a	2.749 7	1.226 0
b	1.100 6	0.420 2
c	1.962 1	2.939 0
d	0	0.049 2

首先用主环数据拟合出迟滞数据的主环曲线。如图 4 所示, $x-H(x)$ 坐标轴对应的是迟滞主环曲线, $x-F(x)$ 坐标轴对应的是所构建的迟滞算子主环曲线。

其次对主环进行平移得到次环。假设任何上升分支是与函数 f_1 相关的一般上升分支的特定平移, 任何下降分支是与函数 g_2 相关的一般反转分

支的特定平移。




图 3 迟滞算子函数的几何分析

Fig. 3 Geometric analysis of hysteresis operator functions




图 4 迟滞曲线与迟滞算子的主环空间对应

Fig. 4 The correspondence between hysteresis curves and the main loop space of hysteresis operators

平移曲线由式(6)给出, 其中 (x_c, V_c) 为平移向量的坐标。变量 x_c 和 V_c 可通过求解(7)的集合来确定。

$$V = f_1(x - x_c) + V_c, \quad (6)$$

$$\begin{cases} V_m = f_1(x_m - x_c) + V_c, \\ V_M = f_1(x_M - x_c) + V_c. \end{cases} \quad (7)$$

由式(6)和式(7)得到平移曲线的方程(8), 其中的所存在的未知参数只有 x_c , 可以通过求解

式(9)的值来确定未知数 x_w 。

$$V = f_1(x - x_c) - f_1(x_M - x_c) + V_M, \quad (8)$$

$$f_1(x_M - x_c) - f_1(x_m - x_c) = V_M - V_m. \quad (9)$$

同理, 反转支路与上升支路过程相同, 平移曲线可通过求解式(10), 式(11)的集合来确定。

$$V = g_2(x - x_c) - g_2(x_m - x_c) + V_m, \quad (10)$$

$$g_2(x_M - x_c) - g_2(x_m - x_c) = V_M - V_m. \quad (11)$$

次环偏移结果如图5所示。




图5 主环及次环偏移图

Fig. 5 Main and secondary ring offset diagram

最后通过偏移量得到整个迟滞环的数据集, 构成新的输入量, 并将其作为一个特征输入到之后构建的神经网络中。

2.2 基于迟滞算子的极限学习机神经网络

极限学习机(Extreme Learning Machine, ELM)是为了解决基于梯度类的学习算法在单隐层前馈神经网络中存在的训练速度慢、泛化性能差等缺点而提出的新方法^[18]。ELM模型的结构^[19]如图6所示, 其中包含 m 个神经元的输入层、 n 个神经元的隐含层、 p 个神经元的输出层。在训练过程中随机产生输入层和隐含层的连接权值以及隐含层的阈值, 可通过设定隐含层的神经元个数求得最优解。




图6 极限学习机神经网络结构

Fig. 6 Neural network structure of extreme learning machine

对于回归问题, 给定训练样本输入为 $X_i = [x_1, x_2, \dots, x_n]^T$, 训练样本输出为 $Y_i = [y_1, y_2, \dots, y_m]^T$, 则其隐含层的输出函数的表达式为

$$p_i = \sum_{i=1}^l \beta_i h(\omega_i \cdot x_i + b_i), \quad i = 1, 2, \dots, N, \quad (12)$$

式中: x_i 为第 i 个训练样本; p_i 为 x_i 经过ELM模型处理之后得到的输出; β_i 为第 i 个隐层神经元的输出权重; $\sigma(x)$ 为隐含层的激活函数; ω_i 为第 i 个隐层神经元的输入权重; b_i 为第 i 个隐层神经元的偏置。式(12)的矩阵形式为

$$\beta H = T, \quad (13)$$

式中: H 为隐含层输出矩阵, 维度为 $N \times l$; β 为隐含层输出权重矩阵, 维度为 $l \times m$; T 为目标输出矩阵, 维度为 $N \times m$, 其中权重 ω 和偏置 b 是随机生成的。

$$H = \begin{bmatrix} h(\omega_1 \cdot x_1 + b_1) & \cdots & h(\omega_l \cdot x_1 + b_l) \\ \vdots & \ddots & \vdots \\ h(\omega_1 \cdot x_N + b_1) & \cdots & h(\omega_l \cdot x_N + b_l) \end{bmatrix}, \quad (14)$$

$$\beta = \begin{bmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1m} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ \beta_{n1} & \beta_{n2} & \cdots & \beta_{nm} \end{bmatrix}, \quad (15)$$

$$T = \begin{bmatrix} t_{11} & t_{12} & \cdots & t_{1m} \\ t_{21} & t_{22} & \cdots & t_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ t_{N1} & t_{N2} & \cdots & t_{Nm} \end{bmatrix}. \quad (16)$$

通过变换, 其最小二乘解为

$$\hat{\xi} = H^+ T, \quad (17)$$

式中: H^+ 为矩阵 H 的Moore Penrose广义逆矩阵, 它的解的范数是最小且唯一的。

通过引入迟滞算子构建新的神经网络模型, 如图7所示。




图7 迟滞输入与输出关系

Fig. 7 Input and output relationship of hysteresis

考虑神经网络中存在的擦除特性。擦除特性是指神经网络中的一种机制, 它允许神经元“擦除”或清除先前存储的信息, 以便在新的输入数据到达时更新或覆盖这些信息, 在本文中指更新存储的局部极大值或局部极小值, 更新之后历史极值相应的加

载历史也被擦除,不再影响之后的输出。

式(18),式(19)分别代表电压和位移,其大小关系由式(20)给出。

$$x_M^n, x_m^n, x_M^{n-1}, x_m^{n-1}, x_M^{n-2}, x_m^{n-2}, \dots, x_M^1, x_m^1, \quad (18)$$

$$V_M^n, V_m^n, V_M^{n-1}, V_m^{n-1}, V_M^{n-2}, \dots, V_M^1, V_m^1, \quad (19)$$

$$\begin{cases} x_m^n > x_m^{n-1} > x_m^{n-2} > \dots > x_m^1, \\ x_M^n < x_M^{n-1} < x_M^{n-2} < \dots < x_M^1. \end{cases} \quad (20)$$

迟滞算子中同样存在类“擦除特性”,对于某一个次环,上升曲线由当前主导极小值点(x_m^{n-1}, V_m^{n-1})开始,最后经过当前次环主导极大值点(x_M^{n-1}, V_M^{n-1})。这段次环曲线所对应的起始点为($x_m^{n-1}, f_2(x_m^{n-1})$),终止点为($x_M^{n-1}, f_2(x_M^{n-1})$)。

同理,某一段次环的下降曲线由当前主导极大值点(x_M^{n-1}, V_M^{n-1})开始,最后经过当前次环主导极小值点(x_m^{n-1}, V_m^{n-1})。这段次环曲线所对应的起始点为($x_M^{n-1}, f_2(x_M^{n-1})$),终止点为($x_m^{n-1}, f_2(x_m^{n-1})$)。

擦除特性是在由主环主导极大值开始下降时达到次环主导极小值,此时,之前保存的主环主导极小值会被擦除掉,新的次环主导极小值会被保存下来。在次环经过次环主导极小值之后开始上升直至达到次环主导极大值,此时主环主导极大值会被消除掉,相应的次环主导极大值被保留下来,以此往复更新所需主导极值。

在构建的神经网络的动态方程中同时考虑擦除特性和迟滞算子的耦合,将网络的激活状态与迟滞算子的状态进行关联。这使得神经网络的激活状态不仅受到当前输入的影响,还受到先前状态的擦除和迟滞效应的影响。这样的设计能够更好地捕捉系统的历史依赖性和非线性响应。

将通过这种方式构建的神经网络模型作为 Hammerstein 模型的静态非线性部分。

3 动态线性环节

Hammerstein 模型常用的动态线性环节包括传递函数模型、自回归模型(AR)、自回归遍历模型(ARX)等。

动态线性环节的数学表达式为

$$L(t+1) = AL(t) + Bv(t). \quad (21)$$

线性环节的输出数学表达式为

$$y(t) = Cv(t), \quad (22)$$

式中: $v(t)$ 为动态线性环节的输入; $L(t)$ 为状态空间变量的矩阵; $y(t)$ 为动态线性环节的输出; A 为状态空间的参数矩阵; B 和 C 为状态空间的参数向量。

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{bmatrix}, \quad (23)$$

$$B = [B_1, B_2, \dots, B_m]^T, \quad (24)$$

$$C = [c_1, c_2, \dots, c_m]. \quad (25)$$

神经网络中全连接层的表达式为

$$y(t) = Wu(t) + b, \quad (26)$$

式中: $u(t)$ 为神经网络内部的输入; $y(t)$ 为全连接层的输出; W 为权重矩阵; b 为偏置向量。

$$W = \begin{bmatrix} \omega_{11} & \omega_{12} & \dots & \omega_{1m} \\ \omega_{21} & \omega_{22} & \dots & \omega_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ \omega_{n1} & \omega_{n2} & \dots & \omega_{nm} \end{bmatrix}, \quad (27)$$

$$b = [b_1, b_2, \dots, b_m]^T. \quad (28)$$

由上述的公式可以看出,神经网络全连接层的权重矩阵 W 与动态线性环节中的状态空间的参数矩阵 A 具有高度的相似性,且都是输入和输出之间关系的权重参数。同时,全连接层的偏置向量 b 和状态空间的参数向量 B 同样用于影响系统状态的变化。全连接层主要用于神经网络,通过非线性激活函数引入非线性变换。

因此,全连接层中的权重矩阵 W 和偏置向量 b 更加灵活,允许网络学习复杂的非线性映射。将神经网络中的全连接层参数作为动态线性系统的一部分,从而发挥神经网络在捕捉复杂非线性关系方面的优势。具体流程如图 8 所示。




图 8 权重偏置参数提取流程图

Fig. 8 Flow chart of weight bias parameter extraction

此时,状态空间的参数矩阵 A 的维度与权重矩阵 W 维度一致,为 $n \times m$,同时全连接层的偏置

向量 \mathbf{b} 和状态空间的参数向量 \mathbf{B} 维度一样, 为 $1 \times n$, 只需要对传递参数进行微调更新即可满足动态、静态环节的连接。

使用迁移学习中常用的技巧: 微调(Fine-tuning)进行上述操作, 使用 TrAdaboost 算法将神

经网络的全连接层参数冻结保存提取, 并用于构建新的动态线性环节的状态空间方程, 使用随机梯度下降法进行参数更新, 此过程中, 随机选择四组权重及偏置在动态线性环节的参数更新进行验证, 结果如图 9 所示。

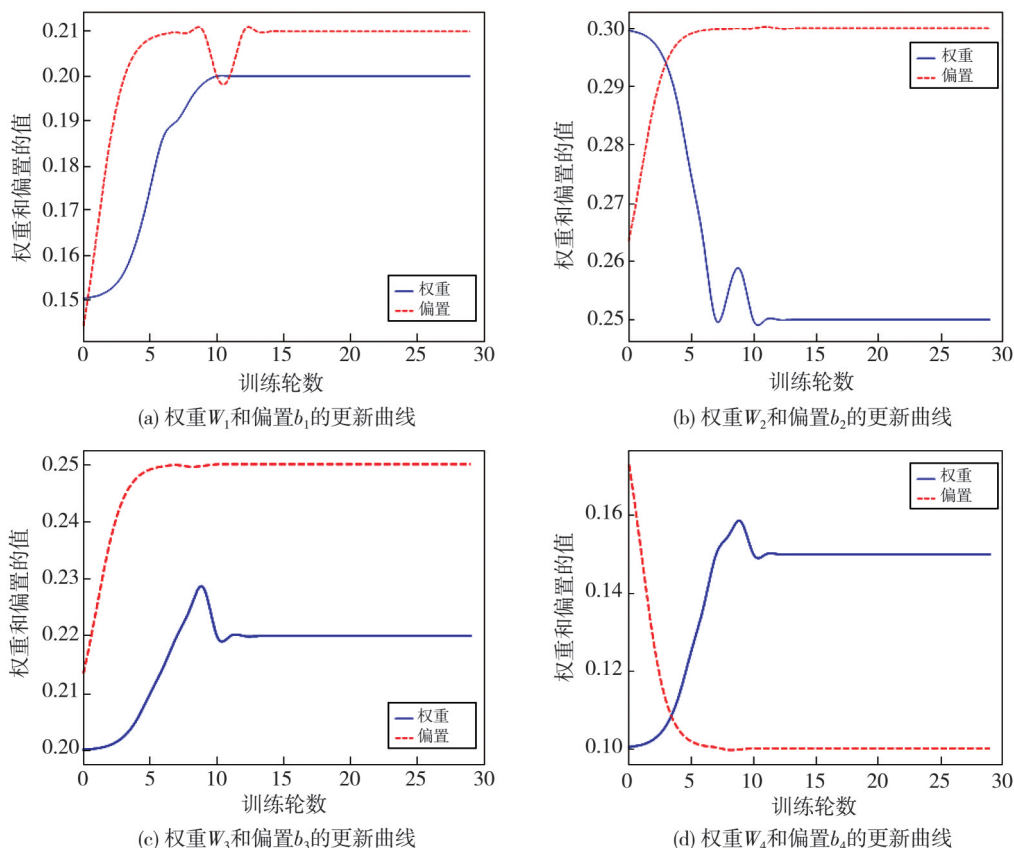


图9 动态线性环节参数更新

Fig. 9 Parameter update of dynamic linear link

由图 9 可知, 将权重矩阵以及偏置向量用于构造动态线性环节并进行参数微调更新之后是稳定且收敛的。

通过这样的方式构造的动态线性环节与全连接层的输出结果的维度一致, 从而使得在整个 Hammerstein 模型中各部分的维度能够协调一致, 同时因为权重偏置维度相同, 减少了所需的辨识工作量, 只需要在动态线性环节构造完成之后进行相应的参数微调即可达到良好的效果。

4 新 Hammerstein 模型仿真

采用一组 GMM 实验数据来验证新 Hammerstein 模型的有效性, GMM 作动器实验数据采集平台如图 10 所示, 实验流程图如图 11 所示, 选择 70% 的数据作为训练集, 余下的 30% 作为测试集, 其中, ELM 模型的搭建是基于 Pytorch 框架来对电压和位

移进行非线性拟合, 需要对神经网络的激活函数、节点数等进行参数寻优, 以达到最小误差。




图10 超磁致伸缩致动器实验平台

Fig. 10 Experimental platform for giant magnetostrictive actuators

使用贝叶斯优化对节点数进行寻优, 结果如图 12 所示。

ELM 模型结构为 3 层, 2 个输入神经元, 198 个隐层神经元和 1 个输出神经元。在标准归一

化处理数据之后,基于ELM模型的基本特性,从节点数上进行随机选取,同时对隐含层每个节点的激活函数也进行随机化处理,隐含层激活函数的选择列表有 Sigmoid 函数、ReLU 函数、Tanh 函数以及 Linear 函数,随机选取以上 4 个不同的激活函数以达到更优的结果。




图 11 GMM 实验数据平台搭建流程图

Fig. 11 Process diagram for building GMM experimental data platform




图 12 贝叶斯优化节点数寻优结果

Fig. 12 Optimization results of Bayesian optimization node count

本文采用迟滞算子和 ELM 模型表示模型中的静态非线性部分,使用神经网络全连接层的权重矩阵 W 和偏置 b 作为动态线性环节中的状态空间的参数矩阵 A 和参数向量 B 构建动态线性环节,其结构如图 13 所示。




图 13 新 Hammerstein 模型结构

Fig. 13 New Hammerstein model structure

新 Hammerstein 模型对比传统 Hammerstein 的优势在于神经网络的全连接层已经学习到了输入数据的高级表示,因此不仅可以提供有效的线性动态建模,同时也能确保提取的全连接层的输入和输出尺寸与 Hammerstein 模型的期望输入和输出尺寸匹配。

通过使用迟滞算子和极限学习机神经网络构成的新 Hammerstein 模型预测的结果如图 14 和图 15

所示,模型的相对误差为 0.86%~3.69%。




图 14 新 Hammerstein 模型预测结果分布

Fig. 14 Distribution of predicted results from the new Hammerstein model




图 15 新 Hammerstein 模型实际值与预测值的对比

Fig. 15 Comparison of actual and predicted values of the new Hammerstein model

将本文所提模型与传统的 Hammerstein 模型进行对比,传统 Hammerstein 模型由 Sigmoid 函数组成其非线性静态部分,AR 模型(自回归模型)作为其线性动态部分。传统 Hammerstein 模型的预测结果如图 16 和图 17 所示,模型的相对误差为 3.98%~7.91%。

本文采用均方根误差 (RMSE)、相对误差 (RE)、判定系数 R^2 以及平均绝对误差 (MAPE) 作为评价模型的指标。

模型效果如表 2 所示,由仿真结果可知,新 Hammerstein 模型比传统的 Hammerstein 模型的均方根误差低 0.8 μm 左右,平均绝对误差提高将近 4%,证明新模型在准确性、可靠性、拟合度和精度方面均优于旧模型,新 Hammerstein 模型在捕捉复杂迟滞非线性系统动态特性方面具有更大的优越性,可以为复杂迟滞非线性系统建模和预测任务提供更可靠的方法。




图 16 传统 Hammerstein 模型预测结果分布

Fig. 16 Distribution of predicted results from the traditional Hammerstein model




图 17 传统 Hammerstein 模型实际值与预测值的对比

Fig. 17 Comparison of actual and predicted values of traditional Hammerstein models

表 2 新旧 Hammerstein 模型性能对比

Tab. 2 Comparison of performance between new and old Hammerstein models

指标	新 Hammerstein 模型值	传统 Hammerstein 模型值
RMSE/ μm	0.092	0.872
RE/%	0.86~3.69	3.98~7.91
R^2	0.987	0.912
MAPE/%	2.63	6.22

5 结 论

为了解决 GMM(超磁致伸缩材料)复杂迟滞非线性建模的问题,本文提出一种新 Hammerstein 模型建模方法,使用基于迟滞算子扩展空间的 ELM 模型作为 Hammerstein 模型中的静态非线性部分,同时提取已经训练好的 ELM 模型全连接层中的权重及偏置作为模型动态线性部分的状态空间参数,代替常规的 AR 模型、ARX 模型等,在减少模型辨识工作的同时使新 Hammerstein 模型具备更高的非线性适应性,本文模型在非线性动态

建模中具备更高的精度,与传统的 Hammerstein 模型进行对比,仿真结果证明了新 Hammerstein 模型在针对超磁致伸缩材料复杂迟滞非线性建模上更加有效。

参考文献:

[1] 贺兴辉,王子维,陈冰倩. 压电陶瓷材料的应用与发展分析[J]. 居业,2018, 10(5): 1.
HE Xinghui, WANG Ziwei, CHEN Bingqian. Analysis of the application and development of piezoelectric ceramic materials[J]. Create Living, 2018, 10(5): 1. (in Chinese)

[2] 成玫,邱冶,刘旭辉,等. 超磁致伸缩驱动器及其微位移特性研究[J]. 机床与液压, 2020, 48(8): 78-80.
CHENG Mei, QIU Ye, LIU Xuhui, et al. Research on giant magnetostrictive drive and its micro displacement characteristics[J]. Machine Tool & Hydraulics, 2020, 48(8): 78-80. (in Chinese)

[3] KIM B, WASHINGTON G N, YOON H S. Hysteresis-reduced dynamic displacement control of piezoceramic stack actuators using model predictive sliding mode control[J]. Smart Materials and Structures, 2012, 21(5): 055018.

[4] 潘雨. 超磁致伸缩驱动器的建模[D]. 泉州: 华侨大学, 2020.

[5] 刘玠,安坤,王亚锋,等. 基于神经网络的 Preisach 磁滞模型的建模[J]. 组合机床与自动化加工技术, 2022(3): 5-8.
LIU Jie, AN Kun, WANG Yafeng, et al. Modeling of preisach hysteresis model based on neural networks [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(3): 5-8. (in Chinese)

[6] 潘明健,安坤,李健宏,等. 基于 CMAC 神经网络的超磁致伸缩非线性控制[J]. 电子测量技术, 2023, 46(9): 182-188.
PAN Mingjian, AN Kun, LI Jianhong, et al. Nonlinear control of giant magnetostriction based on CMAC neural network[J]. Electronic Measurement Technology, 2023, 46(9): 182-188. (in Chinese)

[7] Mielke A. Generalized Prandtl-Ishlinskii operators arising from homogenization and dimension reduction [J]. Physica B: Condensed Matter, 2012, 407(9): 1330-1335.

[8] ZHU W, RUI X T. Hysteresis modeling and displacement control of piezoelectric actuators with the frequency-dependent behavior using a generalized Bouc-Wen model [J]. Precision Engineering, 2016,

- 43: 299-307.
- [9] JI J A, ZHAO Z G, ZHANG S, et al. Hysteresis Characteristics prediction method of nanocrystalline materials under high-frequency excitation based on Maxwell's equation and R-L fractional derivative [J/OL]. Proceedings of the CSEE, (2023-08-07)[2024-01-08] <https://doi.org/10.13334/j.0258-8013.pcsee.230524>.
- [10] 贾立, 李训龙. Hammerstein 模型辨识的回顾及展望 [J]. 控制理论与应用, 2014, 31(1): 1-10.
JIA Li, LI Xunlong. Review and outlook on hammerstein model identification[J]. Control Theory & Applications, 2014, 31(1): 1-10. (in Chinese)
- [11] 范家华, 马磊, 周攀, 等. 基于径向基神经网络的压电作动器建模与控制[J]. 控制理论与应用, 2016, 33(7): 856-862.
FAN Jiahua, MA Lei, ZHOU Pan, et al. Modeling and control of piezoelectric actuators based on radial basis function neural network [J]. Control Theory & Applications, 2016, 33(7): 856-862. (in Chinese)
- [12] NA J, CHEN Q, REN X. Adaptive identification and control of uncertain systems with non-smooth dynamics [M]. Pittsburgh: Academic Press, 2018.
- [13] 贾高欣, 王贞艳. 压电陶瓷作动器的率相关迟滞建模与内模控制[J]. 压电与声光, 2019, 41(1): 130-134.
JIA Gaoxin, WANG Zhenyan. Rate dependent hysteresis modeling and internal model control of piezoelectric ceramic actuators [J]. Piezoelectrics & Acousto-optics, 2019, 41(1): 130-134. (in Chinese)
- [14] 宋伟, 韩佳虎, 李峰, 等. 有色噪声干扰下 Hammerstein 非线性模型辨识[J]. 陕西科技大学学报, 2023, 41(5): 189-194.
SONG Wei, HAN Jiahu, LI Feng, et al. Identification of Hammerstein nonlinear model under colored noise interference [J]. Journal of Shaanxi University of Science and Technology, 2023, 41(5): 189-194. (in Chinese)
- [15] HE H R, NA J, WU J D, et al. Fixed-time adaptive parameter estimation for hammerstein systems subject to dead-zone [J]. IEEE Transactions on Industrial Electronics, 2023, 71(4): 3862-3872.
- [16] PAPANITRIOU C, VARELMANN T, SCHRÖDER C, et al. Globally optimal scheduling of an electrochemical process via data-driven dynamic modeling and wavelet-based adaptive grid refinement [J]. Optimization and Engineering, 2023: 1-39.
- [17] LÜ L, SUN W, PAN J. Two-stage and three-stage recursive gradient identification of Hammerstein nonlinear systems based on the key term separation [J]. International Journal of Robust and Nonlinear Control, 2024, 34(2): 829-848.
- [18] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [19] 王彦, 朱伟, 汪俊亮, 等. 基于 ELM 算法的柔性 FBG 形状重构末端分析 [J]. 仪器仪表学报, 2023, 44(5): 81-89.
WANG Yan, ZHU Wei, WANG Junliang, et al. End analysis of flexible FBG shape reconstruction based on ELM algorithm [J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 81-89. (in Chinese)