

文章编号 1004-924X(2019)03-0694-08

工业机器人谐波减速器迟滞特性的神经网络建模

党选举^{1,2*}, 王凯利¹, 姜 辉¹, 伍锡如¹, 张向文¹

(1. 桂林电子科技大学 电子工程与自动化学院, 广西 桂林 541004;

2. 电子电路国家级实验教学示范中心 桂林电子科技大学, 广西 桂林 541004)

摘要:谐波减速器中柔性环节与传动的非线性摩擦, 导致谐波传动出现了不可避免地影响传动精度的复杂迟滞特性, 为了描述谐波减速器的迟滞特性, 本文构建了一个结构简洁的神经网络迟滞混合模型。该模型由类迟滞特性预处理环节和动态 RBF 神经网络两部分组成; 对输入信号进行类迟滞预处理, 处理后的信号与输入信号之间具有类迟滞特性; 充分利用动态 RBF 神经网络实现类迟滞到谐波减速器迟滞特性的高精度映射。根据本文搭建的实验平台, 在不同实验条件下获得的数据进行建模验证, 在不同频率输入信号、不同负载, 实现相同建模精度下, 神经网络迟滞混合模型的验证精度为 0.449 6(MSE), 远高于经典 RBF 神经网络模型的 3.032 1(MSE)精度, 证明了所构造的神经网络迟滞混合模型的有效性和适应性。

关键词:谐波减速器; 迟滞特性; 径向基函数神经网络; 混合模型; 摩擦

中图分类号:TH132.43 **文献标识码:**A **doi:**10.3788/OPE.20192703.0694

Neural network modeling of hysteresis for harmonic drive in industrial robots

DANG Xuan-ju^{1,2*}, WANG Kai-li¹, JIANG Hui¹, WU Xi-ru¹, ZHANG Xiang-wen¹

(1. School of Electronic Engineering and Automation,

Guilin University of Electronic Technology, Guilin 541004, China;

2. National Demonstration Center for Experimental electronic circuit

Education (Guilin University of Electronic Technology), Guilin 541004, China)

* Corresponding author, E-mail: xjd69@163.com

Abstract: Nonlinear friction caused by the flexible link and the transmission process in the harmonic drive leads to complex hysteresis characteristics of harmonic transmission that inevitably affect the transmission accuracy. To describe the hysteresis characteristics of the harmonic drive, a concise neural network hysteresis hybrid model, comprising hysteresis-like characteristic preconditioning in series with a dynamic neural network, was presented in this study. It was executed in two steps: the input signal was preprocessed to produce hysteresis-like behavior; the dynamic Radial Basis Function (RBF) neural network was fully utilized to achieve high-precision approximation of hysteresis-like to hysteresis characteristics of the harmonic drive. Moreover, an experimental platform was constructed in this

收稿日期:2018-07-03; **修订日期:**2018-09-13.

基金项目:国家自然科学基金资助项目(No. 61263013, No. 61603107); 广西自然科学基金资助项目(No. 2016GXNSFDA380001, No. 2015GXNSFAA139297)

study, and the data obtained under different experimental conditions were modeled and verified. Both at a constant input accuracy and the accuracy with different input signals and loads, the verification accuracy obtained by the neural network hysteresis hybrid model is 0.449 6 (Mean Square Error (MSE)), which is much higher than the 3.0321 (MSE) accuracy of the classical neural network model. This proves the effectiveness and adaptability of the proposed neural network hysteresis hybrid model.

Key words: harmonic drive; hysteresis; Radial Basis Function(RBF) neural networks; hybrid model; friction

1 引 言

谐波齿轮传动是随着空间技术的发展而产生的一种新型传动技术,目前被广泛应用于航空航天、仪器仪表和机器人领域^[1]。谐波减速器具有体积小,传动比大,运动精度高等优点,是工业机器人实现运动的核心部件。我国从 20 世纪 60 年代就开始谐波传动方面的研制工作,但由于加工制造水平的限制,到目前为止国内谐波齿轮的专业生产厂家仍然很少^[2]。针对现状,《中国制造 2025》中明确提出,要突破机器人本体和关键零部件及系统集成设计制造等技术瓶颈。因此作为机器人重要部件,谐波减速器关键技术的突破就显得更加迫切。

谐波减速器主要由波发生器、柔轮和刚轮三个基本零部件构成,通过柔轮的弹性变形实现运动的传递。柔轮的变形、传动中的非线性摩擦、各零部件的制造和安装误差,导致了谐波减速器出现迟滞现象^[3],反映了输出力矩与输入输出轴之间夹角的迟滞特性^[4]。在工业机器人往复运动的过程中,迟滞特性是影响其重复性精度的重要因素^[5]。

国内外对于谐波减速器的研究主要集中在谐波齿轮的设计、制造、材料等方面^[6-7],对其迟滞特性建模的研究相对较少。文献^[8]根据薄壳弹性变形理论,着重对谐波传动的回差、刚度误差和传动误差进行了研究,给出了谐波减速器传动误差公式,此类建模方法较复杂,辨识参数较多,无法预估实际运行中的干扰;文献^[3]基于谐波减速器的工作原理、运动学和动力学特性,建立了整个谐波传动系统的动力学模型和 simulink 仿真模型,但所提出的模型为静态模型且假设迟滞模型与速率无关,在实际应用中可操作性不强;文献^[9-10]采用 Preisach 模型对谐波减速器迟滞现象进行建

模,由于 Preisach 模型计算过程复杂,该模型很难应用于实际的在线补偿控制。

受到文献^[11-13]的启发,本文从信息建模的角度,考虑工业机器人谐波减速器往复运动中的整体迟滞特性,构建一个神经网络迟滞混合模型,为其高精度补偿提供基础。其建模过程包括:(1)对输入信号进行简单的类迟滞预处理,使处理后的信号与输入信号之间具有与谐波减速器迟滞特性曲线类似的特性;(2)利用动态 RBF(Radial Basis Function)神经网络实现类迟滞模型到谐波减速器迟滞特性的映射,补偿两者幅值和相位上的差异,使其能对谐波减速器的迟滞特性进行精确建模。

2 神经网络迟滞混合模型

2.1 谐波减速器迟滞特性

谐波减速器中柔性环节与传动的非线性摩擦,导致谐波传动存在迟滞现象。根据本文搭建的实验平台获得的实验数据,对应得到谐波减速器输出力矩与扭转角的迟滞特性曲线,如图 1 所示。




图 1 谐波减速器迟滞特性曲线

Fig. 1 Hysteresis characteristic curve of harmonic drive

迟滞是一种特殊的非线性特性,表现为多值

对应和记忆特性。实验测得谐波减速器同样具有这两种特性:(1)输入信号 $F(t_a) = F(t_b)$ 时,对应的输出 $\Delta\theta(t_a) \neq \Delta\theta(t_b)$; (2)减速器迟滞的输出不仅和当前的输入值相关,而且和历史输入值相关^[13]。由于迟滞的这两种特性,使得传统神经网络难以实现其高精度建模。

2.2 神经网络迟滞混合模型的构建

针对迟滞的复杂非线性特性,构造的神经网络迟滞混合模型如图 2 所示。




图 2 神经网络迟滞混合模型

Fig. 2 Neural network hysteresis hybrid model

模型对输入信号进行类迟滞预处理后与动态 RBF 神经网络串联,对谐波减速器的复杂迟滞特性进行建模。

本文提出的神经网络迟滞混合模型表示如下:

$$\Delta\theta_m(t) = f(F(t), P(t), \Delta\theta(t-1))$$

通过对实验数据的分析观察,发现在输入输出信号归一化下,预处理后的输出信号 $P(t) = F(t) - \Delta\theta(t-1)$ 与输入信号 $F(t)$ 之间具有与谐波减速器迟滞几何类似的特性,可以描述其基本特点;

文中采用 $y = \text{map}_{\min\max}(x, ps)$ 将数据归一到 $[-1, 1]$, 其中函数 $\text{map}_{\min\max}$ 的表达式为:

$$y = (y_{\max} - y_{\min}) \cdot \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min}. \quad (1)$$

归一化后 $F(t)$ 与 $P(t)$ 的类迟滞关系和 $F(t)$ 与 $\Delta\theta(t-1)$ 的迟滞关系对比如图 3 所示。

如图 3, $P(t)$ 是对输入信号进行处理的结果,可见图 3 中 $F(t)$ 与 $P(t)$ 具有和 $F(t)$ 与 $\Delta\theta(t-1)$ 相似的迟滞特性;后置的动态 RBF 神经网络可以实现类迟滞到谐波减速器迟滞特性的映射,补偿两者在幅值和相位上的差异,完成对谐波减速器迟滞特性的建模。

神经网络迟滞混合模型中采用的 RBF 神经网络是一种局部学习过程的三层前向神经网络,能以任意精度逼近任意连续函数,具有计算量少、学习算法简单、学习速度快等优点,动态 RBF 神经网络结构图如图 4 所示。




图 3 类迟滞与迟滞的对比

Fig. 3 Comparison of hysteresis-like and hysteresis




图 4 RBF 神经网络结构图

Fig. 4 Structure of RBF neural network

选择输出轴转矩 $F(t)$, 类迟滞预处理的输出 $P(t)$ 和谐波减速器扭转角的前一时刻输出 $\Delta\theta(t-1)$ 网络的输入向量,使神经网络具有动态特性。

动态 RBF 神经网络中,隐含层节点数 i 取 30, $\omega = [\omega_1, \omega_2, \dots, \omega_i]^T$ 为输出权值向量, $\varphi = [\varphi_1, \varphi_2, \dots, \varphi_i]^T$ 为径向基向量,其中 φ_i 为高斯基函数,神经网络的隐含层采用高斯基函数。

$$\varphi_i = \exp\left[-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{2\sigma_i^2}\right], \quad (2)$$

其中 \mathbf{c}_i 和 σ_i 分别为隐含层第 i 个神经元的中心坐标向量和宽度,神经网络的输入为:

$$\mathbf{x} = [F(t), P(t), \Delta\theta(t-1)]^T. \quad (3)$$

神经网络的输出:

$$\Delta\theta_m(t) = \omega^T \varphi. \quad (4)$$

网络逼近的误差指标为:

$$E(t) = \frac{1}{2} (\Delta\theta(t) - \Delta\theta_m(t))^2. \quad (5)$$

采用梯度下降法,网络权值按式(6)和式(7)调节^[14]:

$$\Delta\omega_i(t) = -\eta \frac{\partial E}{\partial \omega_i} = \eta(\Delta\theta(t) - \Delta\theta_m(t))\varphi_i, \quad (6)$$

$$\begin{aligned} \omega_i(t) &= \omega_i(t-1) + \Delta\omega_i(t) + \\ &\alpha(\omega_i(t-1) - \omega_i(t-2)), \end{aligned} \quad (7)$$

其中: η 是学习速率,取值为 1.1, α 是动量因子。

谐波减速器扭转角输出与输入信号的历史值有关,将迟滞对象前一时刻的输出 $\Delta\theta(t-1)$ 反馈到神经网络的输入端,使系统包含输入信号的历史信息,所构成动态神经网络迟滞混合模型的结构如图 5 所示。




图 5 动态神经网络迟滞混合模型结构图

Fig. 5 Structure of dynamic neural network hysteresis hybrid model

3 实验设备与方法

3.1 数据采集

目前国内外测试谐波减速器迟滞特性,常采用传统静态的逐渐加载的方法^[15]。固定谐波减速器的输出轴,采用双向力偶的形式通过砝码盘在其输出轴施加双向渐变力矩,并记录相对应的扭转角。实验中增减砝码的操作比较繁琐,并存在测试点不连续的缺点。

为了更精确、全面地描述迟滞特性曲线,本文搭建实时采集记录数据的测试平台进行动态测试,由电机、待测绿的谐波减速器、转矩转速传感器及磁粉制动器构成,如图 6 所示。

谐波传动的重复性误差主要是因长时间使用过程中的摩擦损耗造成的,通过神经网络间歇性学习来调整,神经网络的自学习能力会针对实际实验数据进行建模,有一定的适应能力,有效解决了重复性误差的影响。为了观察不同状态下的谐波减速器动态特性,设定不同频率正弦波作为输入信号,并在不同负载下,进行数据采集。该平台以 1 s 为间隔采集数据,通过上位机实现数据记录。




图 6 谐波减速器测试平台

Fig. 6 Test platform of harmonic drive

3.2 测试过程

伺服电机作为测试系统的动力来源带动谐波减速器,在系统运行过程中,通过在高速轴、低速轴上安装的传感器,实时记录减速器输入轴和输出轴的转速和转矩,负载末端连接角度传感器,可以得到低速轴的角位移,推算扭转角。扭转角 $\Delta\theta$ 是减速器输出轴理论转角与实际转角之差,其定义为:

$$\Delta\theta = \theta_{\text{out}} - \frac{\theta_{\text{in}}}{N}, \quad (8)$$

其中: θ_{in} 为输入轴转角, N 为减速器减速比, θ_{out} 为测得的输出轴实际转角。

3.3 谐波减速器迟滞特性的实验曲线

在输入不同频率的正弦信号,不同负载下,记录减速器的转矩转角。图 7 为输入信号为 10 mHz 正弦信号、负载电流 0.05 A,输入信号为 15 mHz 正弦信号、负载电流 0.05 A,输入信号为 10 mHz 正弦信号、负载电流 0.1 A 时减速器输出端转矩与扭转角分别表现出的迟滞特性




图 7 谐波减速器迟滞特性的实验曲线

Fig. 7 Experimental curve of hysteresis characteristic for harmonic drive

曲线。为了反映测试平台的真实工作状态,文中采用未经零点初值校验处理的实验数据。由图 7 可知,不同频率的输入信号得到的减速器迟滞环两端基本重合,负载不同时由于转矩变化较大,迟滞环形状也存在较大差异。

在不同输入信号、不同负载情况下采集的系列数据,用以验证所提出的谐波减速器神经网络迟滞混合模型的建模精度和适应性。

4 神经网络迟滞混合模型的建模与验证

为了验证所提出的神经网络迟滞混合模型对谐波减速器迟滞建模的有效性和适应能力,用神经网络迟滞混合模型和经典 RBF 神经网络模型进行对比验证。其中建模误差和验证误差为绝对误差 e ,表示为:

$$e = \Delta\theta - \Delta\theta_m, \quad (9)$$

其中: $\Delta\theta$ 为实际测量扭转角, $\Delta\theta_m$ 为模型计算出扭转角。

建模精度使用的评价指标为最大误差和均方差(MSE),均方差计算式为:

$$MSE = \sum_{t=1}^N (\Delta\theta(t) - \Delta\theta_m(t))^2 / N. \quad (10)$$

4.1 不同频率输入信号建模与验证

设定不同频率输入信号、相同负载,用神经网络迟滞混合模型和经典 RBF 神经网络模型分别进行建模和验证。

图 8(a)是输入信号频率为 10 mHz 时(取 200 组数据)用迟滞混合模型对迟滞环的建模结果,图 8(b)是输入信号频率为 15 mHz 时(取 200 组数据)对迟滞混合模型的验证结果,模型可以达到较好的建模和验证效果。图 8(c)、图 8(d)为神经网络迟滞混合模型建模和验证的误差,其中最大误差分别为 -0.830° 和 1.423° ,均方差分别为 0.077 8 和 0.113 2。

图 9 是与图 8 同样的输入和负载条件下,得到的 RBF 神经网络模型建模与验证结果。其中建模和验证最大误差分别为 0.847° 和 1.522° ,均方差为 0.075 3 和 0.177 6。

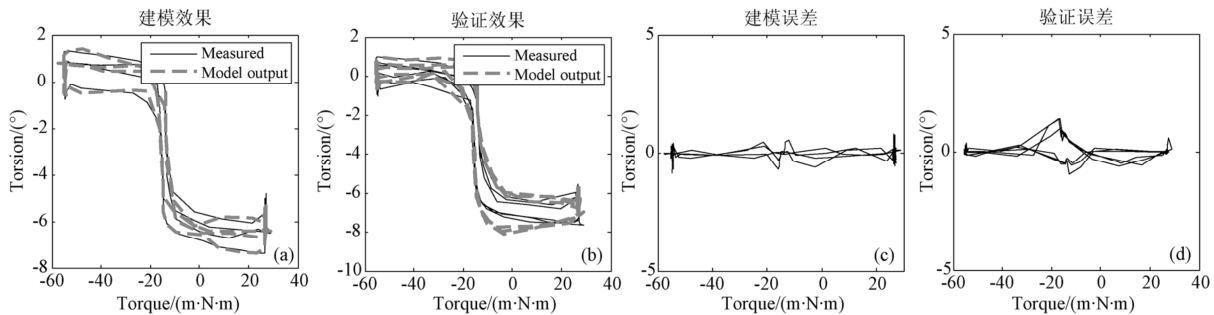


图 8 不同频率输入信号迟滞混合模型建模与验证

Fig. 8 Modeling and verification of hysteresis hybrid model with different frequency input signals

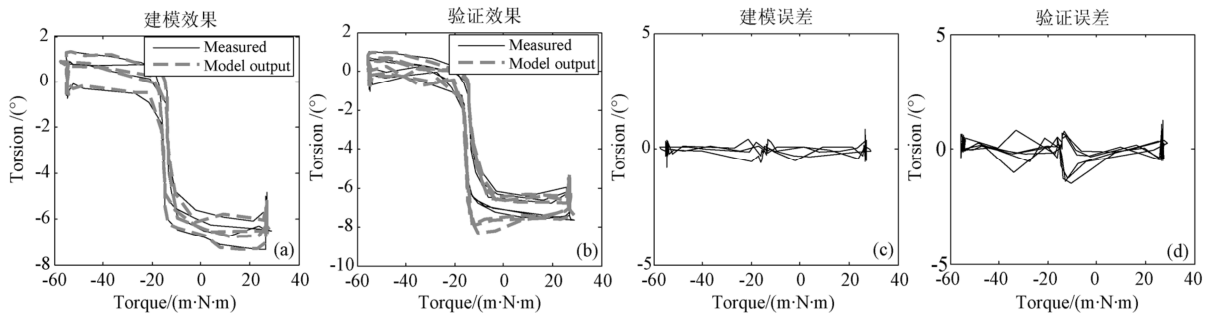


图 9 不同频率输入信号 RBF 神经网络模型建模与验证

Fig. 9 Modeling and verification of RBF Neural Network model with different frequency input signals

4.2 不同负载下建模和验证

设定相同频率输入信号、不同负载,用神经网络迟滞混合模型和经典 RBF 神经网络模型分别进行建模和验证。

图 10(a)是负载电流为 0.05 A 时(取 200 组数据)迟滞混合模型的建模结果,图 10(b)是负载电流为 0.1 A 时(取 200 组数据)对混合迟滞模型的验证结果,模型可以达到较好的建模和验证效

果。图 10(c)、图 10(d)为迟滞混合模型建模和验证的误差,其中最大误差分别为 -0.8396° 和 1.9693° ,均方差分别为 0.077 8 和 0.413 5。

与图 10 同样的输入和负载条件下,得到经典 RBF 神经网络模型建模与验证结果如图 11 所示。其中建模和验证最大误差分别为 -0.8577° 和 6.6273° ,均方差分别为 0.080 3 和 2.295 3。

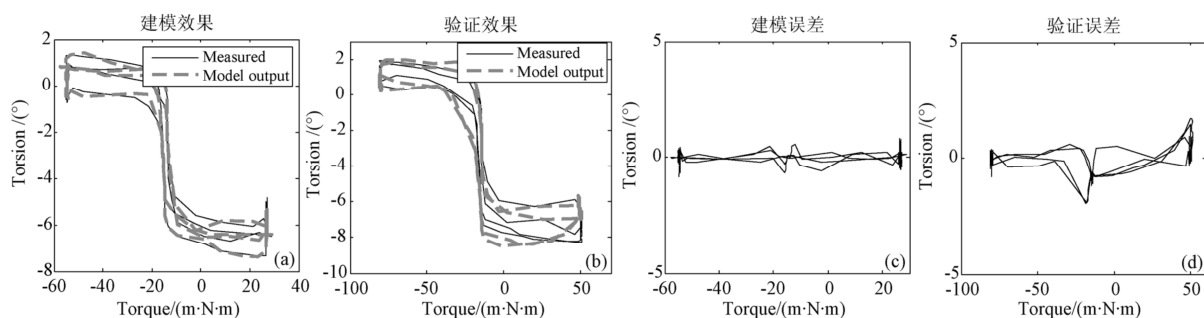


图 10 不同负载下迟滞混合模型建模与验证

Fig. 10 Modeling and verification of hysteresis hybrid model with different load current

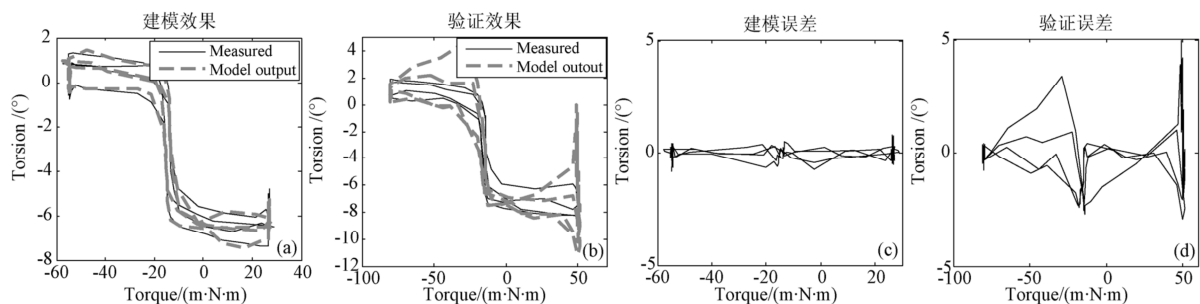


图 11 不同负载下 RBF 神经网络模型建模与验证

Fig. 11 Modeling and verification of RBF Neural Network model with different load current

4.3 不同输入信号不同负载下建模和验证

为了进一步验证所提出的神经网络迟滞混合模型对谐波减速器迟滞建模的有效性和适应能力,在不同频率的输入信号、不同负载状态下,采集数据,对得到的迟滞环数据进行建模和验证。图 12(a)是输入信号频率为 15 mHz、负载为 0.05 A 时取 200 组数据混合迟滞模型的建模结果,图 12(b)是输入信号频率为 10 mHz、负载为 0.1 A 时取 200 组数据对混合迟滞模型的验证结果,模

型可以达到较好的建模和验证效果。图 12(c)、图 12(d)为神经网络迟滞混合模型建模和验证的误差,其中最大误差分别为 -0.6756° 和 -2.1909° ,均方差分别为 0.058 1 和 0.449 6。

与图 12 同样的输入和负载条件下,得到经典 RBF 神经网络模型建模与验证结果如图 13 所示。其中建模和验证最大误差分别为 -0.6899° 和 -3.3594° ,均方差分别为 0.057 8 和 3.032 1。




图 12 不同负载不同频率下迟滞混合模型建模与验证

Fig. 12 Modeling and verification of hysteresis hybrid model with different load current and different frequency input signals

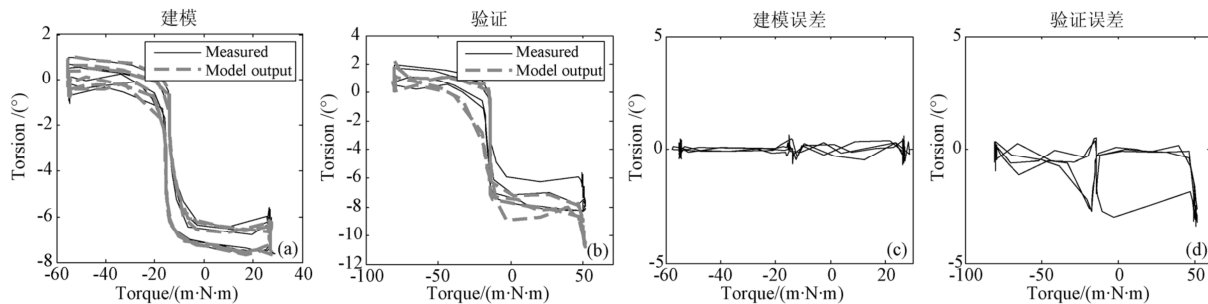


图 13 不同负载不同频率下 RBF 神经网络模型建模与验证

Fig. 13 Modeling and verification of RBF Neural Network model with different load current and different frequency input signals

4.4 实验结果比较分析

由数据可知,所提出的基于构建类迟滞的神经网络迟滞混合模型与 RBF 神经网络模型相比,构成的神经网络迟滞混合模型在神经网络的基础上增加了简单的输入项,结构简洁,便于工程实际应用;在不同频率输入信号、不同负载下实现相同建模精度时,神经网络迟滞混合模型精度远高于后者,具有更好的适应能力。两种迟滞模型验证均方差(MSE)详细对比如表 1 所示。

表 1 两种模型的验证均方差

Tab. 1 Modeling and verification precision of hysteresis model

模型	神经网络迟滞混合模型	RBF 神经网络模型
频率不同	0.113 2	0.177 6
负载不同	0.413 5	2.295 3
频率负载都不同	0.449 6	3.032 1

参考文献:

[1] SHI Z, LI Y, LIU G. Adaptive torque estimation of robot joint with harmonic drive transmission [J].

5 结 论

本文针对谐波减速器所表现出的特殊非线性迟滞特性,基于所发现结构简洁的类迟滞预处理环节,提出了一种将类迟滞预处理与动态 RBF 神经网络相结合的混合迟滞建模方法。使用本文搭建的实验平台测得的数据进行建模验证,结果显示,与直接用经典 RBF 神经网络模型建模方法相比,在不同频率输入信号、不同负载下实现相同建模精度时,神经网络迟滞混合模型的验证精度 0.449 6 (MSE) 远高于 RBF 神经网络模型 3.032 1 (MSE) 的精度。因此本文所提出的神经网络迟滞混合模型误差更小,适应能力更强。以所提出的神经网络迟滞混合模型为基础,建立逆对应模型可以为迟滞特性的高精度补偿与控制提供基础。

Mechanical Systems and Signal Processing, 2017, 96: 1-15.

[2] 吴素珍, 陈丹. 机器人关节传动用精密减速器研究进展[J]. 河南科技学院学报(自然科学版), 2014,

- 42(6):58-63.
- WU S Z, CHEN D. Research progress on application of precision gear reducer in robot joint transmission [J]. *Journal of Henan Institute of Science and Technology*, 2014, 42(6): 58-63. (in Chinese)
- [3] 黑沫,范世珣,廖洪波,等.精密谐波传动系统建模[J].*光学精密工程*,2014,22(7):1842-1849.
- HEI M, FAN SH X, LIAO H B, *et al.*. Modeling of precision harmonic drive system [J]. *Opt. Precision Eng.*, 2014, 22(7): 1842-1849. (in Chinese)
- [4] 杜志江,肖永强,董为.含有摩擦间隙迟滞的机械臂关节建模方法[J].*机器人*,2011,33(5):539-545.
- DU ZH J, XIAO Y Q, DONG W. Modeling of Robot Joints with Friction, Backlash and Hysteresis [J]. *Robot*, 2011, 33(5): 539-545. (in Chinese)
- [5] 石照耀,徐航,韩方旭,等.精密减速器回差测量的现状与趋势[J].*光学精密工程*,2018,26(9):2150-2158.
- SHI ZH Y, XU H, HAN F X, *et al.*. Current status and trend in precision reducer lost motion measurement [J]. *Opt. Precision Eng.*, 2018, 26(9): 2150-2158. (in Chinese)
- [6] 赵强.具有复合材料层的谐波减速器传动精度研究[D].重庆:重庆大学,2015.
- ZHAO Q. *Study on Transmission Accuracy of Harmonic Drive with Composite Material Layer* [D]. Chongqing: Chongqing University, 2015. (in Chinese)
- [7] ZOU C, TAO T, JIANG G, *et al.*. Deformation and stress analysis of short flexspline in the harmonic drive system with load [C]. *IEEE International Conference on Mechatronics and Automation. Takamatsu, Japan*: IEEE, 2013, 466:676-680.
- [8] 万庆祝,陆志刚,王科,等.精密谐波齿轮减速器传动误差分析[J].*仪表技术与传感器*,2013(5):51-54.
- WAN Q ZH, LU ZH G, WANG K, *et al.*. Precision harmonic gear reducer transmission error analysis [J]. *Instrument Technique and Sensor*, 2013 (5): 51-54. (in Chinese)
- [9] RUDERMAN M, BERTRAM T. Modeling and observation of hysteresis lost motion in elastic robot joints [J]. *IFAC Proceedings Volumes*, 2012, 45 (22):13-18.
- [10] 房建成,陈萌,李海涛.磁悬浮控制力矩陀螺框架系统谐波减速器的迟滞建模[J].*光学精密工程*, 2014,22(11):2950-2958.
- FANG J CH, CHEN M, LI H T. Hysteresis modeling for harmonic drive in DGMSCMG gimbal system [J]. *Opt. Precision Eng.*, 2014, 22(11): 2950-2958. (in Chinese)
- [11] XIAO S, LI Y. Modeling and high dynamic compensating the rate-dependent hysteresis of piezoelectric actuators via a novel modified inverse Preisach model [J]. *IEEE Transactions on Control Systems Technology*, 2013, 21(5):1549-1557.
- [12] DANG X, TAN Y H. RBF neural networks hysteresis modelling for piezoceramic actuator using hybrid model [J]. *Mechanical Systems and Signal Processing*, 2007, 21(1): 430-440.
- [13] 党选举,梁卫,姜辉.基于改进Preisach模型的音圈电机复杂迟滞建模[J].*振动与冲击*,2012,31(21): 156-162.
- DANG X J, LIANG W, JIANG H. Complex hysteresis modeling for a voice coil motor based on improved Preisach model [J]. *Journal of Vibration and Shock*, 2012, 31(21): 156-162.
- [14] 刘金琨.智能控制[M].北京:电子工业出版社,2017.
- LIU J K. *Intelligent control* [M]. Beijing: Publishing House of Electronics Industry, 2017. (in Chinese)
- [15] 吕勇,陈青山,刘力双,等.精密谐波齿轮输入轴扭转刚度和迟滞测试[J].*合肥工业大学学报(自然科学版)*,2013,36(5):523-526.
- LV Y, CHEN Q SH, LIU L SH, *et al.*. Test for torsional stiffness and hysteresis of input shaft of precision harmonic gear [J]. *Journal of Hefei University of Technology: Science and Technology*, 2013, 36(5): 523-526. (in Chinese)

作者简介:



党选举(1965—),男,陕西武功人,教授,博士生导师,于1986年、1989年毕业于陕西科技大学,分别获学士、硕士学位。于上海交通大学,获得博士学位。主要从事非线性系统建模与控制。E-mail: xjd69@163.com



王凯利(1992—),女,河北沙河人,硕士研究生,于2015年毕业于天津工业大学获学士学位。主要从事非线性系统建模与控制。E-mail: 1242561892@qq.com