

神经网络类机理建模下的持续自学习控制

谭天乐^{1,2†}, 张万超¹, 何永宁¹, 周恒杰¹

(1. 上海航天控制技术研究所, 上海 201109; 2. 上海市空间智能控制技术重点实验室, 上海 201109)

摘要: 针对未知、时变复杂动力学系统在基于模型的控制中的动态建模问题, 本文采用前向全连接神经网络对动力学系统进行数据驱动下的非机理拟合建模。通过动态线性化和归一化/反归一化数据处理, 基于前向传播算法, 将神经网络的网络拓扑计算过程转化成动力学系统机理模型的同构等价表达形式。与基于模型的预测与反演控制相结合, 提出了神经网络类机理建模下的持续自学习控制方法, 探索了神经网络在动力学系统建模与控制中的可解释性问题。以机械臂为控制对象的仿真结果表明, 神经网络类机理模型与机理模型在形式上同构, 在参数上近似或等价, 可用于控制系统控制品质的定性、定量分析。持续自学习控制对非线性未知、时变复杂系统具有较好的动态适应能力。

关键词: 黑箱系统; 时变系统; 非机理建模; 神经网络建模; 同构等价表达; 模型预测与反演控制; 持续自学习控制; 机械臂控制

引用格式: 谭天乐, 张万超, 何永宁, 等. 神经网络类机理建模下的持续自学习控制. 控制理论与应用, 2024, 41(5): 885–894

DOI: 10.7641/CTA.2023.20771

Continuous self-learning control under transformation of neural network into isomorphic equivalent form of mechanism model

TAN Tian-le^{1,2†}, ZHANG Wan-chao¹, HE Yong-ning¹, ZHOU Heng-jie¹

(1. Shanghai Aerospace Control Technology Institute, Shanghai 201109, China;
2. Shanghai Key Laboratory of Space Intelligent Control Technology, Shanghai 201109, China)

Abstract: Aiming at the problem of dynamic modeling of unknown and time-varying complex dynamic systems in model-based control, a forward fully connected neural network is used to model the dynamic system with data-driven non mechanism fitting. Through dynamic linearization and normalization / anti normalization data processing, based on the forward propagation algorithm, the topological calculation process of neural network is transformed into isomorphic equivalent expression of dynamic system mechanism model. Combined with model-based prediction and inversion control, a continuous self-learning control method based on the neural network mechanism modeling is proposed, and the interpretability of neural network in dynamic system modeling and control is explored. The simulation results with the manipulator as the control object show that the neural network mechanism model is similar to the mechanism model in form, approximate or equivalent in parameters, and can be used for the qualitative and quantitative analysis of the control quality of the control system. Continuous self-learning control has good dynamic adaptability to nonlinear unknown and time-varying complex systems.

Key words: black box system; time varying system; non mechanism modeling; neural network modeling; isomorphic equivalent expression; model prediction and inversion control; continuous self-learning control; manipulator control

Citation: TAN Tianle, ZHANG Wanchao, HE Yongning, et al. Continuous self-learning control under transformation of neural network into isomorphic equivalent form of mechanism model . *Control Theory & Applications*, 2024, 41(5): 885–894

1 引言

对非线性、强耦合、多输入多输出的未知、时变^[1-2]复杂动力学系统进行基于模型的控制时, 存在动态建模问题。当机理建模存在困难时, 可以采用系

统辨识方法, 利用受控系统的在线或离线数据来拟合非线性动态系统, 经过数据处理得到知识以设计控制器, 用于数据驱动下的控制^[3-4]。

由于可充分逼近任意的非线性特性并具有学习跟

收稿日期: 2022-08-31; 录用日期: 2023-04-20.

[†]通信作者. E-mail: 18616017107@163.com; Tel.: +86 18616017107.

本文责任编辑: 贾英民.

踪系统特性变化的能力, 神经网络^[5]已被广泛尝试应用于包括自学习控制^[6]在内的各类控制^[7-11]系统中。如采用神经网络估计和补偿动力学非线性及各种未建模不确定误差^[12-15], 直接拟合系统运动学/动力学^[16-18], 或是用神经网络构建控制器^[19-21]。然而, 基于神经网络的建模和参数辨识的对象通常是动力学系统的局部参数, 而不是通过辨识实时、在线得到系统的整体动力学模型, 基于神经网络的拟合建模或控制器给出的是非线性的计算模型, 常难以在此基础上对控制系统进行能控性、能观性和稳定性等控制特性分析。

本文用前向全连接神经网络拟合受控对象动力学

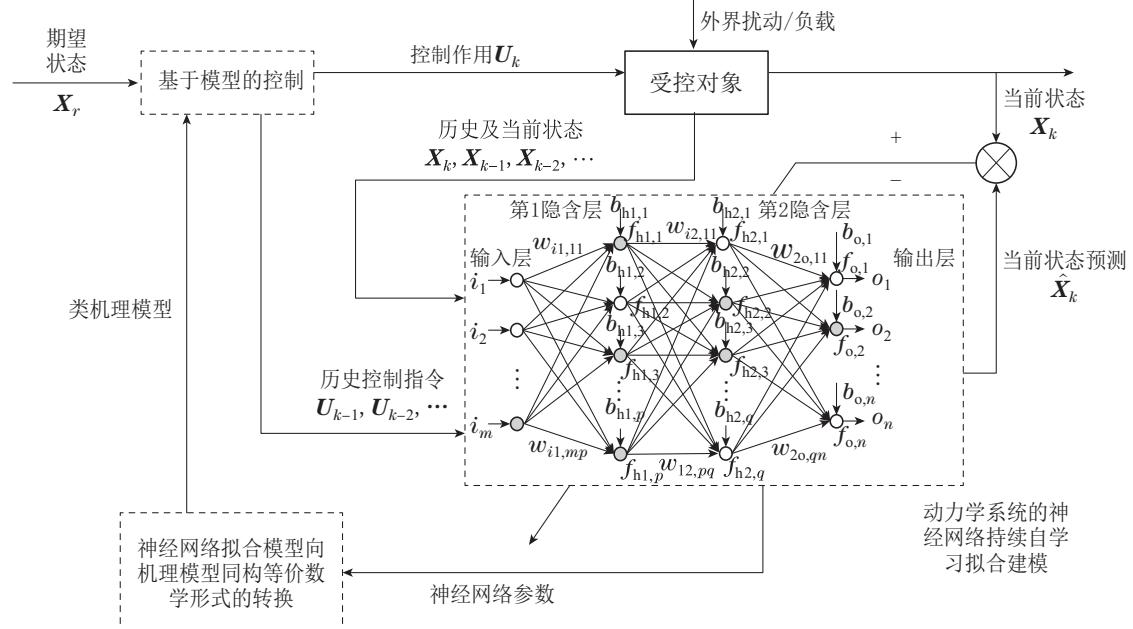


图1 神经网络类机理建模下的持续自学习控制系统原理图

Fig. 1 Principle diagram of continuous self-learning control system based on neural network mechanism modeling

离散时间控制系统中, 受控对象在控制作用下不断进行状态保持或变化。以控制作用输入和系统状态组成学习样本, 通过实时在线的学习训练对受控对象动力学进行神经网络拟合建模。利用神经网络的参数进行受控对象动力学类机理模型的反演和参数的动态辨识与跟踪。采用基于模型的控制器在该模型基础上实现持续自学习控制。

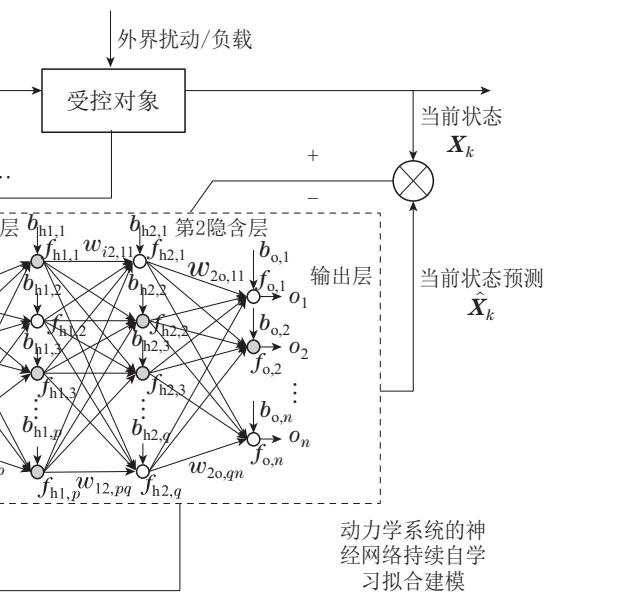
3 神经网络的类机理模型转化

图1中, 神经网络设计为前向全连接神经网络。不失一般性, 设神经网络有1个输入层, 2个隐含层, 1个输出层。 m 个输入组成输入向量 \mathbf{I} , n 个输出组成输出向量 \mathbf{O} 。隐含层1, 2分别有 p, q 个神经元, 隐含层、输出层神经元激活函数分别为 $f_{h1}(\cdot), f_{h2}(\cdot), f_o(\cdot)$; 各层神经元之间连接权值矩阵为 $\mathbf{W}_{i1}, \mathbf{W}_{12}, \mathbf{W}_{2o}$; 各层神经元偏置向量分别为 $\mathbf{B}_{h1}, \mathbf{B}_{h2}, \mathbf{B}_o$ 。由前向传播算法, 易知

特性, 通过局部和动态线性化, 基于前向传播算法, 将神经网络拟合模型的网络拓扑计算转化成状态空间形式下, 动力学系统机理/类机理模型的同构等价形式, 进行了动力学类机理模型的实时在线辨识和模型反演近似, 并讨论了模型辨识的精度。基于模型预测和动力学反演控制, 以三自由度机械臂为对象, 设计了机械臂的持续自学习控制, 仿真验证了所述方法的有效性。

2 控制系统框架

神经网络类机理建模下持续自学习控制系统的原理如图1所示。



$$\mathbf{O} = f_o(\mathbf{W}_{2o} \times f_{h2}(\mathbf{W}_{12} \times f_{h1}(\mathbf{W}_{i1} \times \mathbf{I} + \mathbf{B}_{h1}) + \mathbf{B}_{h2}) + \mathbf{B}_o). \quad (1)$$

为实现神经网络向机理/类机理模型的同构等价转换, 在神经元输入值处, 对神经元激活函数进行求导, 将神经元激活函数变换成如下形式:

$$f(z) = a_0 + a_1 z. \quad (2)$$

表1给出了3种典型神经元激活函数动态线性化时的 a_0, a_1 。其他类型神经元激活函数的动态线性化系数可以类似得到。

经过形如式(2)的变换, 则式(1)可表示成

$$\begin{aligned} \mathbf{O} = & \hat{\Phi} \mathbf{I} + \mathbf{D} = \\ & \mathbf{A}_{o,0} + \mathbf{A}_{o,1} \cdot * (\mathbf{W}_{2o}(\mathbf{A}_{2,0} + \\ & \mathbf{A}_{2,1} \cdot * (\mathbf{W}_{12}(\mathbf{A}_{1,0} + \mathbf{A}_{1,1} \cdot * (\mathbf{W}_{i1} \mathbf{I} + \\ & \mathbf{B}_{h1})) + \mathbf{B}_{h2})) + \mathbf{B}_o), \end{aligned} \quad (3)$$

其中:

$$\hat{\Phi} = \mathbf{A}_{o,1} \cdot \mathbf{W}_{2o} \mathbf{A}_{2,1} \cdot \mathbf{W}_{12} \mathbf{A}_{1,1} \cdot \mathbf{W}_{i1}, \quad (4)$$

$$\mathbf{D} =$$

$$\mathbf{A}_{o,0} + \mathbf{A}_{o,1} \cdot (\mathbf{W}_{2o}(\mathbf{A}_{2,0} + \mathbf{A}_{2,1} \cdot (\mathbf{W}_{12}(\mathbf{A}_{1,0} + \mathbf{A}_{11} \cdot \mathbf{B}_{h1}) + \mathbf{B}_{h2})) + \mathbf{B}_o). \quad (5)$$

表1 神经元激活函数的动态线性化系数 a_0, a_1

Table 1 Dynamic linearization coefficient a_0 and a_1 of neuron activation function

神经元激活函数	a_0	a_1
Sigmoid	$\frac{1}{1+e^{-z}}$	$\frac{1}{1+e^{-z}} - \frac{ze^{-z}}{(1+e^{-z})^2}$
Tanh	$\frac{e^z - e^{-z}}{e^z + e^{-z}}$	$\frac{e^{2z} - e^{-2z} - 4z}{(e^z + e^{-z})^2}$
Purelin	z	0
		1

由线性化方法易知, 式(3)等价于式(1). 动态线性化过程不会产生额外的误差.

在离散时间系统中, 状态空间形式下的动力学系统可表示为

$$\mathbf{X}_{k+1} = \mathbf{G}_{k+1,k} \mathbf{X}_k + \mathbf{H}_{k+1,k} \mathbf{U}_k, \quad (6)$$

其中: $\mathbf{X} = [x_1 \ x_2 \ \cdots \ x_{m1}]^T$ 为系统状态; $\mathbf{G}|_{m1 \times m1}$ 为状态转移矩阵; $\mathbf{U} = [u_1 \ u_2 \ \cdots \ u_{m2}]^T$ 为控制量; $\mathbf{H}|_{m1 \times m2}$ 为控制作用系数矩阵. 对式(6)进行神经网络拟合, 并作类机理建模.

令神经网络每个训练样本中, 神经网络的输入为 $\mathbf{I} = [\mathbf{X}_k^T \ \mathbf{U}_k^T]^T$, 输出为 $\mathbf{O} = \mathbf{X}_{k+1}$, 则当神经网络学习训练好之后, 由式(3)有

$$\mathbf{X}_{k+1} = \hat{\mathbf{G}}_{k+1,k} \mathbf{X}_k + \hat{\mathbf{H}}_{k+1,k} \mathbf{U}_k + \mathbf{D}_k, \quad (7)$$

式中: $\hat{\mathbf{G}}_{k+1,k}$ 为拟合得到的系统状态矩阵, $\hat{\mathbf{H}}_{k+1,k}$ 为拟合得到的控制作用系数阵, 有 $\hat{\Phi} = [\hat{\mathbf{G}}_{k+1,k} \ \hat{\mathbf{H}}_{k+1,k}]$; $\mathbf{D}_k = \mathbf{D}$ 为模型补偿项, 当神经网络能较好拟合动力学系统时, \mathbf{D}_k 应趋向于全零向量.

经过以上转化, 得到神经网络拟合模型的类机理模型同构等价表达形式.

当动力学系统受控运动或演变时, 将由各个控制节拍中, 系统所受控制作用以及系统的状态不断组成新的样本. 通过神经网络的在线学习, 实时动态更新辨识得到的类机理模型, 从而实现模型的持续自学习.

4 归一化与反归一化

神经网络的学习训练一般需要对学习样本进行归一化处理. 在神经网络类机理模型同构等价转化过程中需要进行相应的变换.

当采用最大最小归一化方法将训练样本集中的神

经网络输入、输出归一化到 $[-1, 1]$ 之间, 则有

$$i_{j,\text{nom}} = 2 \frac{i_j - i_{j,\text{mean}}}{i_{j,\text{max}} - i_{j,\text{min}}}, \quad j = 1, 2, \dots, m, \quad (8)$$

$$o_{k,\text{nom}} = 2 \frac{o_k - o_{k,\text{mean}}}{o_{k,\text{max}} - o_{k,\text{min}}}, \quad k = 1, 2, \dots, n, \quad (9)$$

式中: $i_{j,\text{mean}}, i_{j,\text{max}}, i_{j,\text{min}}, o_{k,\text{mean}}, o_{k,\text{max}}, o_{k,\text{min}}$ 分别为样本集中每个输入、输出的平均值、最大值和最小值.

若训练样本归一化后由神经网络辨识转化得到 $\hat{\Phi}_0, \mathbf{D}_0$, 则由式(3)(8)–(9)有

$$(\mathbf{O} - \mathbf{O}_{\text{mean}}) ./ (\mathbf{O}_{\text{max}} - \mathbf{O}_{\text{min}}) =$$

$$\hat{\Phi}_0((\mathbf{I} - \mathbf{I}_{\text{mean}}) ./ (\mathbf{I}_{\text{max}} - \mathbf{I}_{\text{min}})) + \mathbf{D}_0 / 2, \quad (10)$$

式中, 令 $\Delta \mathbf{I} = \mathbf{I}_{\text{max}} - \mathbf{I}_{\text{min}}$, $\Delta \mathbf{O} = \mathbf{O}_{\text{max}} - \mathbf{O}_{\text{min}}$, 有

$$\begin{aligned} \mathbf{O} &= \hat{\Phi}_0((\mathbf{I} - \mathbf{I}_{\text{mean}}) ./ \Delta \mathbf{I}) \cdot * \Delta \mathbf{O} + \\ &\quad \mathbf{D}_0 \cdot * \Delta \mathbf{O} / 2 + \mathbf{O}_{\text{mean}} = \\ &\quad \hat{\Phi}_0 ./ \Delta \mathbf{I}^T \cdot * \Delta \mathbf{O} \mathbf{I} - (\hat{\Phi}_0(\mathbf{I}_{\text{mean}} ./ \Delta \mathbf{I})) \cdot * \Delta \mathbf{O} + \\ &\quad \mathbf{D}_0 \cdot * \Delta \mathbf{O} / 2 + \mathbf{O}_{\text{mean}}. \end{aligned} \quad (11)$$

进而得到

$$\hat{\Phi} = \hat{\Phi}_0 ./ \Delta \mathbf{I}^T \cdot * \Delta \mathbf{O}, \quad (12)$$

$$\begin{aligned} \mathbf{D} &= -\hat{\Phi}_0 ./ \Delta \mathbf{I}^T \cdot * \Delta \mathbf{O} \mathbf{I}_{\text{mean}} + \\ &\quad \mathbf{D}_0 \cdot * \Delta \mathbf{O} / 2 + \mathbf{O}_{\text{mean}}. \end{aligned} \quad (13)$$

若采用诸如tanh函数的其他归一化方法, 则用形如式(2)的动态线性化方法, 可类似得到相应的反归一化策略.

5 基于类机理模型的预测与反演控制

在基于模型的预测与反演控制^[22](model predictive and inversive control, MPIC)中应用神经网络类机理模型. 由式(7)有

$$\mathbf{X}_{k+1} = \hat{\Phi}_{k+1,0} \mathbf{X}_0 + \hat{\mathbf{Q}}_{k+1,0} \mathbf{U}_{k,0} + \mathbf{D}_{k+1,0}, \quad (14)$$

其中:

$$\hat{\Phi}_{k+1,0} = \prod_{i=0}^k \hat{\mathbf{G}}_{i+1,i}, \quad (15)$$

$$\begin{aligned} \hat{\mathbf{Q}}_{k+1,0} &= [\hat{\mathbf{H}}_{k+1,k} \ \hat{\mathbf{G}}_{k+1,k} \hat{\mathbf{H}}_{k,k-1} \\ &\quad \hat{\mathbf{G}}_{k+1,k-1} \hat{\mathbf{H}}_{k-1,k-2} \ \cdots \ \hat{\mathbf{G}}_{k+1,1} \hat{\mathbf{H}}_{1,0}], \end{aligned} \quad (16)$$

$$\mathbf{D}_{k+1,0} = \sum_{i=0}^k (\hat{\mathbf{G}}_{k,i} \mathbf{D}_i), \quad (17)$$

$$\mathbf{U}_{k,0} = [\mathbf{U}_k^T \ \mathbf{U}_{k-1}^T \ \cdots \ \mathbf{U}_0^T]^T. \quad (18)$$

若当前控制周期为 T_0 , 已辨识出前一控制周期的 $\hat{\mathbf{G}}_{0,-1}, \hat{\mathbf{H}}_{0,-1}, \mathbf{D}_{0,-1}$, 且对于 $i=0, 1, 2, \dots, k$, 有 $\mathbf{G}_{i+1,i} \approx \hat{\mathbf{G}}_{0,-1}, \mathbf{H}_{i+1,i} \approx \hat{\mathbf{H}}_{0,-1}, \mathbf{D}_{i+1,i} \approx \mathbf{D}_{0,-1}$, 则对于期望的 \mathbf{X}_{k+1}^* , 可以得到所有可能的控制作用

序列, 即

$$\begin{aligned} \mathbf{U}_{k,0} = & \hat{\mathbf{Q}}_{k+1,0}^+ (\mathbf{X}_{k+1}^* - \hat{\Phi}_{k+1,0} \mathbf{X}_0 - D_{k+1,0}) + \\ & (\mathbf{I}_n - \hat{\mathbf{Q}}_{k+1,0}^+ \hat{\mathbf{Q}}_{k+1,0}) \mathbf{V}, \end{aligned} \quad (19)$$

式中: $\hat{\mathbf{Q}}_{k+1,0}^+$ 为 $\hat{\mathbf{Q}}_{k+1,0}$ 的广义逆; \mathbf{I}_n 为相应维数的单位矩阵; \mathbf{V} 为相应维数的任意向量. 通常可以取用以上通解中的最小二乘、最小范数特解, 即

$$\mathbf{U}_{k+1,0} = \hat{\mathbf{Q}}_{k+1,0}^+ (\mathbf{X}_{k+1}^* - \hat{\Phi}_{k+1,0} \mathbf{X}_0 - D_{k+1,0}), \quad (20)$$

取控制序列 $\mathbf{U}_{k,0}$ 中 \mathbf{U}_0 输出, 并在之后的控制周期中如此反复. 由于系统建模、状态测量和控制执行过程中存在误差, 以及系统受到内/外部扰动, 将导致控制偏差, 可以进行控制偏差的补充. 简单的PID补偿为

$$\mathbf{U}'_0 = \mathbf{Q}_{1,0}^+ (\mathbf{K}_P \Delta \mathbf{X}_0 + \mathbf{K}_I \sum_{j=-\infty}^0 \Delta \mathbf{X}_j + \mathbf{K}_D \Delta \dot{\mathbf{X}}_0), \quad (21)$$

其中: $\Delta \mathbf{X}_j$ 为第 j 次采样时的系统状态偏差; \mathbf{K}_P , \mathbf{K}_I , \mathbf{K}_D 为相应维数的补偿系数向量. 最终的控制为

$$\mathbf{U}_{\text{total}} = \mathbf{U}_0 + \mathbf{U}'_0. \quad (22)$$

从而实现基于神经网络类机理模型的预测与反演控制. 控制系统中, 控制作用同时作为神经网络持续学习和训练的激励源.

6 仿真验证

三自由度机械臂如图2所示.

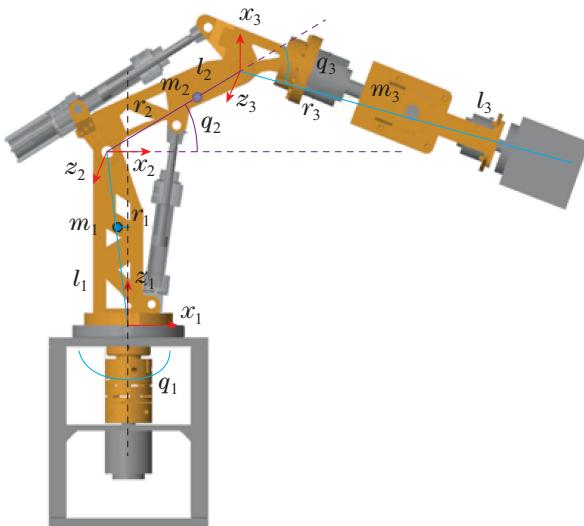


图2 机械臂示意图

Fig. 2 Schematic diagram of mechanical arm

其质量特性及结构参数分别如表2-3所示. 其中: m_i 为第 i 个臂杆的质量, I_i 为第 i 个臂杆绕其关节轴的惯量, l_i 为第 i 个臂杆的长度, r_i 为第 i 个臂杆重心位置到关节轴的长度, 重力加速度取 $g = 9.8 \text{ m}\cdot\text{s}^{-2}$. m_i , I_i 设置为时变量, 模拟在操作过程中机械臂发生的质量、惯量变化.

表2 三自由度机械臂的质量特性

Table 2 Quality characteristics of 3-DOF manipulator

参数	参数值
m_1	$47.682(1 + 0.5 \sin(0.12t)) \text{ kg}$
m_2	$40.828(1 + 0.5 \sin(0.16t)) \text{ kg}$
m_3	$94.797(1 + 0.5 \sin(0.20t)) \text{ kg}$
I_1	$0.83(1 + 0.5 \sin(0.12t)) \text{ kg}\cdot\text{m}^2$
I_2	$0.98(1 + 0.5 \sin(0.16t)) \text{ kg}\cdot\text{m}^2$
I_3	$9.35(1 + 0.5 \sin(0.20t)) \text{ kg}\cdot\text{m}^2$

表3 三自由度机械臂的结构参数

Table 3 Structural parameters of 3-DOF manipulator

参数	参数值/m	参数	参数值/m
l_1	0.57	r_1	0.05
l_2	0.52	r_2	0.22
l_3	2.00	r_3	0.41

将机械臂的3个关节角及其角速度 $x_1 = q_1$, $x_2 = q_2$, $x_3 = q_3$, $x_4 = \dot{q}_1$, $x_5 = \dot{q}_2$, $x_6 = \dot{q}_3$ 设为系统状态, 以关节力矩 $\mathbf{u} = [\tau_1 \ \tau_2 \ \tau_3]^T$ 作为系统控制, 不考虑摩擦力和外部干扰, 得到机械臂的拉格朗日动力学模型

$$\mathbf{M}(\mathbf{x})\ddot{\mathbf{x}} + \mathbf{C}(\mathbf{x}, \dot{\mathbf{x}})\dot{\mathbf{x}} + \mathbf{G}_g = \mathbf{u}, \quad (23)$$

其中:

$$\begin{aligned} \mathbf{M}(\mathbf{x}) &= \begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \end{bmatrix}; \\ \mathbf{C}(\mathbf{x}, \dot{\mathbf{x}}) &= \begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{bmatrix}; \quad \mathbf{G}_g = \begin{bmatrix} g_1 \\ g_2 \\ g_3 \end{bmatrix}; \end{aligned}$$

质量/惯量矩阵 $\mathbf{M}(\mathbf{x})$ 中:

$$\begin{aligned} m_{11} &= a_0 + a_1 \cos x_2 \cos x_2 + a_2 a_3 \cos(x_2 + x_3) \times \\ &\cos(x_2 + x_3) + 2a_3 \cos x_2 \cos(x_2 + x_3) + I_1; \\ m_{12} &= 0; \quad m_{13} = 0; \quad m_{21} = 0; \\ m_{22} &= I_2 + A_1 + a_2 + 2A_3 \cos x_3; \\ m_{23} &= a_2 + A_3 \cos x_3; \quad m_{31} = 0; \quad m_{32} = m_{23}; \\ m_{33} &= I_3 + a_2; \\ a_0 &= m_1 r_1^2; \quad a_1 = m_2(r_2 - l_{20})^2 + m_3(l_2 - l_{20})^2; \\ a_2 &= m_3 r_3^2; \quad a_3 = m_3 r_3(l_2 - l_{20}); \quad A_1 = m_2 r_2^2; \\ A_3 &= m_3 r_3 l_2; \end{aligned}$$

科氏力、离心力矩阵 $\mathbf{C}(\mathbf{x}, \dot{\mathbf{x}})$ 中:

$$\begin{aligned} c_{11} &= -0.5a_1 \sin(2x_2)x_5 - 0.5a_2 \sin(2x_2 + 2x_3) \times \\ &(x_5 + x_6) - a_3 \sin(2x_2 + x_3)x_5 - \\ &a_3 \cos x_2 \sin(x_2 + x_3)x_6; \end{aligned}$$

$$\begin{aligned}
c_{12} &= -0.5a_1 \sin(2x_2)x_5 - \\
&\quad 0.5a_2 \sin(2x_2+2x_3)x_4 - a_3 \sin(2x_2+x_3)x_4; \\
c_{13} &= -0.5a_2 \sin(2x_2+2x_3)x_4 - \\
&\quad a_3 \cos x_2 \sin(x_2+x_3)x_4; \\
c_{21} &= -c_{12}; c_{22} = -A_3 \sin(x_3)x_6; \\
c_{23} &= -A_3(x_5+x_6) \sin x_3; \\
c_{31} &= -c_{13}; c_{32} = A_3 \sin(x_3)x_5; c_{33} = 0;
\end{aligned}$$

重力项 \mathbf{G}_g 中:

$$\begin{aligned}
g_1 &= 0; g_2 = b_1 \cos x_2 + b_2 \cos(x_2+x_3); \\
g_3 &= b_2 \cos(x_2+x_3); \\
b_1 &= (m_2 r_2 + m_3 l_2)g; b_3 = m_3 r_3 g;
\end{aligned}$$

表示成状态空间形式, 得到

$$\dot{\mathbf{x}} = \mathbf{Ax} + \mathbf{B}(\mathbf{u} - \mathbf{G}_g), \quad (24)$$

式中:

$$\mathbf{A} = \begin{bmatrix} 0_{3 \times 3} & \mathbf{I}_{3 \times 3} \\ 0_{3 \times 3} & -\mathbf{M}^{-1}\mathbf{C} \end{bmatrix}; \mathbf{B} = \begin{bmatrix} 0 \\ \mathbf{M}^{-1} \end{bmatrix}.$$

离散化式(24)后可以得到状态转移方程

$$\mathbf{X}_{k+1} = \mathbf{G}_{k+1,k} \mathbf{X}_k + \mathbf{H}_{k+1,k} \mathbf{U}_k - \mathbf{H}_{k+1,k} \mathbf{G}_{g,k}. \quad (25)$$

根据表2-3所示机械臂参数, 可由式(23)–(25)得到 $\mathbf{G}_{k+1,k}$, $\mathbf{H}_{k+1,k}$ 及 $-\mathbf{H}_{k+1,k} \mathbf{G}_{g,k}$ 的精确解析表达. 仿真中用以作为神经网络类机理建模的比较基准.

构建如图1所示的持续自学习控制系统. 受控对象为机械臂. 基于模型的预测与反演控制中, 预测反演控制周期数设为1.

机械臂对于控制系统是一个黑箱系统, 仅仅在整个控制过程中向神经网络提供学习和训练样本. 前向全连接神经网络的训练样本中, 输入为 $[\mathbf{X}_k^T \ \mathbf{U}_k^T]^T$, 输出为 \mathbf{X}_{k+1} . 采用滑动窗口方式取最近200个控制周期中的数据组成训练样本集. 神经网络参数如表4所示. 其中 Levenberg-Marquardt 是高斯-牛顿法和最速下降法的结合, 既有高斯-牛顿法的局部收敛性, 又有梯度法的全局特性, 其计算复杂度是 $n^3/6$, n 是网络中权值数目.

仿真机械臂3个关节从零角度静止状态开始, 分别作幅值/偏置为 $3 \text{ rad}/3 \text{ rad}$, $-4 \text{ rad}/-4 \text{ rad}$, $5 \text{ rad}/5 \text{ rad}$ 的正弦摆动持续自学习控制. 摆动频率分别为 0.12 rad/s , 0.16 rad/s , 0.20 rad/s . 在第 20 s 停止摆动, 保持状态. 控制过程时间 60 s . 控制系统的测控周期为 0.001 s .

持续自学习过程中对神经网络拟合模型进行机理模型同构等价形式的辨识转换以用于MPI控制. 对机械臂的MPI控制过程中则不断产生新的数据样本用于

神经网络的类机理建模.

表4 神经网络参数

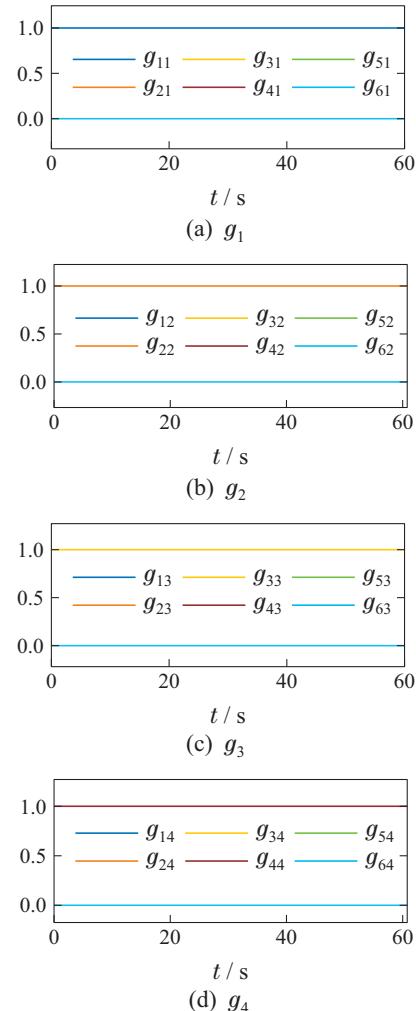
Table 4 Parameters of neural network

参数	参数值
隐层数	2
隐层神经元个数	9, 9
激活函数	'purelin', 'purelin', 'purelin'
学习训练算法	Levenberg-Marquardt
每轮学习中最大训练次数	2000
学习率	0.001
学习误差阈值	1e-8
性能函数	MSE, Mean squared error
动量因子	0.6
滑动窗口采样样本数	200

以下分别从辨识模型与机理模型一致性、辨识模型与动力学输入输出映射关系的一致性, 以及控制的精度3方面给出仿真验证结果.

1) 辨识模型与机理模型的一致性.

由式(25)机理模型得到 $\mathbf{G}_{k+1,k}$, 在控制过程中由神经网络类机理建模辨识得到 $\hat{\mathbf{G}}_{k+1,k}$. $\mathbf{G}_{k+1,k}$, $\hat{\mathbf{G}}_{k+1,k}$ 各列分别见图3-4.



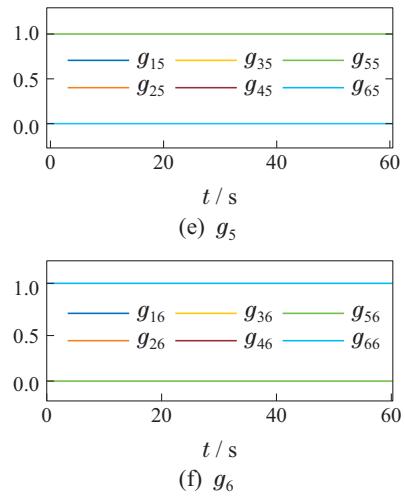
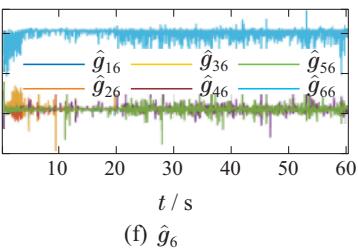
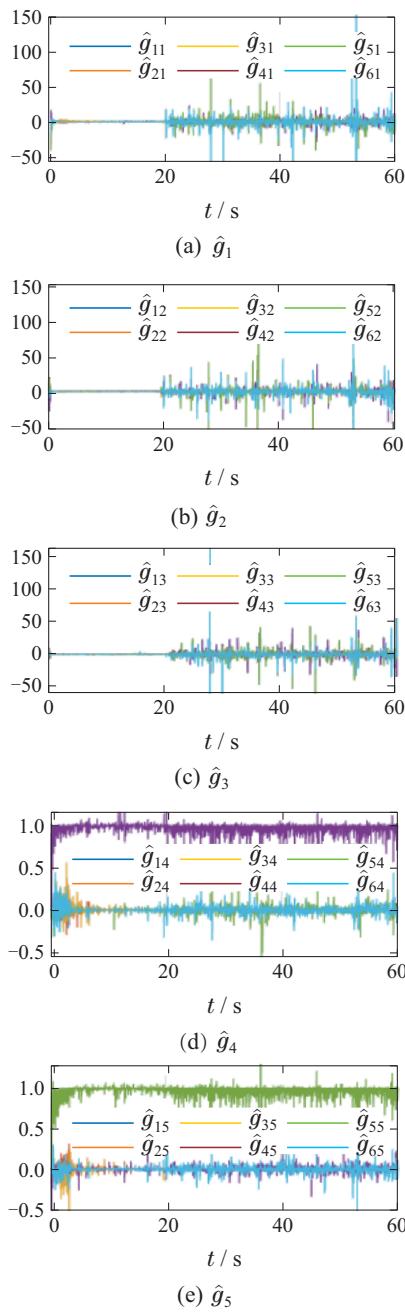
图 3 $G_{k+1,k}$ 各列Fig. 3 Columns of $G_{k+1,k}$ 图 4 $\hat{G}_{k+1,k}$ 各列
Fig. 4 Columns of $\hat{G}_{k+1,k}$

表5给出了 $\hat{G}_{k+1,k}$ 各列拟合参数中的最小平均绝对百分比误差(mean absolute percentage error, MAPE). $\hat{G}_{k+1,k}$ 中第4, 5, 6列参数 $\hat{g}_4, \hat{g}_5, \hat{g}_6$ 分别与 $G_{k+1,k}$ 中对应的 g_4, g_5, g_6 基本一致. $\hat{g}_1, \hat{g}_2, \hat{g}_3$ 则分别与 g_1, g_2, g_3 存在一定偏差.

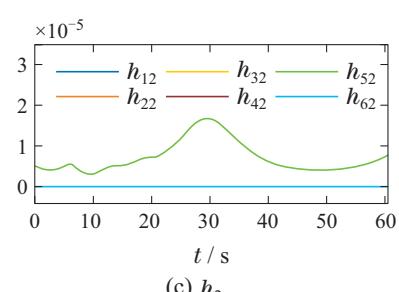
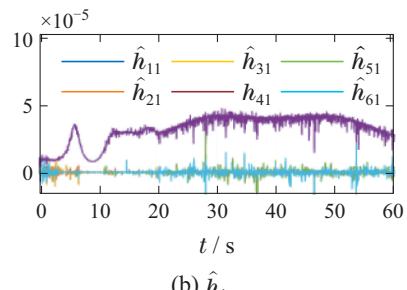
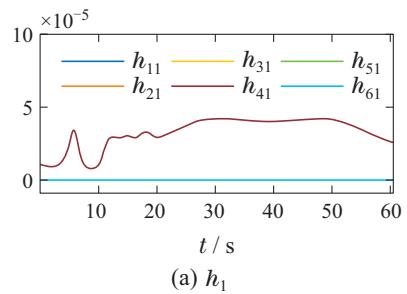
表 5 $\hat{G}_{k+1,k}$ 的MAPETable 5 MAPE of $\hat{G}_{k+1,k}$

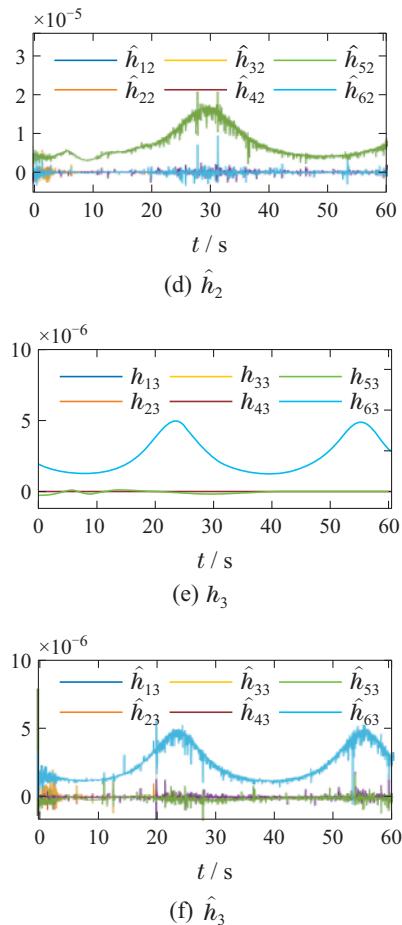
	\hat{g}_{11}	\hat{g}_{22}	\hat{g}_{33}	\hat{g}_{44}	\hat{g}_{55}	\hat{g}_{66}
MAPE/%	13.49	15.21	15.53	2.60	3.06	3.26

式(25)中的 $H_{k+1,k}$ 及辨识得到 $\hat{H}_{k+1,k}$ 各列见图5.

表6给出了 $\hat{H}_{k+1,k}$ 对 $H_{k+1,k}$ 各列参数拟合的最小平均绝对百分比误差.

$\hat{H}_{k+1,k}$ 对 $H_{k+1,k}$ 的拟合较为精确.



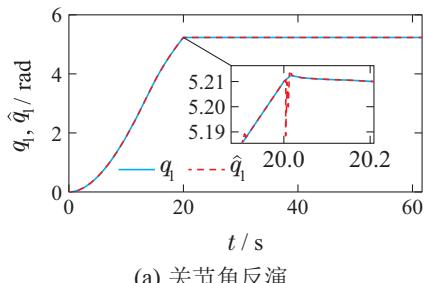
图 5 $\mathbf{H}_{k+1,k}$ 及 $\hat{\mathbf{H}}_{k+1,k}$ 各列Fig. 5 Columns of $\mathbf{H}_{k+1,k}$ and $\hat{\mathbf{H}}_{k+1,k}$ 表 6 $\hat{\mathbf{H}}_{k+1,k}$ 的 MAPETable 6 MAPE of $\hat{\mathbf{H}}_{k+1,k}$

	\hat{h}_{41}	\hat{h}_{52}	\hat{h}_{63}
MAPE/%	2.82	3.31	3.47

2) 辨识模型与受控对象动力学的一致性。

通过辨识得到的 $\hat{\mathbf{G}}_{k+1,k}$, $\hat{\mathbf{H}}_{k+1,k}$, \mathbf{D} , 以及每一控制节拍的 \mathbf{X}_k , \mathbf{U}_k , 由式(7)可以得到 \mathbf{X}_{k+1} 的估计值 $\hat{\mathbf{X}}_{k+1}$. 图6给出了 $\hat{\mathbf{X}}_{k+1}$ 与 \mathbf{X}_{k+1} 的比较.

可以看到, 虽然如表4-5所示, 辨识模型和机理模型存在一定偏差, 但辨识模型在输入输出的映射关系上与受控对象具有良好的一致性.



(a) 关节角反演

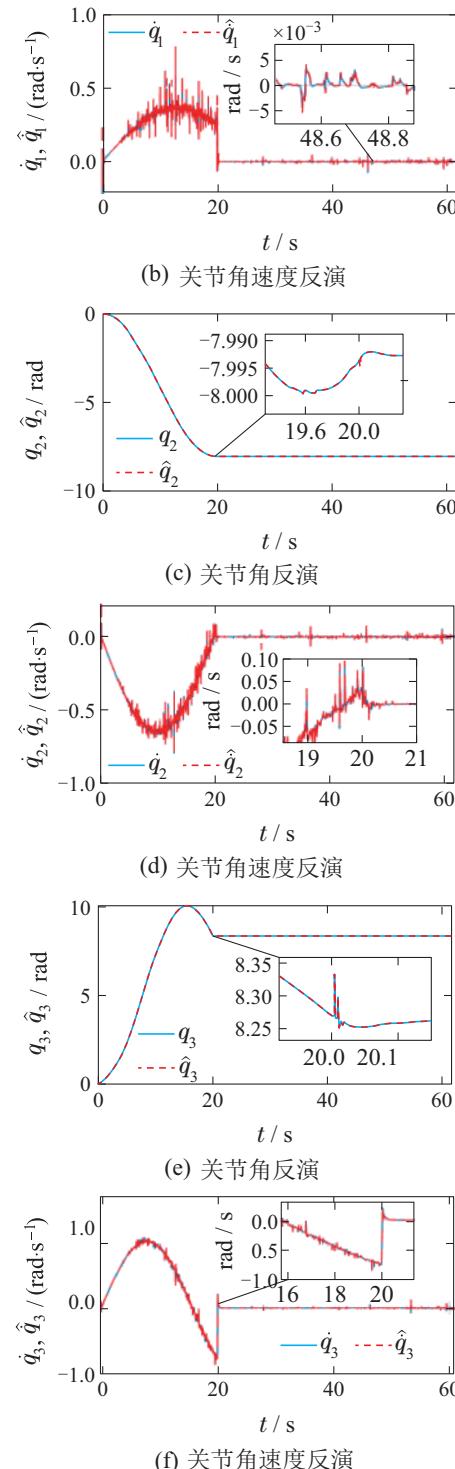


图 6 神经网络类机理模型一致性比较

Fig. 6 Consistency comparison of neural network mechanism models

3) 控制精度.

图7给出了持续自学习控制下, 机械臂关节角、关节角速度曲线. 图8给出了关节角、关节角速度的控制误差. 机械臂关节角控制精度优于 1×10^{-3} rad, 关节角速度控制误差约为 1×10^{-2} rad/s.

通过神经网络类机理建模转化, 基于模型预测及动力学反演控制, 在质量、惯量参数实时变化情况下,

实现了机械臂的持续自学习控制。控制过程中,可以根据辨识模型的 $\hat{\mathbf{G}}_{k+1,k}$, $\hat{\mathbf{H}}_{k+1,k}$ 实时计算系统可控性。

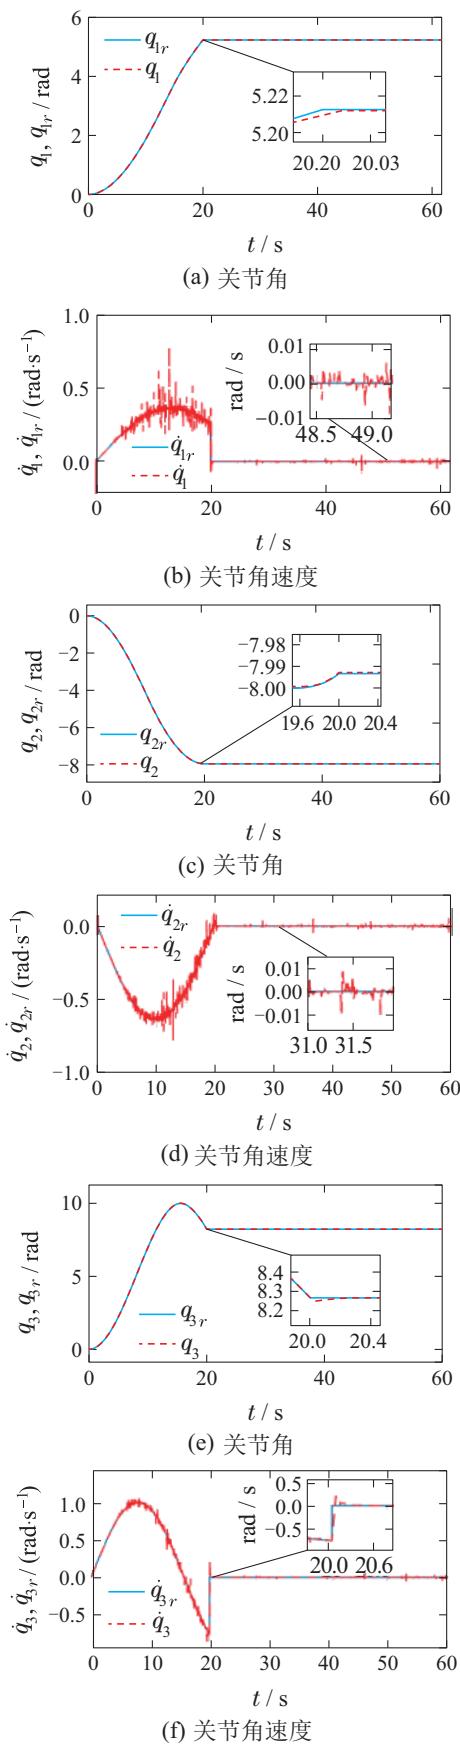


图 7 关节角、关节角速度

Fig. 7 Joint angle and joint angular velocity

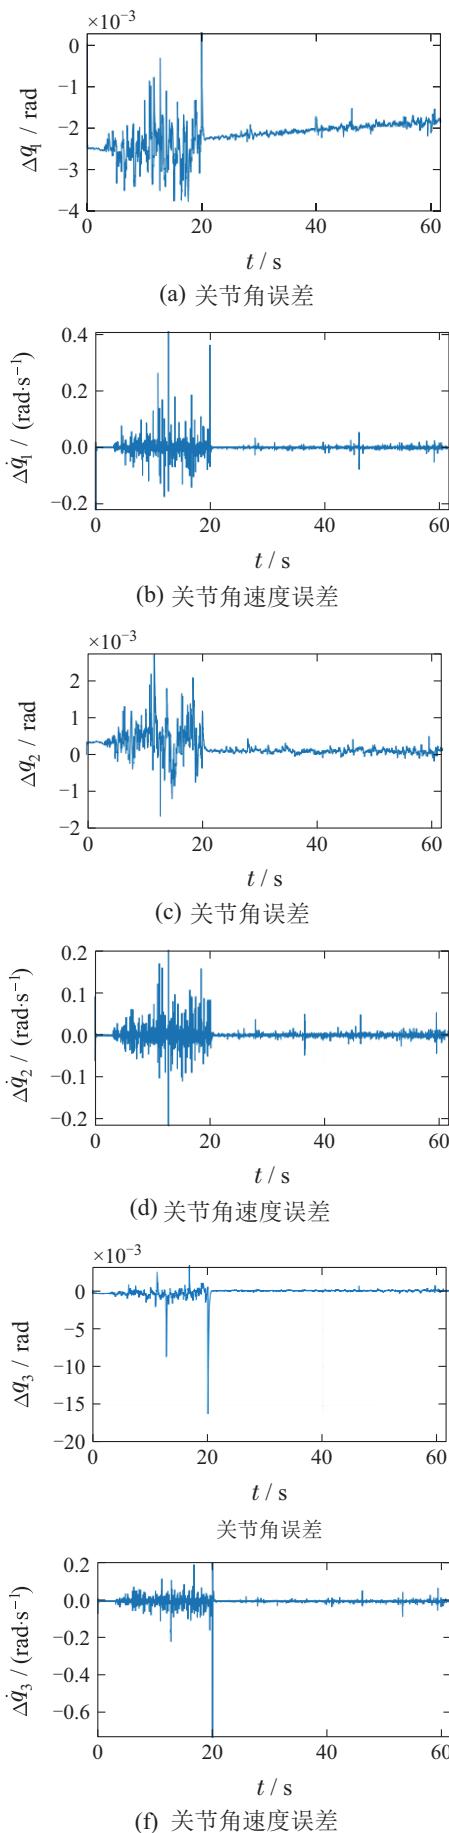


图 8 关节角、关节角速度误差

Fig. 8 Deviation of joint angle and joint angular velocity

图9给出了关节控制力矩. 力矩限幅5000 N·m.

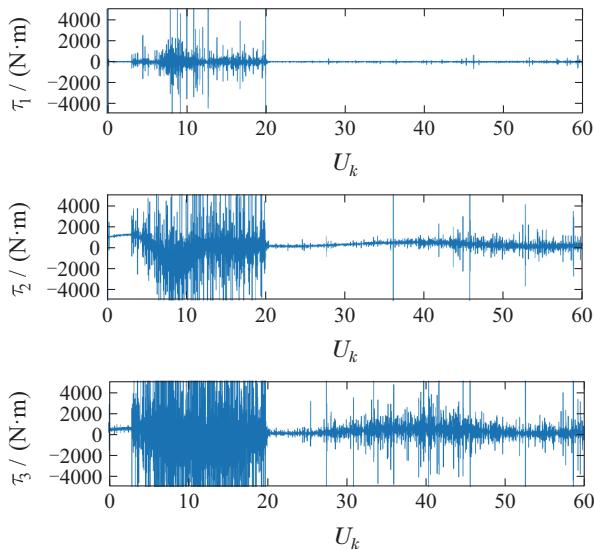


图9 关节控制力矩

Fig. 9 Torque for joint control

神经网络在动力学规律的学习上受限于滑动窗口式取样方式, 存在“遗忘”现象, 从而引起控制力矩的波动.

由神经网络转化得到的机理模型同构等价形式较好的拟合了动力学系统机理模型. 神经网络的网络拓扑运算转化成了容易理解, 具有较好可解释性的动力学机理模型同构形式. 该同构形式中的各个参数与机理模型相应参数近似等价. 在控制过程中, 即使受控对象机械臂的质量、惯量及结构等参数未知时变, 仍然可以经由神经网络实时反演得到的, 形如式(25)的类机理模型, 进而定性、定量的实时分析控制系统的各种控制特性.

神经网络的参数直接影响控制的效果, 包括: 动态样本集的组成规模、数据预处理方法(归一化/标准化)、神经网络结构、激活函数和学习训练算法、学习过程参数(一轮学习中的最大训练次数、训练误差阈值、学习因子、动量因子)等. 不同参数下, 神经网络的学习结果也将有差异, 动力学系统最终在MPI控制下的结果也将有不同.

7 结论

本文通过神经网络类机理模型同构等价转换, 将神经网络拟合模型中隐藏蕴含的系统动力学演化规律表示为与机理模型一致或相似的显式方式. 该方法是对动力学系统模型在各个模型元素上进行反演. 由于能够得到与状态转移方程同构等价的类机理模型, 因此, 可以在基于神经网络的持续自学习控制中对控制系统进行实时、动态、定量的控制特性分析. 这种神经网络实时动态拟合建模不依赖对象模型, 仅仅由数据驱动, 但能给基于模型的控制提供受控对象的类机

理模型, 使控制器具有较强的自适应能力、抗扰能力和快速性.

本文所提出的方法还有很多值得深入研究的问题, 包括不同形式的神经网络对持续自学习的不同影响, 如何确定最适合受控对象的神经网络结构形式、规模大小, 如何选择合适的神经元激活函数和训练算法, 持续自学习过程中是否可以动态的调整神经网络自身的结构和参数等. 此外, 由于在构建训练样本集时采用了滑动窗口的方式, 会出现不断遗忘既往所学到知识的现象, 这种神经网络普遍存在的“灾难性遗忘”问题也需要进一步研究并加以解决.

参考文献:

- [1] YU Xia, LIU Jianchang, LI Hongru. Survey on control of time-varying systems. *Control and Decision*, 2011, 26(9): 1281 – 1287, 1294.
(于霞, 刘建昌, 李鸿儒. 时变系统控制方法综述. 控制与决策, 2011, 26(9): 1281 – 1287, 1294.)
- [2] YE H F, SONG Y D. Adaptive control with guaranteed transient behavior and zero steady-state error for systems with time-varying parameters. *IEEE/CAA Journal of Automatica Sinica*, 2022, 9(6): 1073 – 1082.
- [3] HOU Zhongsheng, XU Jianxin. On data-driven control theory: The state of the art and perspective. *Acta Automatica Sinica*, 2009, 35(6): 650 – 667.
(侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望. 自动化学报, 2009, 35(6): 650 – 667.)
- [4] LEE M, CHIO H, KIM C, et al. Precision motion control of robotized industrial hydraulic excavators via data-driven model inversion. *IEEE Robotics and Automation Letters*, 2022, 7(2): 1912 – 1919.
- [5] ZHANG Chi, GUO Yuan, LI Ming. Review of development and application of artificial neural network models. *Computer Engineering and Applications*, 2021, 57(11): 57 – 69.
(张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述. 计算机工程与应用, 2021, 57(11): 57 – 69.)
- [6] NGUYEN D H, WIDROW B. Neural networks for self-learning control systems. *International Journal of Control*, 2002, 54(6): 1439 – 1451.
- [7] ZHANG Haitao, CHEN Zonghai, XIANG Wei. Summary of artificial neural networks' application in control and modeling. *Proceedings of 2003 Academic Exchange Conference on System Simulation Technology and Its Application*, 2003: 19 – 31.
(张海涛, 陈宗海, 向微. 人工神经网络在系统控制和建模中的应用综述. 2003系统仿真技术及其应用学术交流会论文集, 2003: 19 – 31.)
- [8] THOMAS M J, GEORGE S, SREEDHARAN D, et al. Dynamic modeling, system identification and comparative study of various control strategies for a spatial parallel manipulator. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 2022, 236(2): 270 – 293.
- [9] WU D, ZHU X, WEN J, et al. Neural network based identification and self-tuning PID control for spacecraft thermal vacuum tests. *Journal of Physics: Conference Series*, 2022, 2216(1): 012058.
- [10] WEN Tianci, FANG Yongchun, LU Biao. Adaptive antiswing control for underactuated dual overhead crane system using neural network. *Acta Automatica Sinica*, 2023, 49(1): 111 – 121.
(文天赐, 方勇纯, 卢彪. 采用神经网络的双吊车自适应防摆控制. 自动化学报, 2023, 49(1): 111 – 121.)

- [11] LIANG Xianglong, YAO Jianyong. Nonlinear control of mechatronic servo system based on neural network. *Control and Decision*, 2023, 38(4): 1008 – 1014.
(梁相龙, 姚建勇. 基于神经网络的机电伺服系统非线性控制. 控制与决策, 2023, 38(4): 1008 – 1014.)
- [12] YU Zhigang, SONG Shenming, DUAN Guangren, et al. Adaptive neural networks controller for robotic manipulators with unmodeled dynamics. *Chinese Journal of Scientific Instrument*, 2006, 27(6): 853 – 855.
(于志刚, 宋申民, 段广仁, 等. 具有未建模动态机械臂的自适应神经网络控制. 仪器仪表学报, 2006, 27(6): 853 – 855.)
- [13] YANG Yan, LIU Yunpeng, HAN Jiangtao, et al. Modeling and neural network control of a soft manipulator. *Chinese Journal of Engineering*, 2023, 45(3): 454 – 464.
(杨妍, 刘运鹏, 韩江涛, 等. 软体机械臂的建模与神经网络控制. 工程科学学报, 2023, 45(3): 454 – 464.)
- [14] HU J B, ZHANG D, WU Z G, et al. Neural network-based adaptive second-order sliding mode control for uncertain manipulator systems with input saturation. *ISA Transactions*, 2023, 136: 126 – 138.
- [15] LEONG T K, SARATCHANDRAN P, SUNDARARAJAN N. Real-time performance revaluation of the miniman radial basis function network for identification of time-varying nonlinear systems. *Computers and Electrical Engineering*, 2002, 28(2): 103 – 117.
- [16] HUANG Dengfeng, CHEN Li. Inverse kinematic control of free-floating space manipulator systemBasedona mutual mapping neural network. *Chinese Journal of Applied Mechanics*, 2009, 26(2): 253 – 258, 404 – 405.
(黄登峰, 陈力. 漂浮基空间机械臂基于双向映射神经元网络的逆运动学控制. 应用力学学报, 2009, 26(2): 253 – 258, 404 – 405.)
- [17] LIAO Liefa, YANG Yiguo. Adaptive radial basis function neural network bi-quadratic functional optimal control for manipulators. *Control Theory & Applications*, 2020, 37(1): 47 – 58.
(廖列法, 杨翌虢. 机械臂的自适应径向基函数神经网络双二次泛函最优控制. 控制理论与应用, 2020, 37(1): 47 – 58.)
- [18] CHEN Jun, JIANG Weidong. Trajectory tracking control method of manipulator based on improved rbf neural network. *Machinery Design & Manufacture*, 2022, (12): 269 – 272.
(陈军, 姜卫东. 改进RBF神经网络的机械臂轨迹跟踪控制方法. 机械设计与制造, 2022, (12): 269 – 272.)
- [19] WANG Lei, ZHOU Guoxing, WU Qidi. Artificial neural network theory application in control field. *Journal of Tongji University*, 2001, 29(3): 357 – 361.
(汪镭, 周国兴, 吴启迪. 人工神经网络理论在控制领域中的应用综述. 同济大学学报(自然科学版), 2001, 29(3): 357 – 361.)
- [20] HU Xiaoping, ZHANG Wenhui, JI Xiaoming. Inverse-model control for free-floating space flexible robotic manipulator based on neural network. *China Mechanical Engineering*, 2013, 24(8): 1023 – 1028.
(胡小平, 张文辉, 季晓明. 漂浮基空间柔性机械臂基于神经网络的逆模控制. 中国机械工程, 2013, 24(8): 1023 – 1028.)
- [21] MA Hang, YANG Junyou, MA Fei. Survey on neural-network based inverse control theory research. *Control Engineering of China*, 2005, 12(S1): 76 – 78.
(马航, 杨俊友, 马飞. 基于神经网络的逆控制研究综述. 控制工程, 2005, 12(S1): 76 – 78.)
- [22] TAN T, CHEN J. Model predictive and inversive control for state transition of dynamics systems. *Advances in Astronautics Science and Technology*, 2022, 52(2): 135 – 140.

作者简介:

- 谭天乐** 研究员, 研究领域方向为航天智能控制, Email: 18616017107@163.com;
- 张万超** 工程师, 研究方向为飞行器智能飞行控制, Email: zhang_wanchao@foxmail.com;
- 何永宁** 助理工程师, 研究方向为飞行器智能飞行控制, Email: 15611776036@163.com;
- 周恒杰** 助理工程师, 研究方向为空间智能驱动研究, Email: 18340854685@163.com.