

考虑量化和通信受限的有限时间确定学习控制及其应用

王冠, 夏红伟[†]

(哈尔滨工业大学 航天学院, 黑龙江 哈尔滨 150001)

摘要: 本文针对一类含有量化输入和外部扰动的严格反馈非线性系统, 提出了一种考虑量化和通信受限的有限时间确定学习控制方法. 该方法包含离线学习训练和在线触发控制两个阶段. 首先, 在离线学习训练阶段采用神经网络对系统中的未知非线性函数进行逼近, 引入指令滤波反步技术克服“计算爆炸”的问题, 并在控制过程中实现系统未知动态的知识获取和存储. 随后, 利用所获取的经验知识, 设计了基于确定学习机制的在线触发控制器. 应用李雅普诺夫稳定性理论证明了闭环系统实际有限时间稳定, 跟踪误差在有限时间内收敛到原点的邻域内, 并能够排除采样中的芝诺现象. 最后, 通过飞行器仿真验证了所提方案的有效性.

关键词: 确定学习; 量化控制; 神经网络; 有限时间收敛; 事件触发

引用格式: 王冠, 夏红伟. 考虑量化和通信受限的有限时间确定学习控制及其应用. 控制理论与应用, 2024, 41(4): 649–657

DOI: 10.7641/CTA.2023.20453

Finite-time deterministic learning control considering quantization and communication constraints with its application

WANG Guan, XIA Hong-wei[†]

(School of Astronautics, Harbin Institute of Technology, Harbin Heilongjiang 150001, China)

Abstract: This paper proposes a finite-time deterministic learning control considering quantization and communication constraints for a class of strictly feedback nonlinear systems with quantized input and external disturbances. The method includes two stages: offline learning training and online triggered control. First, the neural network technique is used to approximate the unknown nonlinear function during the offline learning training stage. The command filter backstepping technique is introduced to overcome the problem of “computational explosion”. As a result, the unknown dynamic knowledge of the system is acquired and stored in the control process. Then, an online triggered controller based on deterministic learning mechanism is designed using the obtained empirical knowledge. The Lyapunov stability theory is employed to prove that the closed-loop system is practically finite-time stable, and the tracking error converges to the neighborhood of the origin in finite time. Finally, the effectiveness of the proposed scheme is verified by aircraft simulation.

Key words: deterministic learning; quantized control; neural network; finite-time convergence; event-triggered

Citation: WANG Guan, XIA Hongwei. Finite-time deterministic learning control considering quantization and communication constraints with its application. *Control Theory & Applications*, 2024, 41(4): 649–657

1 引言

量化控制在控制系统中有着重要的理论和实际意义. 通过量化器把连续信号转换为取值在有限集的分段信号, 尤其对于飞行器、机械臂、移动机器人、无人船等复杂非线性系统而言, 能够极大地降低信号传输频率, 提高网络资源的有效利用率. 因此, 非线性系统的量化控制问题具有十分重要的研究价值^[1].

近年来, 非线性量化控制领域的分析与设计受到人们的广泛关注, 并取得了一些卓有成效的成果. 文

献[2]研究了具有量化输入的自适应控制问题, 但其非线性函数需要满足全局Lipschitz条件. 文献[3]提出一种新颖的自适应反步法用于解决非线性系统的输出反馈量化控制问题, 消除了文献[2]中所需的Lipschitz条件. 文献[4]利用函数平移的方法, 提出了对数量化反馈控制器, 实现了稳定和渐近稳定两种控制目标. 然而, 上述研究大多数只是确保闭环系统的状态有界或渐近收敛到零. 与渐近稳定相比, 有限时间稳定具有收敛速度更快、精度更高、抗干扰能力强等优势^[5].

收稿日期: 2022–05–29; 录用日期: 2023–05–12.

[†]通信作者. E-mail: hxia@hit.edu.cn; Tel.: +86 451-86402350.

本文责任编辑: 王卓.

国家自然科学基金项目(61304108), 国家重点研发计划项目(2020YFC2200600)资助.

Supported by the National Natural Science Foundation of China (61304108) and the National Key R & D Program of China (2020YFC2200600).

对此,文献[6]通过结合神经网络和反步控制设计了一种输出反馈量化控制器,可以实现量化系统的半全局实际有限时间稳定.考虑了执行器失效的情形,文献[7]设计了有限时间自适应控制器,并确保了量化系统的全局稳定.需要指出的是,上述论文广泛采用了反步控制方法,其设计过程缺少对虚拟控制器反复微分引起的“计算爆炸”问题的考虑.为了解决这个问题,文献[8]通过指令滤波器设计了基于神经网络的有限时间自适应控制器,但由于采用Levant微分器逼近虚拟控制器在有限时间内的导数,理论上需要保证虚拟控制器的 n 阶导数存在并有界.为了避免上述限制给控制器设计带来的不便,文献[9]构建了一个改进的误差补偿系统,通过在线调节系统参数,可以实现误差补偿系统的有限时间稳定,但是其研究的系统模型相对简单,忽略了未知动态和外界扰动的影响.总体而言,如何通过有限时间学习控制解决含有未知动态和外界扰动的非线性量化系统,目前相关的研究结果较少.

可以看出,上述处理非线性量化控制的方法主要集中于自适应控制和神经网络技术.其中,自适应控制能够较好地处理模型参数不确定性问题,但可能需要引入大量的参数更新律,进而增加了算法结构和参数整定的复杂度^[2-3,7,9].与此同时,神经网络控制同样是当前处理模型参数不确定性问题的常用方法^[6,8].值得指出的是,现有的神经网络控制技术强烈依赖于神经网络的更新规律,学习能力比较有限.特别地,在相同或相似的控制任务中仍然需要对神经网络进行重复的调整和训练,因此不利于将所设计的控制器进行实际应用.由此可以看出,如何在非线性系统的神经网络控制过程中实现未知动态的学习变得尤为重要.实现这一目标的关键在于不断改进神经网络的结构和算法,提高其对未知动态的自适应学习能力和鲁棒性.在此基础上,还需要采用一些有效的方法和技术手段,如深度强化学习、确定学习等,以提高神经网络控制器对未知动态的适应性和稳定性.与传统控制方法相比,确定学习能够实现未知动态的知识获取以及存储利用,并用于解决许多面向实际的控制与学习问题^[10-12].考虑到现有计算能力、可靠性等因素都一定程度上限制着自适应和神经网络控制的实际落地应用,而将确定学习思想引入非线性量化控制设计中,在减轻线上控制计算负担方面具有极大潜力.

然而,上述控制器在追求控制性能和收敛速度的同时,往往采用传统的时间触发方式经通信通道传输大量的数据,可能会造成信道过载并导致巨大的资源浪费.此外,由于通信带宽和系统资源有限,系统各组件之间的持续通信势必受到限制.因此,如何有效使用计算和通信资源在控制系统设计中具有重要意义.针对这个问题,研究人员提出事件触发机制用于充分

利用有限的通信资源^[13].其思想是设计者可以根据实际需求将信号在必要的时候进行非周期的传输,同时实现可靠性较高的控制需求.文献[14]研究了不确定非线性系统的自适应事件触发跟踪控制问题,并设计了3种触发方案.文献[15]提出了一种基于模糊观测器和混合事件触发策略的鲁棒自适应事件触发算法.文献[16]针对一类非线性网络互连系统,设计了分布式自适应事件触发 H_∞ 滤波控制器.但是,上述方法不能应用于解决具有量化输入和外界扰动的非线性系统有限时间跟踪控制问题.

基于上述讨论,本文提出了一种考虑量化和通信受限的有限时间确定学习控制方法.该控制方法设计分为两个步骤:离线学习训练阶段和在线触发控制阶段.在第1步中,本文在具有充足通信资源的离线控制测试端,通过利用高斯径向基(radial basis function, RBF)网络设计神经自适应控制器,实现对未知系统动态的知识获取以及存储.在第2步中,对于在线远程控制阶段,利用存储的系统未知动态经验知识,构建基于事件触发机制的有限时间量化控制器.随后,结合李雅普诺夫稳定性理论验证闭环系统所有信号的实际有限时间稳定,同时能够保证系统的跟踪性能.

本文的主要贡献在于如下几方面:

- 1) 利用确定学习思想来解决非线性量化控制问题,通过离线学习训练获得系统的未知动态知识,利用有效的经验知识进行在线控制方案设计,大大降低了在线应用的实际计算量;
- 2) 所提出的控制方法不仅避免了“计算爆炸”问题,而且实现了有限时间内对滤波误差的补偿,保证了系统性能;
- 3) 引入事件触发机制,以更少的触发次数节省了通信资源.通过高超声速飞行器的飞行控制案例验证了所设计方法,有效降低了传感器-控制器信道之间的数据通信负载.

2 系统描述与预备知识

2.1 系统描述

考虑如下含有量化输入的严格反馈非线性系统:

$$\begin{cases} \dot{x}_i = g_i x_{i+1} + f_i(\bar{x}_i) + d_i(\bar{x}_i, t), \\ \dot{x}_n = g_n q(u) + f_n(\bar{x}_n) + d_n(\bar{x}_n, t), \\ y = x_1, \end{cases} \quad (1)$$

式中: $f_i(\bar{x}_i)$ 和 $f_n(\bar{x}_n) \in \mathbb{R}$, $i = 1, \dots, n-1$ 是未知的非线性函数; $\bar{x}_i = [x_1 \cdots x_i]^T \in \mathbb{R}^i$, $i = 1, \dots, n$ 是系统状态向量; g_i 和 $g_n \in \mathbb{R}$ 是已知的常量系数; $y \in \mathbb{R}$ 是系统输出; $u \in \mathbb{R}$ 是系统控制输入, $q(u) \in \mathbb{R}$ 代表量化输入; $d_i(\bar{x}_i, t)$ 和 $d_n(\bar{x}_n, t) \in \mathbb{R}$ 代表外界扰动.

为避免量化信号的快速切换及抖振问题,本文选

取如下迟滞量化器^[6]:

$$q(u) = \begin{cases} u_i \operatorname{sgn}(u), & \frac{u_i}{1+\delta} < |u| \leq u_i, \dot{u} < 0, \\ & \text{或 } u_i < |u| \leq \frac{u_i}{1-\delta}, \dot{u} > 0, \\ u_i(1+\delta)\operatorname{sgn}(u), & \\ u_i < |u| \leq \frac{u_i}{1-\delta}, \dot{u} < 0, & \\ \text{或 } \frac{u_i}{1-\delta} < |u| \leq \frac{u_i(1+\delta)}{1-\delta}, \dot{u} > 0, & \\ 0, & 0 < |u| \leq \frac{u_{\min}}{1+\delta}, \dot{u} < 0, \\ \text{或 } \frac{u_{\min}}{1+\delta} < |u| \leq u_{\min}, \dot{u} > 0, & \\ q(u(t^-)), & \dot{u} = 0, \end{cases} \quad (2)$$

式中: $u_{\min} > 0, 0 < \rho < 1, \delta = \frac{1-\rho}{1+\rho}, u_i = \rho^{1-i} u_{\min}$ ($i = 1, 2, \dots$), $\operatorname{sgn}(\cdot)$ 为符号函数. 根据文献[17], 量化输入 $q(u)$ 可以描述为

$$q(u) = b_1 u + b_2, \quad (3)$$

且满足 $1 - \delta \leq b_1 \leq 1 + \delta$ 和 $|b_2| \leq u_{\min}$.

2.2 预备知识

下面的假设、定义及引理对本文中控制器设计起了重要作用.

假设 1^[9] $d_i(\bar{x}_i, t)$ 表示系统受到的外界扰动, 满足 $|d_i(\bar{x}_i, t)| \leq \bar{d}_i$, 其中 \bar{d}_i 为未知正常数.

假设 2^[9] 量化器的参数已知, 即 ρ 和 u_{\min} 是已知的.

假设 3^[12] 非线性函数 g_i 的符号是已知的, 且满足 $\underline{g}_i \leq g_i \leq \bar{g}_i$, 其中 \underline{g}_i 和 \bar{g}_i 是正常数.

引理 1^[18] 对于紧集 $\Omega \in \mathbb{R}$ 上的未知平滑非线性函数 $f_i(\bar{x}_i)$, 可利用RBF神经网络系统进行逼近, 表示为

$$f_i(\bar{x}_i) = \omega_i^{*\top} \theta_i(\bar{x}_i) + \varepsilon_i^*(\bar{x}_i), \quad (4)$$

式中: $\omega_i^* \in \mathbb{R}^l$ 为最优权重向量, $l > 1$; $\varepsilon_i^*(\bar{x}_i)$ 为神经网络逼近误差, 满足 $|\varepsilon_i^*| \leq \varepsilon_{im}^*$, 其中 $\varepsilon_{im}^* > 0$ 为逼近误差上界; $\theta_i(\bar{x}_i) = [\theta_{i1}(\bar{x}_i) \theta_{i2}(\bar{x}_i) \cdots \theta_{il}(\bar{x}_i)]^\top$ 为平滑向量, 选择高斯函数作为径向基函数, 表达式为

$$\theta_{ij}(\bar{x}_i) = \frac{1}{\sqrt{2\pi}\bar{\delta}_j} e^{-\frac{(\bar{x}_i - \bar{\varepsilon}_j)^\top (\bar{x}_i - \bar{\varepsilon}_j)}{2\bar{\delta}_j^2}}, \quad (5)$$

式中: $j = 1, 2, \dots, l, \bar{\varepsilon}_j = [\varepsilon_{j1} \varepsilon_{j2} \cdots \varepsilon_{ji}]^\top$ 为吸引域中心; $\bar{\delta}_j$ 为高斯函数的标准差.

引理 2^[10] 未知动态 $f_i(\bar{x}_i)$ 能够被沿着回归参考信号 $\bar{x}_i(t)$ 的常值神经网络 $\bar{\omega}_i^\top \theta_i(\bar{x}_i)$ 局部逼近, 其表达为

$$f_i(\bar{x}_i) = \bar{\omega}_i^\top \theta_i(\bar{x}_i) + \varepsilon_i(\bar{x}_i), \quad (6)$$

式中: ε_i 为神经网络逼近误差, 满足 $|\varepsilon_i| \leq \varepsilon_{im}$, 其中

$\varepsilon_{im} > 0$ 为逼近误差上界; 且常值神经网络权值表示为

$$\bar{\omega}_i = \operatorname{mean}_{t \in [t_a, t_b]} \hat{\omega}_i(t) = \frac{1}{t_b - t_a} \int_{t_a}^{t_b} \hat{\omega}_i(s) ds, \quad (7)$$

式中: $t_b > t_a > T, [t_a, t_b]$ 为系统稳态后的时间段.

定义 1^[5] 考虑非线性系统 $\dot{x} = f(x)$, 对于平衡点 $f(0) = 0$ 附近邻域 U 出发的任意初始状态 $x(t_0)$, 若存在正实数 δ 及有限时间 $T_f(\delta, x(t_0))$ 满足 $\lim_{t \rightarrow T_f(\delta, x(t_0))} \|x(t)\| < \delta$, 则称系统实际有限时间稳定.

引理 3^[9] 考虑非线性系统 $\dot{x} = f(x)$, 如果存在连续正定函数 $\mathcal{V}(x)$ 满足如下不等式:

$$\dot{\mathcal{V}}(x) \leq -c_1 \mathcal{V}(x) - c_2 \mathcal{V}^\mu(x) + c_0, \quad (8)$$

式中 $c_1 > 0, c_2 > 0, 0 < \mu < 1, 0 < c_0 < \infty$ 均为常数. 根据定义1, 系统是实际有限时间稳定的, 其解集定义如下:

$$x \in \left\{ \lim_{t \rightarrow T_{f1}} \mathcal{V}(x) \leq \min \left\{ \frac{c_0}{(1-\pi_0)c_1}, \left(\frac{c_0}{(1-\pi_0)c_2} \right)^{\frac{1}{\mu}} \right\} \right\}, \quad (9)$$

式中 $0 < \pi_0 < 1$. 稳定时间可表示为以下形式:

$$T_{f1} \leq \max \left\{ t_0 + \frac{1}{\pi_0 c_1 (1-\mu)} \ln \frac{\pi_0 c_1 \mathcal{V}^{1-\mu}(t_0) + c_2}{c_2}, t_0 + \frac{1}{c_1 (1-\mu)} \ln \frac{c_1 \mathcal{V}^{1-\mu}(t_0) + \pi_0 c_2}{\pi_0 c_2} \right\}.$$

引理 4^[19] 考虑如下标量系统:

$$\dot{y} = -a [y]^{w_1} - b [y]^{w_2}, y(0) = y_0, \quad (10)$$

式中: $a > 0, b > 0, 0 < w_1 < 1, w_2 > 1$, 均为正常数; $[\cdot]^{w_1} = (\cdot)^{w_1} \operatorname{sgn}(\cdot), [\cdot]^{w_2} = (\cdot)^{w_2} \operatorname{sgn}(\cdot)$. 那么, 系统(10)的原点是固定时间稳定的, 其稳定时间可表示为

$$T_{f2} \leq \frac{1}{b} \frac{1}{\omega_2 - 1} + \frac{1}{a} \frac{1}{1 - \omega_1}.$$

引理 5^[20] 考虑非线性系统 $\dot{x} = f(x)$, 若存在连续正定函数 $\mathcal{V}(x)$ 满足如下不等式:

$$\dot{\mathcal{V}}(x) \leq -c_1 \mathcal{V}(x) - c_2 \mathcal{V}^\mu(x), \quad (11)$$

式中 $c_1 > 0, c_2 > 0, 0 < \mu < 1$ 均为常数. 系统轨迹是有限时间稳定的, 其稳定时间可表示为以下形式:

$$T_{f3} \leq t_0 + \frac{1}{c_1 (1-\mu)} \ln \frac{c_1 \mathcal{V}^{1-\mu}(t_0) + c_2}{c_2}.$$

引理 6^[21] 对于任意实数 x 和正实数 v , 下面不等式成立:

$$0 < |x| - x \tanh \frac{x}{v} \leq \kappa v, \quad (12)$$

式中 $\kappa \approx 0.2785$.

本文的控制目标是在考虑量化和通信资源受限的情况下, 设计基于事件触发的有限时间确定学习控制方案, 使得系统(1)的输出 y 在有限时间内跟踪给定的

参考轨迹 y_d , 并节省通信资源和降低算法的计算量。

3 控制器设计

本节给出了有限时间确定学习控制方案的设计过程, 如图1所示. 在离线学习训练阶段, 首先通过构造神经自适应控制器使得系统输出能够紧密地跟踪参考轨迹; 然后进行离线神经网络训练, 利用确定学习机制获取系统动态的权值知识并进行存储. 对于在线触发控制阶段, 调用已存储的未知动态权值经验知识, 通过引入固定时间滤波器和有限时间补偿系统, 避免“计算爆炸”并对滤波误差进行补偿, 最后构造基于经验知识的在线触发控制器。

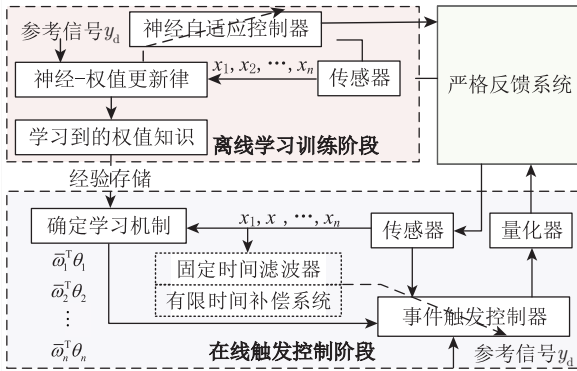


图1 有限时间确定学习控制框图

Fig. 1 The control framework of the finite-time deterministic learning control

3.1 离线学习控制的知识获取以及存储

在具有充足通信资源的离线学习训练阶段, 利用RBF神经网络设计神经自适应控制器获取系统动态的知识. 下面给出控制器的设计过程。

第 i 步 ($1 \leq i < n$) 定义误差为 $z_i = x_i - x_i^d$, 其中 $x_1^d = y_d$. 根据式(1)并利用RBF神经网络逼近未知动态(4), 即 $f_i(\bar{x}_i) = \omega_i^{*T} \theta_i(\bar{x}_i) + \varepsilon_i^*(\bar{x}_i)$, 可将 z_i 的导数表示为

$$\dot{z}_i = g_i x_{i+1} + \omega_i^{*T} \theta_i(\bar{x}_i) + \varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t) - \dot{x}_i^d, \quad (13)$$

式中 $\varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t)$ 视为扰动项集总. 根据假设1以及引理1, 该项存在上界, 即 $|\varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t)| \leq D_i$, D_i 为未知正常数。

考虑到传统反步法设计过程中的“计算爆炸”问题, 定义 $z_{i+1} = x_{i+1} - x_{i+1}^d$, 其中新的状态变量 x_{i+1}^d 由待设计的虚拟控制信号 x_{i+1}^c 通过如下的一阶滤波器获得:

$$\eta_i \dot{x}_{i+1}^d = x_{i+1}^d - x_{i+1}^c, \quad x_{i+1}^d(0) = x_{i+1}^c(0), \quad (14)$$

式中 $\eta_i > 0$ 是待设计的参数。

为补偿指令滤波引入的误差 $x_{i+1}^d - x_{i+1}^c$, 对于 $i = 1, \dots, n-1$, 设计补偿信号为

$$\begin{cases} \dot{\lambda}_1 = -k_1 \lambda_1 + g_1 \lambda_2 + g_1 (x_2^d - x_2^c), \\ \dot{\lambda}_i = -k_i \lambda_i - g_{i-1} \lambda_{i-1} + g_i \lambda_{i+1} + \\ g_i (x_{i+1}^d - x_{i+1}^c), \quad \lambda_i(0) = 0. \end{cases} \quad (15)$$

定义经补偿的跟踪误差 $e_i = z_i - \lambda_i$, 神经网络权值的估计误差 $\tilde{\omega}_i = \omega_i^* - \hat{\omega}_i$, 然后设计Lyapunov函数 $\mathcal{V}_1 = \frac{1}{2} e_1^2 + \frac{1}{2\tau_1} \tilde{\omega}_1^T \tilde{\omega}_1$ ($\tau_1 > 0$)为正常数, 其导数可表示为

$$\begin{aligned} \dot{\mathcal{V}}_1 = & e_1 (g_1 (e_2 + x_2^c) + \hat{\omega}_1^T \theta_1(\bar{x}_1) + \tilde{\omega}_1^T \theta_1(\bar{x}_1) + \\ & k_1 \lambda_1 + \varepsilon_1^*(\bar{x}_1) + d_1(\bar{x}_1, t) - \dot{x}_1^d) - \frac{1}{\tau_1} \tilde{\omega}_1^T \dot{\tilde{\omega}}_1. \end{aligned} \quad (16)$$

因此, 设计虚拟控制律及更新律为

$$\begin{cases} x_2^c = g_1^{-1} (-k_1 z_1 + \dot{x}_1^d - \hat{\omega}_1^T \theta_1(\bar{x}_1) - l_1 \text{sgn}(e_1)), \\ \dot{\hat{\omega}}_1 = \tau_1 (e_1 \theta_1(\bar{x}_1) - \sigma_1 \hat{\omega}_1), \end{cases} \quad (17)$$

式中 $k_1, l_1, \sigma_1 > 0$ 为待设计的参数。

相似地, 对于 $1 < i < n$, 设计Lyapunov函数 $\mathcal{V}_i = \frac{1}{2} e_i^2 + \frac{1}{2\tau_i} \tilde{\omega}_i^T \tilde{\omega}_i$ ($\tau_i > 0$), 其导数可表示为

$$\begin{aligned} \dot{\mathcal{V}}_i = & e_i (g_i (e_{i+1} + x_{i+1}^c) + g_{i-1} \lambda_{i-1} + k_i \lambda_i + \\ & \hat{\omega}_i^T \theta_i(\bar{x}_i) + \tilde{\omega}_i^T \theta_i(\bar{x}_i) + \varepsilon_i^*(\bar{x}_i) + \\ & d_i(\bar{x}_i, t) - \dot{x}_i^d) - \frac{1}{\tau_i} \tilde{\omega}_i^T \dot{\tilde{\omega}}_i, \end{aligned} \quad (18)$$

因此, 设计虚拟控制律及更新律为

$$\begin{cases} x_{i+1}^c = g_i^{-1} (-k_i z_i + \dot{x}_i^d - g_{i-1} z_{i-1} - \\ \hat{\omega}_i^T \theta_i(\bar{x}_i) - l_i \text{sgn}(e_i)), \\ \dot{\hat{\omega}}_i = \tau_i (e_i \theta_i(\bar{x}_i) - \sigma_i \hat{\omega}_i), \end{cases} \quad (19)$$

式中 $k_i, l_i, \sigma_i > 0$ 为待设计的参数。

第 n 步 定义误差为 $z_n = x_n - x_n^d$. 结合式(1), 为方便离线训练, 本小节不考虑量化输入, 利用RBF神经网络逼近未知动态, 即 $f_n(\bar{x}_n) = \omega_n^{*T} \theta_n(\bar{x}_n) + \varepsilon_n^*(\bar{x}_n)$, 可以得到

$$\dot{z}_n = g_n u + \omega_n^{*T} \theta_n(\bar{x}_n) + \varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t) - \dot{x}_n^d, \quad (20)$$

式中 $\varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t)$ 视为扰动项集总. 根据假设1以及引理1, 该项存在上界, 即 $|\varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t)| \leq D_n$, D_n 为未知正常数。

设计补偿信号 $\dot{\lambda}_n = -k_n \lambda_n - g_{n-1} \lambda_{n-1}$, $\lambda_n(0) = 0$. 定义经补偿的跟踪误差 $e_n = z_n - \lambda_n$, 神经网络权值的估计误差 $\tilde{\omega}_n = \omega_n^* - \hat{\omega}_n$, 设计Lyapunov函数

$$\mathcal{V}_n = \frac{1}{2} e_n^2 + \frac{1}{2\tau_n} \tilde{\omega}_n^T \tilde{\omega}_n \quad (\tau_n > 0), \quad \text{其导数可表示为}$$

$$\begin{aligned} \dot{\mathcal{V}}_n = & e_n (g_n u + k_n \lambda_n + g_{n-1} \lambda_{n-1} + \\ & \hat{\omega}_n^T \theta_n(\bar{x}_n) + \tilde{\omega}_n^T \theta_n(\bar{x}_n) + \varepsilon_n^*(\bar{x}_n) + \end{aligned}$$

$$d_n(\bar{x}_n, t) - \dot{x}_n^d - \frac{1}{\tau_n} \tilde{\omega}_n^T \dot{\omega}_n, \quad (21)$$

因此, 设计控制律 $u(t)$ 及更新律为

$$\begin{cases} u(t) = g_n^{-1}(-k_n z_n + \dot{x}_n^d - g_{n-1} z_{n-1} - \\ \tilde{\omega}_n^T \theta_n(\bar{x}_n) - l_n \operatorname{sgn}(e_n)), \\ \dot{\hat{\omega}}_n = \tau_n(e_n \theta_n(\bar{x}_n) - \sigma_n \hat{\omega}_n), \end{cases} \quad (22)$$

式中 $k_n, l_n, \sigma_n > 0$ 为待设计的参数。

最后, 选取 Lyapunov 函数 $\mathcal{V}_A = \sum_{i=1}^n \mathcal{V}_i$, 结合误差动态 (16)(18)(21) 和控制律 (17)(19)(22), 可将 \mathcal{V}_A 的导数表示为

$$\begin{aligned} \dot{\mathcal{V}}_A = & -\sum_n k_i e_i^2 - \sum_n \frac{\sigma_i}{2} \|\tilde{\omega}_i\|^2 + \sum_n \frac{\sigma_i}{2} \|\omega_i^*\|^2 + \\ & \sum_n |e_i|(D_i - l_i), \end{aligned} \quad (23)$$

可以看出, 通过选取适当的参数 $l_i > D_i$, 即可使得 $\dot{\mathcal{V}}_A \leq -a_A \mathcal{V}_A + b_A$, 其中 $a_A = \min\{2k_i, \tau_i \sigma_i\}, i = 1, \dots, n; b_A = \sum_n \frac{\sigma_i}{2} |\omega_i^*|^2$, 因此, 所设计的控制器使得闭环系统满足最终一致有界稳定条件。

以上完成了神经自适应控制的推导. 根据引理 2, 为了实现离线学习阶段的知识获取以及存储, 需要在稳定的控制过程中获取神经网络真正的学习能力. 随后, 获得的经验知识将以常值神经网络的方式存储, 其中常值神经网络权值向量可通过式(7)计算获得. 利用存储的知识 $\tilde{\omega}^T \theta(\bar{x})$, 构造基于经验的在线触发控制器以实现良好的控制性能. 基于文献[10, 12]的研究, 为了实现确定学习的目标, 回归子向量 $\theta(\bar{x})$ 需符合部分持续激励条件, 这是影响神经网络权值能否精确收敛的重要因素. 结合引理 2, 训练过程采用周期信号 y_d 以满足所需激励条件.

3.2 利用存储的经验知识构造在线触发控制器

为了减轻远程在线控制阶段的在线计算负担, 本小节调用存储的系统未知动态权值经验知识, 结合固定时间滤波器和有限时间补偿系统, 构造基于经验知识的在线触发量化控制器, 在保证控制性能的同时降低通信资源的占用。

结合式(1)(3), 考虑量化输入和已存储的经验知识, 可将式(20)改写为

$$\begin{cases} \dot{z}_i = g_i x_{i+1} + \tilde{\omega}_i^T \theta_i(\bar{x}_i) + \varepsilon_i^*(\bar{x}_i) + \\ d_i(\bar{x}_i, t) - \dot{x}_i^d, \quad i = 1, 2, \dots, n-1, \\ \dot{z}_n = g_n b_1 u + g_n b_2 + \tilde{\omega}_n^T \theta_n(\bar{x}_n) + \\ \varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t) - \dot{x}_n^d, \end{cases} \quad (24)$$

式中 $\tilde{\omega}_i$ 是离线训练获得的常值神经网络权值向量。

受文献[22]启发, 采用如下的固定时间指令滤波器:

$$\begin{cases} \eta_{fi} \dot{x}_{i+1}^d = [x_{i+1}^d - x_{i+1}^c]^{w_1} + [x_{i+1}^d - x_{i+1}^c]^{w_2}, \\ x_{i+1}^d(0) = x_{i+1}^c(0), \end{cases} \quad (25)$$

式中 $\eta_{fi} > 0, 0 < w_1 < 1, w_2 > 1$ 是滤波器的重要参数, 其选取将影响滤波器的收敛速度. $[\cdot]^{w_1} = (\cdot)^{w_1} \times \operatorname{sgn}(\cdot), [\cdot]^{w_2} = (\cdot)^{w_2} \operatorname{sgn}(\cdot)$. 参考文献[19]并结合引理 4, 滤波误差 $x_{i+1}^d - x_{i+1}^c$ 在固定时间内有界, 并可知在固定时间 T_{f2} 时能实现 $|x_{i+1}^d - x_{i+1}^c| \leq \mathcal{E}_i, \mathcal{E}_i$ 为未知正常数。

为方便后续控制器设计, 给出如下假设。

假设 4^[22] 固定时间滤波器的输入信号的导数 \dot{x}_{i+1}^c 是连续的, 且存在未知上界。

注 1 离线学习部分采用了传统一阶滤波器, 在使用中通常调节较小的时间常数以加快收敛速度, 并减小跟踪误差, 但同时会引入高频噪声. 相比之下, 本文所采用的固定时间滤波器无需较小的时间常数即可实现快收敛速度和高跟踪精度^[19]。

为补偿指令滤波引入的误差 $x_{i+1}^d - x_{i+1}^c$, 设计如下补偿信号:

$$\begin{cases} \dot{\lambda}_1 = -k_1 \lambda_1 + g_1 \lambda_2 + g_1 (x_2^d - x_2^c) - p_1 \operatorname{sgn}(\lambda_1), \\ \dot{\lambda}_i = -k_i \lambda_i - g_{i-1} \lambda_{i-1} + g_i \lambda_{i+1} + \\ g_i (x_{i+1}^d - x_{i+1}^c) - p_i \operatorname{sgn}(\lambda_i), \\ \dot{\lambda}_n = -k_n \lambda_n - g_{n-1} \lambda_{n-1} - p_n \operatorname{sgn}(\lambda_n), \end{cases} \quad (26)$$

式中: $p_i > 0$ 为待设计的参数, $\lambda_i(0) = 0$ 。

随后, 设计虚拟控制律及更新律设计为

$$\begin{cases} x_2^c = g_1^{-1}(-k_1 z_1 + \dot{x}_1^d - \tilde{\omega}_1^T \theta_1(\bar{x}_1) - \\ \hat{D}_1 \tanh(\frac{e_1 \hat{D}_1}{v_1}) - s_1 e_1^{\mu_0}), \\ x_{i+1}^c = g_i^{-1}(-k_i z_i + \dot{x}_i^d - \tilde{\omega}_i^T \theta_i(\bar{x}_i) - \\ g_{i-1} z_{i-1} - \hat{D}_i \tanh(\frac{e_i \hat{D}_i}{v_i}) - s_i e_i^{\mu_0}), \\ \hat{D}_i = \rho_i (|e_i| - \iota_i \hat{D}_i), \quad i = 1, 2, \dots, n-1, \end{cases} \quad (27)$$

式中 $k_i > 0, v_i > 0, s_i > 0, \rho_i > 0, \iota_i > 0$ 为待设计的参数. 根据假设 1-2 以及引理 1, 扰动项集总 $\varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t)$ 存在上界, 即 $|\varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t)| \leq D_i, \hat{D}_i$ 是对 D_i 的估计. μ_0 是正常数, 且满足 $0 < \mu_0 = \frac{\mu_1}{\mu_2} < 1$, 其中 μ_1 和 μ_2 是奇数。

设计控制律 $\varphi(t)$ 及更新律为

$$\begin{cases} \varphi(t) = -\operatorname{sgn}(g_n) \varpi \left(\frac{\Lambda}{b_0} \tanh \frac{e_n \Lambda}{v_n} + \right. \\ \left. \Xi \tanh \frac{e_n \Xi}{v_n} \right), \\ \Lambda = g_n^{-1}(-k_n z_n - g_{n-1} z_{n-1} - \tilde{\omega}_n^T \theta_n(\bar{x}_n) + \\ \dot{x}_n^d - \hat{D}_n \tanh \frac{e_n \hat{D}_n}{v_n} - s_n e_n^{\mu_0}), \\ \hat{D}_n = \rho_n (|e_n| - \iota_n \hat{D}_n), \end{cases} \quad (28)$$

式中: $k_n > 0, v_n > 0, s_n > 0, \rho_n > 0, \iota_n > 0, \Xi > \frac{m_2}{1-m_1}$ 为待设计的参数; $\varpi = 1 + m_1, b_0 = 1 - \delta$, 则有 $b_0 < b_1; \bar{\omega}_n$ 是经离线训练获得的常值神经网络权值向量. 根据假设1-2以及引理1, 扰动项集总 $g_n b_2 + \varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t)$ 存在上界, 即 $|g_n b_2 + \varepsilon_n^*(\bar{x}_n) + d_n(\bar{x}_n, t)| \leq D_n, \hat{D}_n$ 是对 D_n 的估计.

设计触发事件如下:

$$\begin{cases} u(t) = \varphi(t_k), \forall t \in [t_k, t_{k+1}), \\ t_{k+1} = \inf \{t \in \mathcal{R} | |e(t)| \geq m_1 |u(t)| + m_2\}, \end{cases} \quad (29)$$

式中: $e(t) = \varphi(t) - u(t)$ 代表由触发事件引起的测量误差, $0 < m_1 < 1, m_2 > 0, \Xi > \frac{m_2}{1-m_1}$ 均为正的设计参数. $t_k, k \in \mathbb{Z}_+$ 代表事件被触发的时刻, 即每当式(29)被触发, 便把这个时刻标记为 t_{k+1} , 同时该时刻的控制信号 $u(t_{k+1})$ 作用在系统上. 在两个事件触发时刻的间隙 $t \in [t_k, t_{k+1})$, 控制信号为 $\varphi(t_k)$ 保持不变.

3.3 稳定性分析

定理 1 对于系统(1), 在迟滞量化器(2)及满足假设1-4的条件下, 设计虚拟控制器及更新律(27), 实际控制器及更新律(28)和事件触发条件(41). 通过选择适当的设计参数, 闭环系统跟踪误差在有限时间内收敛到原点附近的邻域内, 且能保证闭环系统实际有限时间稳定, 以及有限时间内对滤波误差的补偿, 并能够排除芝诺现象.

此定理的证明可以通过以下步骤形成.

证

步骤 1 首先, 选取李雅普诺夫函数为

$$\mathcal{V} = \mathcal{V}_e + \mathcal{V}_D, \quad (30)$$

式中: $\mathcal{V}_e = \sum_n \frac{1}{2} e_i^2, \mathcal{V}_D = \sum_n \frac{1}{2\rho_i} \tilde{D}_i^2$, 且 $\tilde{D}_i = D - \hat{D}_i$.

由式(29)可得, 在区间 $t \in [t_k, t_{k+1})$ 中,

$$\varphi(t) = (1 + \varsigma_1(t)m_1)u(t) + \varsigma_2(t)m_2, \quad (31)$$

式中 $\varsigma_1(t)$ 和 $\varsigma_2(t)$ 为满足 $|\varsigma_1(t)| \leq 1$ 和 $|\varsigma_2(t)| \leq 1$ 的变量. 因此可以得到

$$u(t) = \frac{\varphi(t)}{1 + \varsigma_1(t)m_1} - \frac{\varsigma_2(t)m_2}{1 + \varsigma_1(t)m_1}, \quad (32)$$

考虑到 $\forall a \in \mathbb{R}, \varepsilon > 0, -a \tanh \frac{a}{\varepsilon} \leq 0$, 则有

$$g_n b_1 e_n u \leq \frac{g_n b_1 e_n \varphi}{1 + m_1} + \frac{|g_n b_1 e_n| m_2}{1 - m_1}, \quad (33)$$

对于式(33)中的项 $\frac{g_n b_1 e_n \varphi}{1 + m_1}$, 结合式(28)和引理4可得

$$\frac{g_n b_1 e_n \varphi}{1 + m_1} \leq g_n e_n \Lambda - |g_n b_1 e_n| \Xi + 2\kappa \bar{g}_n v_n. \quad (34)$$

结合式(34)并考虑到 $\Xi > \frac{m_2}{1-m_1} > 0$, 式(33)可写成

$$g_n b_1 e_n u \leq g_n e_n \Lambda + 2\kappa \bar{g}_n v_n. \quad (35)$$

此外, 利用如下不等式:

$$\begin{cases} e_i p_i \operatorname{sgn}(\lambda_i) \leq \frac{p_i}{2} e_i^2 + \frac{p_i}{2}, \\ e_i(\varepsilon_i^*(\bar{x}_i) + d_i(\bar{x}_i, t)) \leq \\ |e_i| \tilde{D}_i + e_i \hat{D}_i \tanh\left(\frac{e_i \hat{D}_i}{v_i} + \kappa v_i\right), \\ e_n(\varepsilon_n^*(\bar{x}_n) + g_n b_2 + d_n(\bar{x}_n, t)) \leq \\ |e_n| \tilde{D}_n + e_n \hat{D}_n \tanh\left(\frac{e_n \hat{D}_n}{v_n} + \kappa v_n\right), \\ 2\tilde{D}_i \hat{D}_i \leq D_i^2 - \tilde{D}_i^2. \end{cases} \quad (36)$$

考虑对于 $\Upsilon = \frac{\iota_i}{4} \tilde{D}_i^2$, 若 $\Upsilon \geq 1$, 则 $\Upsilon^\mu - \Upsilon \leq 0$; 若 $\Upsilon < 1$, 则 $\Upsilon^\mu - \Upsilon \leq 1 - \Upsilon \leq 1$. 因此, $\Upsilon^\mu - \Upsilon \leq 1$ 恒成立. 因此, 结合式(24)(26)-(27)和式(35), 利用引理2、杨氏不等式^[21], 对式(30)求导可得

$$\begin{aligned} \dot{\mathcal{V}} \leq & -\sum_n \bar{k}_i \left(\frac{1}{2} e_i^2\right) - \sum_n \bar{l}_i \left(\frac{1}{2\rho_i} \tilde{D}_i^2\right) - \\ & \sum_n \bar{s}_i \left(\frac{1}{2} e_i^2\right)^\mu - \sum_n \bar{l}_{i\mu} \left(\frac{1}{2\rho_i} \tilde{D}_i^2\right)^\mu + \\ & \sum_n \left(\frac{\iota_i}{2} D_i^2 + \frac{p_i}{2} + \kappa v_i + 1\right) + 2\kappa \bar{g}_n v_n, \end{aligned} \quad (37)$$

式中: $\bar{k}_i = 2k_i - p_i, \bar{l}_i = \frac{1}{2} \iota_i \rho_i, \bar{s}_i = 2^\mu s_i, \bar{l}_{i\mu} = \left(\frac{1}{2} \times \iota_i \rho_i\right)^\mu$. 选取恰当的参数可使得 $\bar{k}_i > 0, \bar{l}_i > 0, \bar{s}_i > 0, \bar{l}_{i\mu} > 0$. 进而可将式(37)写为

$$\dot{\mathcal{V}} \leq -c_1 \mathcal{V} - c_2 \mathcal{V}^\mu + c_0, \quad (38)$$

式中: $c_1 = \min\{\bar{k}_i, \bar{l}_i\}, c_2 = \min\{\bar{s}_i, \bar{l}_{i\mu}\}, c_0 = \sum_n \left(\frac{\iota_i}{2} \times D_i^2 + \kappa v_i + 1\right) + 2\kappa \bar{g}_n v_n$.

根据引理3, 式(30)中的系统轨迹是实际有限时间稳定的. 对于 $0 < \pi_0 < 1$, 系统解的集合表示如下:

$$\left\{ \lim_{t \rightarrow T_{f1}} \mathcal{V} \leq \min\left\{ \frac{c_0}{(1-\pi_0)c_1}, \left(\frac{c_0}{(1-\pi_0)c_2}\right)^{\frac{1}{\mu}} \right\} \right\}, \quad (39)$$

稳定时间

$$\begin{aligned} T_{f1} \leq & \max\left\{ \frac{1}{\pi_0 c_1 (1-\mu)} \ln \frac{\pi_0 c_1 \mathcal{V}^{1-\mu}(t_0) + c_2}{c_2}, \right. \\ & \left. \frac{1}{c_1 (1-\mu)} \ln \frac{c_1 \mathcal{V}^{1-\mu}(t_0) + \pi_0 c_2}{\pi_0 c_2} \right\}. \end{aligned}$$

步骤 2 选取补偿系统的李雅普诺夫函数为

$$\bar{\mathcal{V}}_\lambda = \sum_n \frac{1}{2} \lambda_i^2, \quad (40)$$

结合式(26), 对上式进行求导, 可得

$$\dot{V}_\lambda = -\sum_n^1 k_i \lambda_i^2 - \sum_n^1 p_i |\lambda_i| + \sum_{i=1}^{n-1} g_i \lambda_i (x_{i+1}^d - x_{i+1}^c), \quad (41)$$

在引理4和假设4的条件下, 固定时间滤波器的滤波误差 $x_{i+1}^d - x_{i+1}^c$ 在固定时间内有界, 并可知在固定时间 T_{f2} 时能够实现 $|x_{i+1}^d - x_{i+1}^c| \leq \mathcal{E}_i$, \mathcal{E}_i 为未知正常数. 因此, 当 $t \geq T_{f2}$ 时, 结合 $\underline{g}_i \leq g_i \leq \bar{g}_i$ 可得

$$\dot{V}_\lambda \leq -\bar{k}_0 \bar{V}_\lambda - \bar{p}_0 \bar{V}_\lambda^{\frac{1}{2}}, \quad (42)$$

式中: $\bar{k}_0 = 2 \min(k_i)$, $\bar{p}_0 = \sqrt{2} \min(p_i) - \sqrt{2n} \bar{g}_i \cdot \max(\mathcal{E}_i)$. 选取恰当的参数可使得 $\bar{k}_0 > 0$, $\bar{p}_0 > 0$, 根据引理5, 该补偿系统能够在有限时间 T_{f3} 内稳定.

综上所述, 本文利用存储的经验知识的触发控制器能够在 $T_f \leq T_{\max} := \max\{T_{f1}, T_{f2}, T_{f3}\}$ 闭环系统实际有限时间稳定.

步骤3 最后, 将证明触发机制不会产生芝诺现象, 即能够避免有限时间内进行无限次触发事件. 为此, 只需证明存在一个常数 t^* 满足 $\forall k \in \mathbb{Z}_+, t_{k+1} - t_k \geq t^*$. 由 $e(t) = \varphi(t) - u(t)$, $\forall t \in [t_k, t_{k+1})$, 可得

$$\frac{d}{dt}|e| = \frac{d}{dt}(e \times e)^{\frac{1}{2}} = \text{sgn}(e)\dot{e} \leq |\dot{\varphi}|, \quad (43)$$

由式(28)可知, $\dot{\varphi}$ 是可微的连续函数. 同时, $\dot{\varphi}$ 是一个关于 x 和 $\dot{\omega}$ 的函数, 这些变量都是全局有界的, 因而一定存在一个常数 $\zeta > 0$ 满足 $|\dot{\varphi}| \leq \zeta$. 注意到 $e_{t_k} = 0$ 并且 $\lim_{t \rightarrow t_{k+1}} e(t) = m_1 |u(t)| + m_2$, 因此一定可以找到一个正常数 t^* 满足 $t^* \geq \frac{m_1 |u(t)| + m_2}{\zeta}$, 即芝诺现象不会发生. 证毕.

4 仿真研究

本节将采用高超声速飞行器运动控制问题的应用场景来验证所提出控制策略的有效性及其可行性.

采用面向控制的高超声速飞行器模型作为研究对象^[23]. 其动态方程可描述为

$$\dot{V} = \frac{T \cos \alpha - D}{m} - g \sin \gamma, \quad (44)$$

$$\begin{cases} \dot{h} = V \sin \gamma, \dot{\gamma} = \frac{L + T \sin \alpha}{mV} - \frac{g \cos \gamma}{V}, \\ \dot{\alpha} = q - \dot{\gamma}, \dot{q} = \frac{M_{yy}}{I_{yy}} + \sum_{i=1}^2 \frac{\psi_i \ddot{\eta}_i}{I_{yy}}, \\ \ddot{\eta}_i = -2\xi_i \omega_i \dot{\eta}_i - \omega_i^2 \eta_i + N_i + \psi_i' \dot{Q}, i = 1, 2, \end{cases} \quad (45)$$

式中: 系统状态包括速度 V 、高度 h 、航迹角 γ 、攻角 α 、俯仰角速度 q 和弹性模态 η_i ; 控制输入为升降舵指令 δ_e 和燃油阀开度 Φ . 更具体的动力学和机身参数值可以参考文献[23]. 根据功能将动态方程进行分解, 划分为速度子系统(44)和高度子系统(45). 其中速度子系统采用比例-积分-微分(proportional-integral-deri-

vative, PID)控制, 本文所提出的控制方法主要应用于高度子系统.

定义高度参考指令 h_r , 高度跟踪误差 $e_h = h - h_r$. 进而, 航迹角参考指令可定义为

$$\gamma_d = \arcsin\left(\frac{-k_h e_h - k_i \int e_h dt + \dot{h}_r}{V}\right),$$

其中 k_h 和 k_i 为待设计的参数. 然后, 定义 $x_1 = \gamma$, $x_2 = \theta = \alpha + \gamma$, $x_3 = q$, 考虑 $T \sin \alpha \ll L$, 式(45)可建模为如下含有量化输入的严格反馈非线性系统:

$$\begin{cases} \dot{x}_1 = g_1 x_2 + f_1(\bar{x}_1) + d_1(t), \\ \dot{x}_2 = g_2 x_3 + d_2(t), \\ \dot{x}_3 = g_3 q(u) + f_3(\bar{x}_3) + d_3(\bar{x}_3, t), \\ y = x_1, \end{cases} \quad (46)$$

式中: $f_1 = \frac{\bar{q}S(C_L^1 \alpha + C_L^0)}{mV} - \frac{g \cos \gamma}{V}$, $g_1 = \frac{\bar{q}SC_L^1}{mV}$, $g_2 = 1$, $f_3 = \frac{z_T T + \bar{q}S\bar{c}(C_M^2 \alpha^2 + C_M^1 \alpha + C_M^0)}{I_{yy}}$, $g_3 = \frac{\bar{q}SC_M^{\delta_e}}{I_{yy}}$, $u = \delta_e$. $d_1(t)$, $d_2(t)$, $d_3(\bar{x}_3, t)$ 均存在未知上界的扰动项, 且 $d_3(\bar{x}_3, t) = \sum_{i=1}^2 \frac{\psi_i \ddot{\eta}_i}{I_{yy}} + d_3(t)$

表示包含外界扰动和弹性模态在内的扰动项集总. 控制目标为实现高超声速飞行器输出速度 V 和高度 h 能够在有限时间内快速稳定跟踪期望的速度指令 V_r 和高度指令 h_r .

为了实现确定学习的目标, 需满足确定神经网络的部分持续激励条件, 在训练设计中参考信号将 $y_d = 10 \sin t + 5 \cos(0.5t)$ 作为周期信号给出. 对于RBF神经网络的参数选取, 采用2932个神经元进行构造, 神经网络的接受域宽度选择为1, 0.75和1, 中心点均匀分布在 $[-1, 1] \times [-1.5, 1.5] \times [-2, 2]$ 区域. 结合确定学习思想, 未知的非线性动态可以被常值权重准确逼近.

根据第3.2节中式(27)–(29), 选取 $n = 3$ 即可得到高超声速飞行器高度子系统(45)的虚拟控制律、实际控制律, 以及相应的事件触发条件, 由于篇幅限制, 此处不再赘述. 本仿真中, 期望速度指令为 $V_d = 2600$ m/s, 期望高度指令为 $h_d = 34328$ m. 主要控制参数选取如下: $k_h = 0.8$, $k_i = 2$, $k_1 = 0.1$, $k_2 = 0.5$, $k_3 = 0.2$, $\iota_1 = 0.6$, $\iota_2 = 0.5$, $\iota_3 = 0.25$, $\rho_1 = 0.3$, $\rho_2 = 0.1$, $\rho_3 = 0.2$, $m_1 = 0.0001$, $m_2 = 0.001$, $\Xi = 0.2$. 所受的外界扰动表示为: $d_1(t) = 0.02 \cos(\frac{\pi}{3}t)$, $10s < t < 30s$; $d_2(t) = 0.01 \cos(\frac{\pi}{2}t)$, $100s < t < 120s$; $d_3(t) = 0.003 \cos(\pi t)$, $200s < t < 220s$.

本部分将文献[24]和文献[22]作为对比方案, 从而验证文中提出控制方案的有效性及其优点. 仿真结果如

图2-4所示.




图2 速度和高度变化曲线

Fig. 2 Curves of velocity and altitude

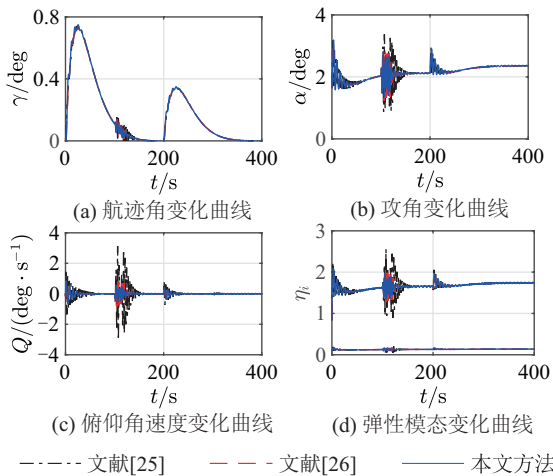


图3 姿态角和弹性模态变化曲线

Fig. 3 Curves of attitude angles and flexible states

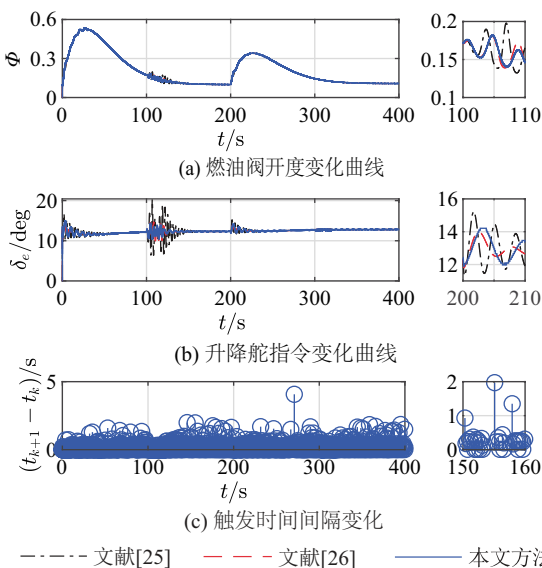


图4 控制输入曲线与事件触发时间间隔

Fig. 4 Curves of system inputs and event interval time

图2给出了速度与高度跟踪的效果对比,即使存在外界扰动和模型不确定性的情况下,3种方法均能有效跟踪参考指令,本文方案和文献[22]具有较高的跟踪精度,在有限时间内收敛到零的附近区域,同时对滤波误差以及外界扰动实现较好地补偿.相较于文献[22]将非线性动态和外界扰动处理为复合扰动的方式,本文方案更充分地考虑了飞行器系统的未知非线性动态部分并采用确定学习思想进行逼近.因此,本文方案能够一定程度保证系统在量化和通信受限条件下的跟踪精度.图3描述了姿态角和弹性模态变化曲线.图3(a)-(c)分别给出了航迹角、攻角、俯仰角速度和弹性模态的变化曲线,可以看出在相同外界扰动的影响下,本文方法具有较稳定的控制效果,且机体的弹性振动也处于较低水平.图4给出了控制输入和事件触发时间间隔的状态结果,利用事件触发机制节省了控制器到执行器间的通信资源,量化后的输入在整个控制过程中是有界的.其中,图4(c)描述了本次仿真中的具体触发情况,结合表1可以看出,在400 s飞行时间内传统的时间触发方案总触发次数为40000次(固定触发间隔为0.01 s),而在本文所采用的事件触发机制作用下,总触发次数为3130次(平均触发间隔为0.1728 s),因此,本文方案可以有效地减少触发次数,从而降低传感器-控制器信道之间的数据通信负载.此外,表1给出了本文方案和对比方案在触发次数以及处理器耗时方面的对比结果.可以看出,本文方案采用离线训练获得的经验知识避免了神经网络权值参数的在线调节,明显减少了计算量和通信资源占用.需要指出,由于量化和事件触发机制的引入,本文控制方案相较于采用固定频率更新的对比方案可能表现出姿态和控制输入曲线的抖动(如图3-4),特别是在飞行器机动上升的初始阶段,控制输入在触发条件(或量化条件)未被激活的短时间内维持上一状态,当触发条件一旦激活,控制输入将做出较为激烈的响应以追求较好的跟踪效果.进一步的仿真表明,通过减少触发机制式(29)中的 m_1 和 m_2 可以缓解这些抖动.

表1 性能对比

Table 1 Performance comparison

	文献[24]	文献[22]	本文方法
触发次数	40000	40000	3130
处理器耗时/s	2.1858	2.3232	1.0573

5 结论

针对含有量化输入和外部扰动的严格反馈非线性系统,本文提出了一种考虑量化和通信受限的有限时间确定学习控制方法.利用确定学习理论,实现了非线性系统未知动态的知识获取,并将获取的知识存储于常值神经网络.随后引入指令滤波反步技术克服

“计算爆炸”的问题. 结合事件触发机制建立了有限时间确定学习控制器, 能够保证跟踪误差在有限时间内收敛到原点的邻域内, 闭环系统的所有信号都是有界的, 且避免芝诺现象. 仿真结果验证了此方案能够节省通信资源, 减少算法计算量, 并获得良好的跟踪效果.

参考文献:

- [1] QIN Zhenhua, HE Xiongxiang, LI Gang, et al. Adaptive decentralized tracking control for nonlinear interconnected systems with input quantization and output constraints. *Acta Automatica Sinica*, 2021, 47(5): 1111 – 1124.
(秦贞华, 何熊熊, 李刚, 等. 考虑量化输入和输出约束的互联系统自适应分散跟踪控制. *自动化学报*, 2021, 47(5): 1111 – 1124.)
- [2] ZHOU J, WEN C, YANG G. Adaptive backstepping stabilization of nonlinear uncertain systems with quantized input signal. *IEEE Transactions on Automatic Control*, 2014, 59(2): 460 – 464.
- [3] XING L, WEN C, ZHU Y, et al. Output feedback control for uncertain nonlinear systems with input quantization. *Automatica*, 2016, 65(C): 191 – 202.
- [4] WANG Gexia. Geometrical method on quantized feedback control design for a class of nonlinear systems. *Acta Automatica Sinica*, 2020, 46(5): 1044 – 1050.
(王霞. 一类非线性系统量化反馈控制的几何设计方法. *自动化学报*, 2020, 46(5): 1044 – 1050.)
- [5] LIU Yang, JING Yuanwei, LIU Xiaoping. Survey on finite-time control for nonlinear systems. *Control Theory & Applications*, 2020, 37(1): 1 – 12.
(刘洋, 井元伟, 刘晓平. 非线性系统有限时间控制研究综述. *控制理论与应用*, 2020, 37(1): 1 – 12.)
- [6] WANG F, CHEN B, LIN C, et al. Adaptive neural network finite-time output feedback control of quantized nonlinear systems. *IEEE Transactions on Cybernetics*, 2017, 48(6): 1839 – 1848.
- [7] LIU W, QI X, LU J, et al. Finite-time fault-tolerant control for nonlinear systems with input quantization and its application. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2020, 67(7): 1249 – 1253.
- [8] ZHAO L, YU J, LIN C, et al. Adaptive neural consensus tracking for nonlinear multiagent systems using finite-time command filtered backstepping. *IEEE Transactions on Systems, Man and Cybernetics*, 2018, 48(11): 2003 – 2012.
- [9] MA J, JU H, XU S. Command-filter-based finite-time adaptive control for nonlinear systems with quantized input. *IEEE Transactions on Automatic Control*, 2021, 66(5): 2339 – 2344.
- [10] WANG C, HILL D J. Learning from neural control. *IEEE Transactions on Neural Networks*, 2006, 17(1): 130 – 146.
- [11] WANG M, WANG C. Recent advances on dynamic learning from adaptive NN control. *Control Theory and Technology*, 2020, 18(1): 107 – 109.
- [12] WANG M, WANG C. Learning from adaptive neural dynamic surface control of strict-feedback systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 26(6): 1247 – 1259.
- [13] GIRARD A. Dynamic triggering mechanisms for event-triggered control. *IEEE Transactions on Automatic Control*, 2013, 60(7): 1992 – 1997.
- [14] XING L, WEN C, LIU Z, et al. Event-triggered adaptive control for a class of uncertain nonlinear systems. *IEEE Transactions on Automatic Control*, 2017, 62(4): 2071 – 2076.
- [15] LI X, YANG G. Model-based adaptive event-triggered control of strict-feedback nonlinear systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(4): 1033 – 1045.
- [16] GU Z, SHI P, YUE D, et al. Decentralized adaptive event triggered H_∞ filtering for a class of networked nonlinear interconnected systems. *IEEE Transactions on Cybernetics*, 2019, 49(5): 1570 – 1579.
- [17] LIU Z, WANG F, ZHANG Y, et al. Fuzzy adaptive quantized control for a class of stochastic nonlinear uncertain systems. *IEEE Transactions on Cybernetics*, 2015, 46(2): 524 – 534.
- [18] CHEN M, TAO G, JIANG B. Dynamic surface control using neural networks for a class of uncertain nonlinear systems with input saturation. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(9): 2086 – 2097.
- [19] ZUO Z. Nonsingular fixed-time consensus tracking for second-order multi-agent networks. *Automatica*, 2015, 54: 305 – 309.
- [20] YU S, YU X, SHIRINZADEH B, et al. Continuous finite-time control for robotic manipulators with terminal sliding mode. *Automatica*, 2005, 26(9): 1957 – 1964.
- [21] JIN X. Adaptive fixed-time control for mimo nonlinear systems with asymmetric output constraints using universal barrier functions. *IEEE Transactions on Automatic Control*, 2018, 64(7): 3046 – 3053.
- [22] LI J, YANG Y, HUA C. Fixed-time backstepping control design for high-order strict-feedback non-linear systems via terminal sliding mode. *IET Control Theory & Applications*, 2017, 11(8): 1184 – 1193.
- [23] PARKER J, SERRANI A, YURKOVICH S, et al. Control-oriented modeling of an air-breathing hypersonic vehicle. *Journal of Guidance, Control, and Dynamics*, 2007, 30(3): 856 – 869.
- [24] SHIN J. Adaptive dynamic surface control for a hypersonic aircraft using neural networks. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 53(5): 2277 – 2289.

作者简介:

王冠 博士研究生, 目前研究方向为自适应控制与智能控制, E-mail: wangguan@sina.cn;

夏红伟 教授, 博士生导师, 目前研究方向为飞行器控制及仿真技术、智能装备一体化设计, E-mail: hxia@hit.edu.cn.