

引用格式:周德召,刘晓东,李佳庆,等.基于在线学习的机载光电系统扩张状态观测器参数整定研究[J].电光与控制,2019,26(8):43-47.  
ZHOU D Z, LIU X D, LI J Q, et al. Parameter setting of extended state observer in airborne electro-optical system based on online learning[J]. Electronics Optics & Control, 2019, 26(8):43-47.

## 基于在线学习的机载光电系统扩张状态观测器参数整定研究

周德召<sup>1</sup>, 刘晓东<sup>2</sup>, 李佳庆<sup>3</sup>, 王合龙<sup>1,4</sup>

(1. 中国航空工业集团公司洛阳电光设备研究所,河南 洛阳 471000; 2. 空军装备部,北京 100843;  
3. 北京理工大学,北京 100081; 4. 光电控制技术重点实验室,河南 洛阳 471000)

**摘要:** 针对非线性动态系统的扩张状态观测器(ESO)参数整定问题,建立了基于BP神经网络的参数整定模型。采用在线梯度下降法进行网络训练以保证对动态系统的学习能力,并引入了IDBD算法,利用输入数据的信息和学习过程中的经验实现学习速率的自适应调整,以改进在线梯度下降法的适应性。数字仿真表明,该参数整定模型较传统的参数整定模型具有动态性能好、精度高等优点,能够提高非线性系统扩张状态观测器参数的动态整定精度,进而在一定程度上改善自抗扰控制器的系统控制性能。

**关键词:** 机载光电系统; 前向神经网络; 在线学习; 自抗扰控制; 扩张状态观测器

中图分类号: TN391 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.08.009

## Parameter Setting of Extended State Observer in Airborne Electro-Optical System Based on Online Learning

ZHOU De-zhao<sup>1</sup>, LIU Xiao-dong<sup>2</sup>, LI Jia-qing<sup>3</sup>, WANG He-long<sup>1,4</sup>

(1. Luoyang Institute of Electro-Optical Equipment, AVIC, Luoyang 471000, China;  
2. PLA Air Force Equipment Department, Beijing 100843, China; 3. Beijing Institute of Technology, Beijing 100081, China;  
4. Science and Technology on Electro-Optical Control Laboratory, Luoyang 471000, China)

**Abstract:** In order to solve the problem of parameter setting of the extended state observer used in nonlinear dynamic system, a parameter setting model based on BP neural network is established. The online gradient descent method is used to train the network so as to ensure the learning ability of the dynamic system. The incremental Delta-Bar-Delta algorithm is introduced, and the information of input data and learning experience are used to realize the adaptive adjustment of the learning rate and improve the adaptability of the online gradient descent method. It can be seen from the numerical simulation that the parameter setting model possesses the advantages of good dynamic performance and high accuracy compared with the traditional parameter setting model, and it can improve the dynamic setting accuracy of the parameters of the extended state observer of the nonlinear system, so that the controlling performance of the ADRC system is improved to a certain extent.

**Key words:** airborne electro-optical system; forward neural network; online learning; active disturbance rejection controller; extended state observer

### 0 引言

机载光电系统利用多波段探测器实现对目标的全天候成像,增强载机态势感知能力,具有抗电磁干扰性强、无源探测等优点。但其成像性能与平台稳定性

息息相关,而光电系统平台受载机振动、风阻力矩等未知扰动作用,其稳定性提升受到一定限制。将自抗扰控制(ADRC)应用于机载光电系统稳定环控制,可以有效解决未知扰动给系统带来的影响,提升光电系统成像质量<sup>[1]</sup>。

自抗扰控制是由韩京清在非线性微分跟踪器(TD)和扩张状态观测器(ESO)基础上提出的无模型控制器,具有算法设计简单、易于实现、鲁棒性好、适应范围广等优点<sup>[1]</sup>。但自抗扰控制器存在多项待整定的参

收稿日期:2018-09-07

修回日期:2019-06-30

作者简介:周德召(1980—),男,黑龙江齐齐哈尔人,博士生,研究员,研究方向为系统工程。

数,而这些参数的选取直接影响控制器的控制精度和整个系统的动态性能。文献[2]指出自适应确定非线性 ESO 参数是未来研究的方向。

BP 神经网络是应用最为广泛的一种多层前向神经网络,可通过网络自身的学习来实现从输入到输出的非线性映射,或逼近任何非线性函数。文献[3]指出可将神经网络用于 ESO 参数整定,但其采用离线整定方式,不能做到对系统变化实时响应。本文针对光电系统自抗扰控制中的 ESO 参数整定问题,采用 BP 神经网络在线学习方式对 ESO 参数估计,实现了被控对象变化的动态补偿,进而提高了自抗扰控制器的控制性能。

## 1 自抗扰 ESO 模型分析

ESO 不依赖于控制系统扰动的具体模型,只用了系统的输入、输出信息,是一个通用扰动观测器<sup>[3]</sup>。若被控系统为

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = x_3 \\ \vdots \\ \dot{x}_{n-1} = x_n \\ x_n = f(x_1, x_2, \dots, x_{n-1}, t) + w(t) + bu(t) \\ y = x_1 \end{cases} \quad (1)$$

式中:  $x_1, x_2, \dots, x_{n-1}$  为控制系统状态;  $f(x_1, x_2, \dots, x_{n-1}, t)$  为被控系统模型;  $w(t)$  为外部扰动;  $b$  为比例因子;  $u(t)$  为系统控制量。

则系统的离散化扩张状态观测器可描述为

$$\begin{cases} e(k) = z_1(k) - y(k) \\ z_1(k+1) = z_1(k) + h[z_2(k) - \beta_{01}e(k)] \\ z_2(k+1) = z_2(k) + h[z_3(k) - \beta_{02}fal(e, \alpha_1, \delta)] \\ \vdots \\ z_n(k+1) = z_n(k) + h[z_{n+1}(k) - \beta_{0n}fal(e, \alpha_{n-1}, \delta) + u(k)] \\ z_{n+1}(k+1) = z_{n+1}(k) - h\beta_{0n+1}fal(e, \alpha_n, \delta) \end{cases} \quad (2)$$

式中:  $h$  为积分步长;  $z_1(k), z_2(k), z_3(k), \dots, z_n(k)$  为  $k$  时刻观测状态;

$$fal(e, \alpha, \delta) = \begin{cases} |e|^{\alpha} \text{sgn } e & |e| > \delta \\ \frac{e}{\delta^{1-\alpha}} & |e| \leq \delta \end{cases} \quad (3)$$

ESO 需整定的参数主要包括  $\{\beta_{01}, \beta_{02}, \dots, \beta_{0n+1}\}$ ,  $\{\alpha_1, \alpha_2, \dots, \alpha_n\}$  和  $\delta$  等。其中:  $\{\alpha_1, \alpha_2, \dots, \alpha_n\}$  取值在范围  $(0, 1)$  时,  $fal(\cdot)$  的非线性度较强,且取值越小,ESO 对扰动及系统模型不确定性的适应能力也就越强<sup>[4]</sup>;  $\delta$  是  $fal(\cdot)$  的线性区间长度,能够避免曲线在零点附近斜率过大而产生高频抖动,通常取 0.1,然后根据状态跟踪

效果适当增大线性区间长度;参数  $\{\beta_{01}, \beta_{02}, \dots, \beta_{0n+1}\}$  影响系统状态跟踪和扰动的估计,尤其是总和扰动的准确性对控制性能影响比较大<sup>[5]</sup>。为提高被控对象在扰动及系统模型变化条件下 ESO 参数  $\{\beta_{01}, \beta_{02}, \dots, \beta_{0n+1}\}$  的动态整定性能,引入 BP 前向神经网络以改进参数的动态整定能力<sup>[6]</sup>。

## 2 基于 BP 神经网络的 ESO 参数整定

### 2.1 参数整定模型建模

首先,根据机载光电系统实际需求,设定扩张状态观测器(ESO)系统为 3 阶系统,其方程为

$$\begin{cases} e(k) = z_1(k) - y(k) \\ z_1(k+1) = z_1(k) + h[z_2(k) - \beta_{01}e(k)] \\ z_2(k+1) = z_2(k) + h[z_3(k) - \beta_{02}fal(e, \alpha_1, \delta) + u(k)] \\ z_3(k+1) = z_3(k) - h\beta_{03}fal(e, \alpha_2, \delta) \end{cases} \quad (4)$$

式中,  $z_1(k), z_2(k), z_3(k)$  分别为系统状态变量  $x_1(t), x_2(t)$  和扰动  $w(t)$  的观测值。

根据文献[7]设定合适的参数  $h, \beta_{01}, \beta_{02}, \beta_{03}$ , 可使观测误差在有限时间内充分小,系统满足收敛性要求。

基于 BP 神经网络的参数整定由输入层、隐含层和输出层组成,其中隐含层可以有若干层,如图 1 所示。

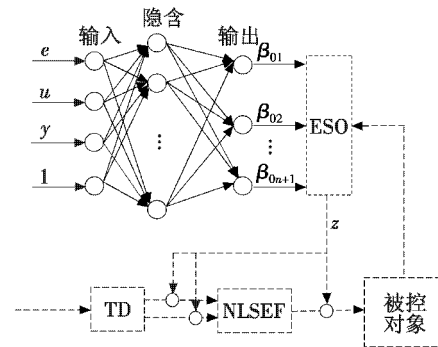


图 1 BP-ESO 参数整定结构

Fig. 1 Structure of BP-ESO parameter setting

由式(4)可以确定 BP 神经网络的输入层为

$$\mathbf{O}^{(1)}(k) = [e(k) \quad u(k) \quad y(k) \quad 1]^T \quad (5)$$

式中: 常数项 1 的引入可以减小输入数据相关性,提高收敛速度。

隐含层的输入、输出分别为

$$\begin{cases} net_j^{(2)}(k) = \sum_{i=1}^m w_{ji}^{(2)} O_i^{(1)} - \theta_j \\ O_j^{(2)}(k) = f[net_j^{(2)}(k)] \end{cases} \quad (6)$$

式中:  $m$  为输入层神经元数量; 神经元活化函数  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

输出层的输入、输出分别为

$$\begin{cases} net_i^{(3)}(k) = \sum_{j=1}^h w_{ij}^{(3)} O_j^{(1)} - \theta_i \\ O_i^{(3)}(k) = g[net_i^{(3)}(k)] \end{cases} \quad (7)$$

式中:输出即为  $\{\beta_{01}, \beta_{02}, \dots, \beta_{0n+1}\}$ ;  $h$  为隐含层神经元数量; 神经元活化函数  $g(x) = \frac{1}{1 + e^{-x}}$ 。

## 2.2 网络结构确定

BP 前向神经网络的输入层、输出层神经元数量确定以后,选取合适的隐含层神经元个数是确保控制性能和运算量的关键。若隐含层神经元个数不足,则系统的收敛性能变差;反之,网络训练时间长,易陷入局部极小点,出现“过拟合”现象<sup>[7]</sup>。本文采用公式法和试验法相结合的方式确定隐含层神经元个数<sup>[8-9]</sup>。

1) 采用公式法大致确定隐含层神经元数目范围,即

$$N = \sqrt{M + L} + a \quad (8)$$

式中: $N$  为隐含层神经元数目; $M$  为输入层神经元数目; $L$  为输出层神经元数目; $a$  为选取的 1~10 之间的常数,通常由经验所得。

2) 按照从小到大的顺序对隐含层神经元个数进行排序。

3) 按次序进行试验,结合系统精度、计算量等综合确定最优隐含层神经元个数。

## 2.3 训练学习方法选择

本文针对动态系统的特点,采用了在线梯度下降法进行自抗扰 ESO 参数整定神经网络的训练。通常指标函数选取为  $E(n) = \sum_{k=1}^L \frac{[r_k(n) - y_k(n)]^2}{2}$ 。其中: $r_k(n)$  为神经元期望输出数据; $y_k(n)$  为神经网络实际输出。

考虑到系统的稳定性、动态性能以及抗高频扰动等性能,本文指标函数设置为复合型误差函数,即

$$\begin{aligned} G_\lambda(n) &= \lambda E(n) + (1 - \lambda) E_c(n) = \\ &0.5 \sum_{k=1}^L (r(k) - y(k))^2 + (1 - \lambda) \sum_{k=1}^L (1 - y(k)r(k)) = \\ &0.5\lambda \sum_{k=1}^L (e(k))^2 + (1 - \lambda) \sum_{k=1}^L (r(k)e(k)) \quad (9) \end{aligned}$$

式中,  $\lambda = \exp(-|\Delta E(n)|/E(n))$ ,  $\Delta E(n) = E(n) - E(n-1)$  为误差变化量,  $\Delta E(n)/E(n)$  为误差变化率,  $E(n)$  为第  $n$  个样本学习时的误差。

在训练的初始阶段  $\lambda = 1$ , 此时  $G_\lambda(n) = E(n)$ , 即全局均方误差函数,网络收敛速度加快;随着训练量的增加,  $E(n)$  不断减小,当  $\lambda$  从 1 趋于 0 时,  $(1 - \lambda)E_c(n)$  部分贡献值增大,此时  $G_\lambda(n) = E_c(n)$ , 网络收敛速度同样加快,在一定程度上克服了传统 BP 算法收敛速度慢的缺点,改善了算法性能<sup>[10]</sup>。对于  $G_\lambda(n)$ , 判断其收敛性,当  $e(k) \rightarrow 0$  时,复合误差函数能使  $E(n)$  和  $E_c(n)$  同时达到极小,收敛性与  $E(n)$  的收敛性一致。

此时有

$$\begin{cases} w_{ij}^{(3)}(k+1) = w_{ij}^{(3)}(k) + \eta \Delta w_{ij}^{(3)}(k) + \alpha [w_{ij}^{(3)}(k) - w_{ij}^{(3)}(k-1)] \\ w_{ij}^{(2)}(k+1) = w_{ij}^{(2)}(k) + \eta \Delta w_{ij}^{(2)}(k) + \alpha [w_{ij}^{(2)}(k) - w_{ij}^{(2)}(k-1)] \end{cases} \quad (10)$$

式中: $\eta$  为学习速率; $\alpha$  为惯性系数;

$$\Delta w_{ij}^{(3)}(k) = - \frac{\partial J(k)}{\partial net_i^{(3)}(k)} \cdot \frac{\partial net_i^{(3)}(k)}{\partial w_{ij}^{(3)}(k)} = \delta_i^{(3)} \cdot O_j^{(2)} \quad (11)$$

$$\begin{aligned} \Delta w_{ij}^{(2)}(k) &= - \frac{\partial J(k)}{\partial net_i^{(2)}(k)} \cdot \frac{\partial net_i^{(2)}(k)}{\partial w_{ij}^{(2)}(k)} = \\ &g'[net_i^{(2)}(k)] \cdot \sum_{l=1}^N w_{il}^{(3)} \cdot \delta_l^{(3)} \cdot O_j^{(1)} \quad (12) \end{aligned}$$

其中,

$$\delta_i^{(3)} = - \frac{\partial J}{\partial net_i^{(3)}(k)} = e(k) \cdot \frac{\partial y(k)}{\partial O_i^{(3)}(k)} \cdot f'[net_i^{(3)}(k)] \quad (13)$$

上述模型中,  $\frac{\partial y(k)}{\partial O_i^{(3)}(k)}$  未知,但考虑到其数值较

小,且正负性容易获得,本文采用  $\text{sgn}\left[\frac{\partial y(k)}{\partial O_i^{(3)}(k)}\right]$  近似替代,并通过学习速率参数调整来补偿这一近似带来的影响。

为改进在线梯度下降法的适应性,本文综合考虑了以下几种神经网络学习常用算法的优劣。

1) 动量项法是在系统中加入(0,1)之间的常数作为动量项系数来提高系统收敛性能。但只有当目前的梯度下降方向与上一步的权值改变方向相近时,该种算法才具备加速的功能,否则会导致误差增大<sup>[11]</sup>。

2) 自适应学习率法可以保证学习率随训练过程而改变,改善神经网络收敛性能,但要找到万能的自适应学习率算法是不可能的。自适应学习率算法不合适,会导致误差增大。

3) 共轭梯度法是一种改进搜索方向的方法。把过去的梯度和现在某点的梯度信息综合利用,用其线性组合来构造更好的搜索方向,但无法保证收敛性和避免陷入局部极值<sup>[10]</sup>。

考虑上述算法不足,本文采用增量 Delta-Bar-Delta (IDBD) 算法,利用输入数据的信息和学习过程中的经验实现学习速率的自适应调整,做到保证收敛速度,避免陷入局部极值<sup>[12]</sup>。即算式为

$$\eta_{ij}(k) = \eta_{ij}(k-1) + \Delta \eta_{ij}(k) \quad (14)$$

式中:

$$\Delta \eta_{ij}(k) = \begin{cases} a & S_{ij}(k-1) D_{ij}(k) > 0 \\ -b \eta_{ij}(k) & S_{ij}(k-1) D_{ij}(k) < 0, D_{ij}(k) = \\ 0 & S_{ij}(k-1) D_{ij}(k) = 0 \end{cases}$$

$\frac{\partial J(k)}{\partial w_{ij}(k)}, S_{ij}(k) = (1 - \xi) D_{ij}(k) + \xi S_{ij}(k-1)$ ,  $a, b$  和  $\xi$  为

0~1的常数,通常 $10^{-4} \leq a \leq 0.1, 0.1 \leq b \leq 0.5, 0.1 \leq \xi \leq 0.7$ 。

## 2.4 算法稳定性分析

为了高效训练神经网络,从离散的 Lyapunov 稳定性方法出发,给出保证神经网络稳定性的证明。

首先给出结论:

若 $\eta_1(n)$ 满足

$$0 < \eta_1(n) < 8/(\lambda ML |\max_j O_j(n)|) \quad (15)$$

式中, $\eta_1(n)$ 为输出层学习率。则由上述学习算法表达的对权值 $\mathbf{v}_{jk}(n)$ 的迭代过程收敛。

若 $\eta_2(n)$ 满足

$$0 < \eta_2(n) < 8/(\lambda \alpha MN |\max_{jk} \mathbf{v}_{jk}(n)| \cdot |\max_j \xi_j|) \quad (16)$$

式中: $\mathbf{v}_{jk}(n)$ 为隐含层到输出层权值; $\eta_2(n)$ 为隐含层学习率; $w_{ij}(n)$ 为输入层到隐含层权值。则由上述学习算法表达的对权值 $w_{ij}(n)$ 的迭代过程收敛。

证明如下。

首先定义 Lyapunov 能量函数,与传统误差函数类似,其表达式为

$$E_\lambda(n) = \frac{1}{2} \sum_{k=1}^L (e_k(\lambda, n))^2 = \frac{1}{2} \sum_{k=1}^L (r_k(n) - \lambda y_k(n))^2 \quad (17)$$

于是,有

$$\Delta E_\lambda(n+1) = E_\lambda(n+1) - E_\lambda(n) = \frac{1}{2} \sum_{k=1}^L (e_k(\lambda, n+1) - e_k(\lambda, n))^2 \quad (18)$$

学习过程中的误差可以表示为

$$e_k(\lambda, n+1) = e_k(\lambda, n) + \sum_{j=1}^M \sum_{k=1}^L \frac{\partial e_k(\lambda, n)}{\partial \mathbf{v}_{jk}(n)} \Delta \mathbf{v}_{jk}(n) = e_k(\lambda, n) - \sum_{j=1}^M \sum_{k=1}^L \lambda \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \Delta \mathbf{v}_{jk}(n) \quad (19)$$

其中,隐含层到输出层连接权值 $\mathbf{v}_{jk}(n)$ 的修正量为

$$\Delta \mathbf{v}_{jk}(n) = -\eta_1(n) \left[ \frac{\partial \lambda E(n)}{\partial e_k(n)} + \frac{\partial (1-\lambda) E_G(n)}{\partial e_k(n)} \right] \frac{\partial e_k(n)}{\partial \mathbf{v}_{jk}(n)} = -\eta_1(n) (r_k - \lambda y_k) \frac{\partial e_k(n)}{\partial \mathbf{v}_{jk}(n)} = \eta_1(n) e_k(\lambda, n) \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \quad (20)$$

于是,有

$$\Delta E_\lambda(n+1) = \frac{1}{2} \sum_{k=1}^L (e_k(\lambda, n))^2 \cdot \left[ \left( 1 - \lambda \eta_1(n) \left[ \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right]^T \left[ \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right] \right)^2 - 1 \right] = \frac{1}{2} \sum_{k=1}^L (e_k(\lambda, n))^2 \left[ \left( 1 - \lambda \eta_1(n) \left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\|^2 \right)^2 - 1 \right] - \sum_{k=1}^L (e_k(\lambda, n))^2 \beta_k(\lambda, n) \quad (21)$$

式中:

$$\beta_k(\lambda, n) = \frac{1}{2} \lambda \eta_1(n) \left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\|^2 \left( 2 - \lambda \eta_1(n) \left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\|^2 \right) \quad (22)$$

这里把 $\mathbf{v}_{jk}(n)$ 看成一个 $N \times L$ 维度向量。此时其输出层的传递函数为 $f(x) = \frac{1}{1 + e^{-x}}$ ,而 $0 < f'(x) \leq \frac{1}{4}$ ,所以

$$\left| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right| = \left| \frac{\partial y_k(n)}{\partial L_k(n)} \frac{\partial L_k(n)}{\partial \mathbf{v}_{jk}(n)} \right| =$$

$$|f'(L_k(n)) \cdot O_j(n)| \leq \frac{1}{4} |\max_j O_j(n)| \quad (23)$$

按照范数的定义,有

$$\left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\| \leq \sqrt{\frac{1}{4} |\max_j O_j(n)|} \quad (24)$$

从而,当 $0 < \eta_1(n) < 8/(\lambda \alpha_1 ML |\max_j O_j(n)|)$ 时,有 $\beta_k(\lambda, n) > 0$ ,此时 $\Delta E_\lambda(n+1) < 0$ 。根据离散型 Lyapunov 稳定性原理可知算法稳定。当 $n \rightarrow \infty$ 时, $E_\lambda(n)$ 将收敛到0。由于 $\Delta E(n) \rightarrow 0$ 时, $\lambda \rightarrow 1$ ,此时, $e_k(\lambda, n) = \lambda e_k(n) + (1-\lambda)r_k$ 将收敛到0,所以可知训练误差 $e_k(n)$ 将收敛到0。式(15)证明完毕。

同理可证明式(16)。

由上述定理的结论可知:当 $\eta_1(n)$ 满足 $0 < \eta_1(n) < 8/(\lambda ML |\max_j O_j(n)|)$ 时,可保证网络较快收敛。但当

$\left[ 1 - \lambda \eta_1(n) \left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\|^2 \right] = 1$ 时, $\Delta E_\lambda(n+1)$ 达到最小,

即网络能以最快速度收敛。若近似认为 $\left\| \frac{\partial y_k(n)}{\partial \mathbf{v}_{jk}(n)} \right\| =$

$\sqrt{\frac{ML}{4} |\max_j O_j(n)|}$ ,则取 $\eta_1(n) = 8/(\lambda ML |\max_j O_j(n)|)$ ,

可以保证网络以较快速度收敛;同理可取 $\eta_2(n) = 8/(\lambda \alpha MN |\max_{jk} \mathbf{v}_{jk}(n)| \cdot |\max_j \xi_j|)$ ,以保证网络较快收敛。

## 3 仿真分析

本文以3阶ESO观测复杂非线性系统为例进行算法仿真验证,假定系统的传递函数为

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = x_3 + u \\ \dot{x}_3 = 0.5 \cdot \text{sgn}(\sin(2t)) - 0.2x_2 \\ y = x_1 \end{cases} \quad (25)$$

结合上述分析可以看出,神经网络的输入、输出分别为 $\mathbf{O}^{(1)}(k) = [e(k) \quad u(k) \quad y(k) \quad 1]^T$ , $\mathbf{O}^{(3)}(k) = [\beta_{01} \quad \beta_{02} \quad \beta_{03}]^T$ 。其中:定义控制量 $u$ 为0;系统初始状态为 $[1 \ 0 \ 0]$ 。

根据经验公式可以得出隐含层神经元个数应该在4~13之间。综合考虑系统计算复杂程度和计算精度

的取舍,本文选取隐含层神经元个数为 6。图 2 为仿真系统网络结构图。

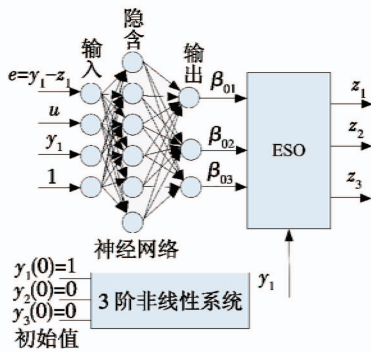


图 2 仿真系统网络结构图

Fig. 2 Network structure diagram of simulation system

本文通过对复杂 3 阶非线性系统进行仿真,得到系统实际状态值、基于在线学习整定 ESO 参数所得系统状态值与基于常规整定方法得到离线 ESO 参数所得系统状态变量观测值。实验结果如图 3 所示。

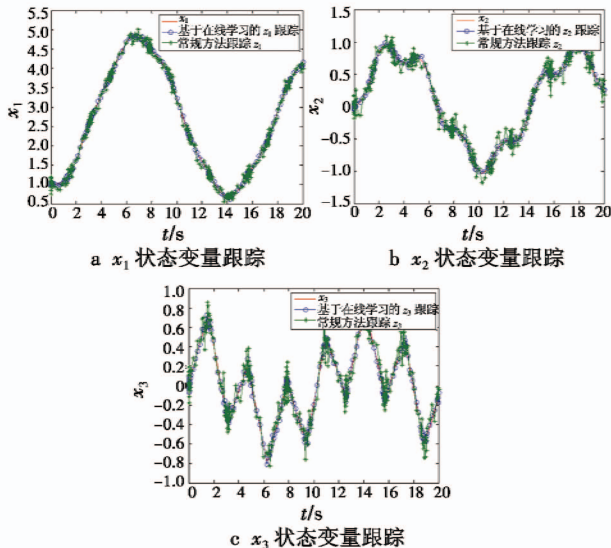


图 3 复杂 3 阶非线性系统仿真结果

Fig. 3 Simulation result diagram of complex three-order nonlinear system

通过仿真可以看出,本文采用的在线学习状态观测器参数整定方法能够实现 ESO 的参数  $\{\beta_{01}, \beta_{02}, \beta_{03}\}$  整定,满足 ESO 稳定跟踪复杂非线性系统状态变量的要求,并且其整定精度较传统参数整定方法有较大提高。由图 3 可以看出,基于传统 ESO 参数整定方法的 ESO 观测器能够实现对复杂 3 阶非线性系统状态变量的实时观测,但其局部点容易出现峰值误差,且峰值误差可达 0.1;而基于在线学习的 ESO 参数整定方法的 ESO 观测器在观测复杂 3 阶非线性系统的基础上,可使其观测到的峰值误差减小到 0.03,提高 ESO 的观测精度。

## 4 结束语

基于在线学习的扩张状态观测器参数整定方法相对于传统的参数整定方法具有动态性能好、精度高等优点,能够实现非线性动态系统扩张状态观测器的参数整定,为提升光电系统自抗扰控制精度,进而提高系统稳定精度和成像质量打下基础。但神经网络的结构(隐含层神经元个数)对 ESO 参数整定具有一定的影响,是需进一步考虑的因素。

## 参考文献

- [1] 韩京清. 自抗扰控制技术—估计补偿不确定因素的控制技术[M]. 北京:国防工业出版社,2008.
- [2] 王坤,蔡远利. 基于神经网络的跟踪-微分器设计[J]. 计算机与数字工程,2014,42(3):378-381,432.
- [3] 葛立明,李宗刚,王世伟,等. 基于调节/观测时间的自抗扰控制器参数整定[J]. 控制与决策,2017,32(7):1333-1337.
- [4] LIU Y, YANG C T. Automatic grading system for Mandarin proficiency test based on PSO-ANN[J]. Journal of Computers, 2010, 5(11):1739-1746.
- [5] 栾强利,陈章位,徐进荣,等. 地震模拟振动台三参量控制参数整定技术的研究[J]. 振动工程学报,2014,27(3):416-425.
- [6] 王世峰,赵党军. 基于有限时间收敛 ESO 的四旋翼无人机控制[J]. 中南大学学报:自然科学版,2015,46(7):2494-2503.
- [7] 潘东华. 面向超精定位系统无铁心直流直线电机精确建模与优化研究[D]. 哈尔滨:哈尔滨工业大学,2013.
- [8] TAN X, RUAN X B. Optimal design of DCM LCC resonant converter with inductive filter based on mode boundary map[J]. IEEE Transactions on Power Electronics, 2015, 30(8):4144-4155.
- [9] 张国翊,胡铮. 改进 BP 神经网络模型及其稳定性分析[J]. 中南大学学报:自然科学版,2011,42(1):115-124.
- [10] 李菁菁,任章,曲鑫. 机动滑翔飞行器的自抗扰反步高精度姿态控制[J]. 系统工程与电子技术,2010,32(8):1711-1715,1721.
- [11] 关学忠,白云龙,高哲. 基于 BP 神经网络的无刷直流电机的自抗扰控制[J]. 计算机与数字工程,2014,42(12):2399-2403.
- [12] 殷宗迪,董浩,史文杰,等. 精确模型辨识的光电平台自抗扰控制器[J]. 红外与激光工程,2017,46(9):308-313.