

doi: 10.7690/bgzdh.2024.04.003

# 基于 WNN 参数整定的 ADRC 在火箭炮伺服系统中的应用

廖 华, 侯润民, 张志豪

(南京理工大学机械工程学院, 南京 210094)

**摘要:** 针对多管火箭炮交流伺服系统存在变负载、强耦合和不确定性扰动等非线性问题, 提出一种优化型小波神经网络自抗扰控制器(WNN-ADRC)。简化电流环节得到被控系统的数学模型, 将小波神经网络(wavelet neural network, WNN)嵌入自抗扰控制器中进行参数整定, 利用分层调整学习速率的方法优化小波神经网络的学习算法得到 WNN-ADRC, 采用 WNN-ADRC 控制火箭炮伺服系统, 实现对非线性特性的精准估计和补偿。数值仿真结果表明: 相对于传统的自抗扰控制器, WNN-ADRC 能改善伺服系统的静态响应和动态性能, 具有响应速度快、控制精度高的优点。

**关键词:** 交流伺服系统; 小波神经网络; 自抗扰控制器

**中图分类号:** TJ391; TP273 **文献标志码:** A

## Application of ADRC Based on WNN Parameter Tuning in Rocket Launcher Servo System

Liao Hua, Hou Runmin, Zhang Zhihao

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

**Abstract:** An optimized wavelet neural network active disturbance rejection controller (WNN-ADRC) is proposed to solve the nonlinear problems of multiple rocket launcher AC servo system, such as variable load, strong coupling and uncertain disturbance. The mathematical model of the controlled system is obtained by simplifying the current link, and the wavelet neural network (WNN) is embedded into the ADRC for parameter tuning, and the learning algorithm of the WNN is optimized by using the method of hierarchically adjusting the learning rate to obtain the WNN-ADRC. The WNN-ADRC is used to control the servo system of the rocket launcher to realize the accurate estimation and compensation of the nonlinear characteristics. The numerical simulation results show that the WNN-ADRC can improve the static response and dynamic performance of the servo system, and has the advantages of fast response and high control precision compared with the traditional ADRC.

**Keywords:** AC servo system; wavelet neural network; active disturbance rejection controller

## 0 引言

火箭炮作为火箭弹发射装置, 其追踪能力、响应速度等控制性能的好坏决定了火箭弹的效力能否得到充分发挥。在实际的工作中, 火箭炮会受到结构性不确定、负载、外界环境变化等干扰因素的影响, 传统的 PID 控制很难保证系统的稳定性和控制能力满足要求<sup>[1-3]</sup>。神经控制、遗传算法、自适应控制、自抗扰控制等算法相继被提出, 并且将其相互结合, 形成复合控制器应用于伺服系统中<sup>[4]</sup>。

自抗扰控制(active disturbance rejection control, ADRC)相对于传统 PID 控制性能更好, 但在实际应用中需要的参数数量较多, 难以选定。人工神经网络有逼近任意非线性函数的能力, 可用于与 ADRC 形成复合控制器, 解决 ADRC 参数过多难以选定的问题。文献[5]中使用 BP 神经网络对 ADRC

的参数进行整定, 结果表明 BP-ADRC 控制性能比 ADRC 更好; 文献[6]使用 RBF 神经网络对 ADRC 进行参数整定, 改善了 ADRC 的动态性能以及系统的响应速度。

小波神经网络(WNN)是以 BP 神经网络为基础的一种新型前馈型神经网络。其核心是将母小波函数的伸缩和平移得到的小波函数作为隐含层的激活函数, 伸缩因子和平移因子作为隐含层节点的阈值。相较于传统神经网络, WNN 在系统辨识及控制方面拥有更强的逼近和学习能力, 近年来被广泛应用于非线性系统的识别和控制。文献[7]中分别使用传统 BP 神经网络和 WNN 神经网络对伺服系统进行系统辨识, 对比仿真结果, WNN 神经网络的函数逼近能力更强; 文献[8]中使用 WNN 神经网络对 PID 的参数进行整定, 比传统 PID 控制性能更好。

笔者将采用 WNN 对 ADRC 进行参数整定, 整

收稿日期: 2023-12-20; 修回日期: 2024-01-15

第一作者: 廖 华(1998—), 男, 江苏人, 硕士。

定的对象是扩张状态观测器中的非线性增益  $\beta_1, \beta_2, \beta_3$ 。通过实时信号对其进行在线整定，以整定后的参数为控制扩张状态观测器的输入，以便于实时控制 ADRC，使 ADRC 更好地实现控制性能。

### 1 火箭炮伺服系统

#### 1.1 伺服系统结构及原理

如图 1 所示，本文中的被控对象是某种舰载多管火箭炮伺服系统，其主要组成部分为火控系统、随动控制计算机、交流调速系统、减速箱、负载、旋转变压器和 RDC 模块。

系统运行过程：随动控制计算机接受来自上位机(火控计算机)的数据以及系统的反馈信号，通过控制算法转换为一定的控制信号，控制信号输入

至调速系统中，调速系统中的控制器输出控制量到电机中。电机经过减速器带动负载工作，旋转变压器检测负载的位置信息并传输给 RDC 转换模块，RDC 将位置信息转换并通过 CAN 总线反馈回随动控制计算机中，从而形成一个闭环控制。




图 1 舰载火箭炮交流伺服系统结构

#### 1.2 伺服系统数学模型

某火箭炮伺服系统框图如图 2 所示。其执行单位为永磁同步交流电机。

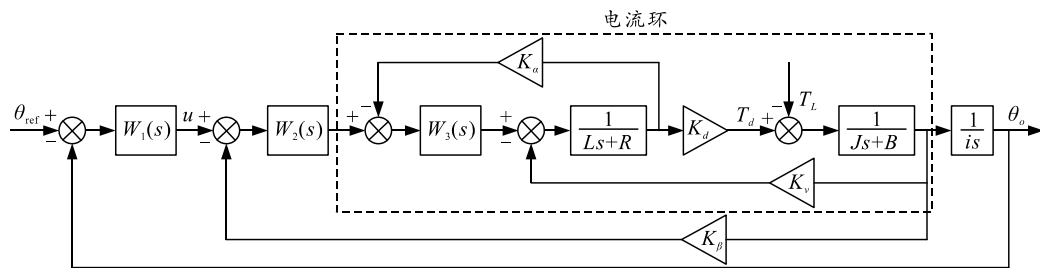


图 2 系统框图

图中： $\theta_{ref}$ 、 $\theta_o$  分别为系统的方位角输入量、负载加载角度； $u$  为控制电压； $W_1(s)$  为位置控制器，控制位置环； $W_2(s)$  为速度控制器，控制速度环； $W_3(s)$  为电流控制器，控制电流环； $K_v$ 、 $K_\alpha$ 、 $K_\beta$  分别为反电势、电流反馈、速度反馈增益系数； $T_L$ 、 $T_d$  分别为负载力矩、电机电磁转矩； $J$  为负载等效转动惯量； $L$ 、 $R$ 、 $B$  分别为电机的电枢回路电感值、回路电阻值、黏性摩擦系数； $i$  为减速比。

图 2 的虚线为系统的电流环，其控制对象主要为电枢回路、滤波电路和逆变器 3 部分。

电枢回路和滤波电路均可等效为一阶惯性环节，反电动势的反馈对电流环的影响不大，可以忽略；因此，电流环的控制对象可以看作是 2 个一阶惯性环节的串联<sup>[9]</sup>。将 PI 控制引入  $W_3(s)$ ，通过零极点对消和简化可得到图 3 所示的系统框图。

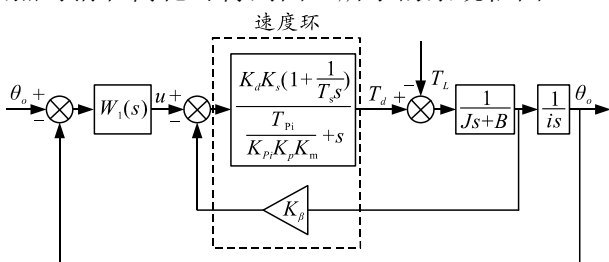


图 3 简化系统框图

图中虚线框为速度环，易得速度环开环传递函数为：

$$G(s) = \frac{K_s(T_s s + 1)K_T}{J s^2 T_s (1 + s / (K_{Pi} K_p K_m / T_{Pi}))} \quad (1)$$

式中： $K_s$ 、 $T_s$  分别为速度环的放大倍数、积分时间常数； $K_p$ 、 $K_{Pi}$ 、 $K_m$  分别为逆变器增益、电流调节器比例放大倍数、电机电枢回路时间常数； $T_{Pi}$  为调节器比例积分的时间常数。

### 2 自抗扰控制器概述

自抗扰控制器的核心是在 PID 的误差反馈控制的基础上，将系统里的扰动或者不确定性变成一个新的状态，由扩张状态观测器对其估计，然后进行补偿<sup>[10]</sup>。二阶系统的自抗扰控制器结构如图 4 所示。

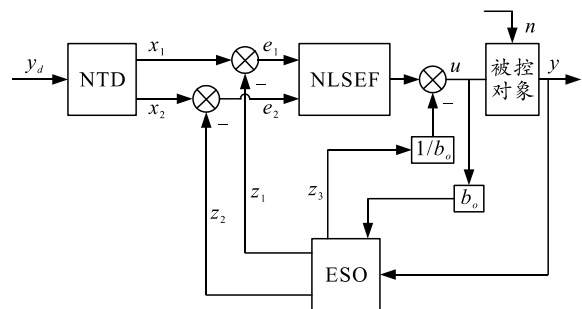


图 4 ADRC 结构

非线性跟踪微分器 (nonlinear tracking differentiator, NTD) 负责跟踪输入信号  $y_d$  以及输入信号的微分  $dy_d$ , 主要作用是过渡 (将输入信号进行平滑处理, 防止出现如阶跃信号那样的突变) 和过滤高频噪音。

扩张状态观测器 (extended state observer, ESO) 的主要作用是观测和反馈被控对象的状态变量  $z_1$ 、 $z_2$ , 并且将系统内外的扰动扩张成一种新的状态变量  $z_3$ , 对其估计并将补偿值与非线性状态反馈器的输出值一起形成控制量。

非线性状态反馈器 (nonlinear state error feedback, NLSEF) 的作用是将输入信号 (误差和误差微分) 通过非线性函数进行组合。

ADRC 离散表达式为:

NTD:

$$\left. \begin{aligned} x_1(k+1) &= x_1(k) + hx_2(k) \\ x_2(k+1) &= x_2(k) + hfst(x_1(k) - y_d(k), x_2(k)r, h_0) \end{aligned} \right\} \quad (2)$$

式中:  $h$  为积分步长;  $r$  与跟踪速度有关,  $r$  越大跟踪速度越快;  $h_0$  为滤波因子, 主要影响滤波效果, 一般控制在比  $h$  稍大一些;  $fst(\bullet)$  为最优控制函数, 其展开的离散表达式为:

$$\left. \begin{aligned} fst(x_1(k), x_2(k), r, h_0) &= \begin{cases} -r(a/d), & |a| \leq d \\ -r \operatorname{sgn}(a), & |a| > d \end{cases} \\ a &= \begin{cases} x_2(k) + (a_0 - d) \operatorname{sgn}(y(k)) / 2, & |y(k)| > d_0 \\ x_2(k) + y(k) / h, & |y(k)| \leq d_0 \end{cases} \\ d &= rh, d_0 = dh, a_0 = \sqrt{d^2 + 8r|y(k)|} \\ y(k) &= x_1(k) + hx_2(k) \end{aligned} \right\} \quad (3)$$

ESO:

$$\left. \begin{aligned} e(k) &= z_1(k) - y(k) \\ z_1(k+1) &= z_1(k) - h[z_2(k) - \beta_1 e(k)] \\ z_2(k+1) &= z_2(k) - \\ &h[z_3(k) - \beta_2 \operatorname{fal}(e(k), \alpha_1, \delta_1) + b_0 u(k)] \\ z_3(k+1) &= z_3(k) - h\beta_3 \operatorname{fal}(e(k), \alpha_2, \delta_1) \end{aligned} \right\} \quad (4)$$

式中:  $h$  为积分步长;  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$  为误差校正增益;  $\alpha_1$ 、 $\alpha_2$  为非线性因子;  $\delta_1$  为平滑滤波因子; 输出值  $z_1$  跟踪  $y$ ;  $z_2$  跟踪  $dy$ ;  $z_3$  估计系统内外扰动以及不确定因素等;  $\operatorname{fal}(\bullet)$  为非线性函数, 其展开表达式为:

$$\operatorname{fal}(e(k), \alpha, \delta) = \begin{cases} |e(k)|^\alpha \operatorname{sgn}(e(k)), & |e(k)| > \delta \\ e(k) / \delta^{1-\alpha}, & |e(k)| \leq \delta \end{cases} \quad (5)$$

NLSEF:

$$\left. \begin{aligned} e_1(k+1) &= x_1(k+1) - z_1(k+1) \\ e_2(k+1) &= x_2(k+1) - z_2(k+1) \\ u &= \beta_{01} \operatorname{fal}(e_1(k+1), \alpha_3, \delta_2) + \\ &\beta_{02} \operatorname{fal}(e_2(k+1), \alpha_4, \delta_3) + z_3(k+1) / b_0 \end{aligned} \right\} \quad (6)$$

式中:  $\beta_{01}$ 、 $\beta_{02}$  为非线性误差增益;  $\alpha_3$ 、 $\alpha_4$  为非线性因子;  $b_0$  为调整因子。

### 3 WNN-ADRC 设计

#### 3.1 WNN

小波神经网络中的小波函数是由母小波函数平移和伸缩变换而来, 可以避免局部最优的同时在时频域具有紧支性<sup>[11]</sup>。小波神经网络的结构如图 5。




图 5 小波神经网络的结构

其结构与 BP 神经网络相似,  $W_{ij}$  和  $W_{jf}$  为神经网络的权值, 隐含层的激活函数被替换成了小波函数  $\psi_n(\bullet)$ , 学习方法为梯度下降法。

输入层的输入为:  $x_1, x_2, \dots, x_n$ 。

隐含层的输入和输出为:

$$O_j = W_{ij} x_i; \quad (7)$$

$$\psi(j) = \psi \left( \sum_{i=1}^n W_{ij} x_i - b_j / a_j \right), \quad j = 1, 2, \dots, l. \quad (8)$$

式中:  $O_j$ 、 $\psi(j)$  分别为隐含层第  $j$  个节点的输入和输出值;  $n$ 、 $l$  分别为输入层、隐含层节点数;  $b_j$ 、 $a_j$  分别为平移因子、伸缩因子。

输出层的输出为:

$$y(f) = \sum_{j=1}^l W_{jf} \psi(j), \quad j = 1, 2, \dots, l, \quad f = 1, 2, \dots, m; \quad (9)$$

$$e = y(f) - y_d(f). \quad (10)$$

式中:  $y(f)$ 、 $y_d(f)$  分别为输出层第  $f$  个节点的实际输出、期望输出;  $e$  为误差;  $m$  为输出层节点数。

#### 3.2 WNN-ADRC

ADRC 虽然性能优越, 但存在参数较多难以选定的问题。下面列出在设计 ADRC 时影响较大参数和常用的选定方法: ESO 中的误差校正增益  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$  一般根据系统脉宽的选定公式 ( $\beta_1 = 3w_0$ ,  $\beta_2 = 3w_0^2$ ,  $\beta_3 = w_0^3$ ,  $w_0$  为系统脉宽) 取初值, 然后通过大量仿真实验取合适值; NLSEF 中的非线性误差增益  $\beta_{01}$ 、

$\beta_{02}$  和增益系数  $b$  可根据文献[12]中的多次改变对比、大范围搜寻的方法来取值。

ADRC 的参数大多是根据大量仿真实验的经验来选择, 计算量大且准确度较低, 无法完全发挥 ADRC 的控制性能。神经网络则是可以逼近任意非线性函数, 因此将神经网络嵌入至 ADRC 中能很好地实时在线调整 ADRC。在多次仿真选定参数的过程中发现, ESO 中的重要参数  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$  对最终的结果影响较大。其中,  $\beta_1$ 、 $\beta_2$  与状态变量的估计值相关,  $\beta_3$  则是与系统内外扰动等因素相关。笔者将 WNN 嵌入至 ADRC 中通过 WNN 对 ADRC 中 ESO 的参数进行在线整定。其工作原理如图 6 所示。




图6 WNN-ADRC工作原理

图中: WNN 的输入层节点数  $n=4$ , 分别是  $x_1=e_1(k)$  (信号误差)、误差微分  $x_2=e_2(k)$  (误差微分)、 $x_3=y$  (系统的输出) 和  $x_4=1$ ; 隐含层为 1 层, 节点数为  $l=5$  (根据隐含层节点选定公式  $l=\sqrt{nm+1.6799n+0.9298}$ ); 输出层节点  $m=3$ , 输出为 ESO 中所需的参数  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$ 。

小波函数选择常用 Morlet 母小波基函数:

$$\psi(x) = \cos(1.75)e^{-x^2/2}。 \quad (11)$$

设小波神经网络的目标函数为:

$$E = \frac{1}{2}(y_a(k) - y(k))^2 = \frac{1}{2} \sum_{k=1}^m e(k)^2。 \quad (12)$$

式中:  $y_a(k)$ 、 $y(k)$ 、 $e(k)$  分别为第  $k$  时刻的系统期望输出、系统实际输出、系统输出误差。

用梯度下降法来修正小波神经网络的权值  $W_{ij}$  和  $W_{if}$ , 以及小波基函数系数  $b_j$  和  $a_j$ 。

$$\left. \begin{aligned} W_{ij}(k+1) &= W_{ij}(k) - \eta(\partial E / \partial W_{ij}) \\ W_{if}(k+1) &= W_{if}(k) - \eta(\partial E / \partial W_{if}) \\ a_j(k+1) &= a_j(k) - \eta(\partial E / \partial a_j) \\ b_j(k+1) &= b_j(k) - \eta(\partial E / \partial b_j) \end{aligned} \right\}。 \quad (13)$$

式中:  $W_{ij}(k+1)$ 、 $W_{if}(k+1)$ 、 $a_j(k+1)$ 、 $b_j(k+1)$  为该小波神经网络第  $k$  时刻更新后的权值和系数;  $\eta$  为学习率。

由上可知, WNN-ADRC 在修正权值和系数时

需要用梯度下降的学习方式依次推导出  $\partial E / \partial W_{ij}$ 、 $\partial E / \partial W_{if}$ 、 $\partial E / \partial a_j$ 、 $\partial E / \partial b_j$ 。推导过程如下所示:

$$\left. \begin{aligned} \frac{\partial E(k)}{\partial W_{ij}} &= \frac{\partial E(k)}{\partial y(k)} \frac{\partial y(k)}{\partial O_f(k)} \frac{\partial O_f(k)}{\partial \psi_j(k)} * \\ &\frac{\partial \psi_j(k)}{\partial \text{net}_j(k)} \frac{\partial \text{net}_j(k)}{\partial W_{ij}}, i=1, 2, \dots, n \\ O_f(k) &= \psi_j(\text{net}_j(k)) W_{if}, f=1, 2, \dots, m \\ \text{net}_j(k) &= \frac{(\sum_{i=1}^n W_{ij} x_i(k) - b_j)}{a_j}, j=1, 2, \dots, l \end{aligned} \right\}。 \quad (14)$$

式中:  $\text{net}_j(k)$ 、 $\psi_j(k)$  分别为第  $k$  时刻的隐含层第  $j$  个节点的输入、输出;  $O_f(k)$  为输出层第  $f$  个节点的输出。

由于  $\partial y(k) / \partial O_f(k)$  未知, 可用近似符号  $\text{sign}(\partial y(k) / \partial O_f(k))$  取代, 其中引起的误差可参照文献[13]用分层调整学习率  $\eta$  的方式来优化 WNN-ADRC 的学习方法, 而且由于  $\eta$  的取值会直接影响到学习效果, 分层调整的方式可改善其作用。其原理主要基于负梯度下降的学习方式, 当误差曲线较为平缓且误差在减小时适当增大学习速率, 从而减少计算时间, 反之减小。

将  $\eta$  的值设定为较小的值, 当  $e(k+1) < e(k)$  时, 按照分层调节学习率的方式增大该方向的学习速率直至误差不再减小, 然后记录该时刻的阈值和权值; 反之减小学习速率, 直至误差减小, 记录阈值和权值; 然后进入下个时刻。其离散表达型式如下:

$$\left. \begin{aligned} \eta(j+1) &= a\eta(j), e(k+1) > e(k), a > 1 \\ \eta(j+1) &= b\eta(j), e(k+1) < e(k), 0 < b < 1 \end{aligned} \right\}。 \quad (15)$$

通过该调节方法可降低近似符号  $\text{sign}$  带来的误差, 综上所述可得:

$$\frac{\partial E(k)}{\partial W_{ij}} = -e(k) \text{sign}\left(\frac{\partial y(k)}{\partial O_f(k)}\right) W_{if} \psi_j'(k) \frac{x_i(k)}{a_j}。 \quad (16)$$

同理可得:

$$\left. \begin{aligned} \frac{\partial E(k)}{\partial W_{if}} &= -e(k) \text{sign}\left(\frac{\partial y(k)}{\partial O_f(k)}\right) \psi_j(k) \\ \frac{\partial E(k)}{\partial a_j} &= e(k) \text{sign}\left(\frac{\partial y(k)}{\partial O_f(k)}\right) W_{if} \psi_j'(k) \frac{\text{net}_j(k)}{a_j} \\ \frac{\partial E(k)}{\partial b_j} &= e(k) \text{sign}\left(\frac{\partial y(k)}{\partial O_f(k)}\right) W_{if} \psi_j'(k) \frac{1}{a_j} \end{aligned} \right\}。 \quad (17)$$

WNN-ADRC 工作的流程如图 7 所示。

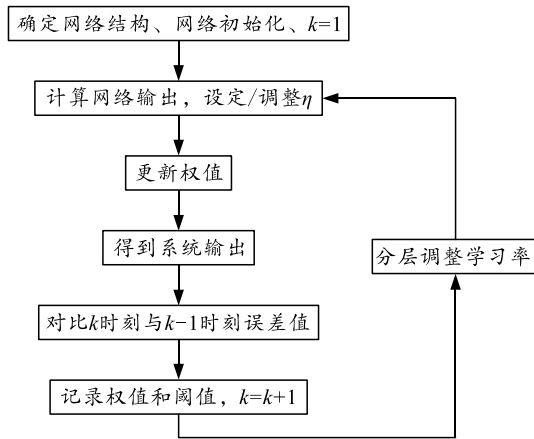


图 7 WNN-ADRC 流程

### 4 仿真验证

为验证该控制器的控制和抗干扰等能力，在 Matlab/Simulink 中搭建 WNN-ADRC、ADRC 模型和被控对象(火箭炮伺服系统)并进行仿真，通过两者对比仿真实验来验证控制性能。

被控对象中的伺服电机主要参数：极对数  $P_n=4$ ，电机绕组电感值  $L=8.5 \text{ mH}$ ，电机电阻值  $R=2.875 \text{ } \Omega$ ，转动惯量  $J=0.002 \text{ 2 kg}\cdot\text{m}^2$ ，粘滞系数  $B=0.008 \text{ N}\cdot\text{m}\cdot\text{s}$ 。

ADRC 3 个模块对应的参数设定为：

NTD:  $r=2 \text{ 000}$ ,  $h=0.01$ ,  $h_0=0.1$ ; NLSEF:  $\beta_{01}=10$ ,  $\beta_{02}=32$ ,  $\alpha_3=0.6$ ,  $\alpha_4=0.3$ ,  $b_0=1$ ; ESO:  $\beta_1=10$ ,  $\beta_2=150$ ,  $\beta_3=500$ ,  $\alpha_1=0.5$ ,  $\alpha_2=0.25$ ,  $\delta_1=0.1$ 。

WNN-ADRC 的初始参数设定：为重点体现 WNN 在线整定参数的效果，除了以 WNN 神经网络的输出为 ESO 中的  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$ ，其他参数都与 ADRC 一致。

#### 1) 阶跃输入测试。

给定目标输入为  $50^\circ$ ，仿真时间为  $10 \text{ s}$ ，为验证其抗干扰能力，在系统到达稳态后( $5 \text{ s}$ )加入一个  $20 \text{ N}\cdot\text{m}$  的力矩扰动，模拟火箭炮发射时的冲击力矩，其仿真结果如图 8 和 9 所示。




图 8 阶跃响应曲线




图 9 带负载干扰的阶跃响应曲线

图 8 中：ADRC 到达系统过渡状态(进入  $\pm 5\%$  的误差范围)需要  $1.78 \text{ s}$ ；而 WNN-ADRC 到达系统过渡状态只需要  $1.07 \text{ s}$ 。两者都无明显超调。仿真结果表明 WNN-ADRC 的响应速度和收敛速度更快。图 9 中：加入力矩干扰后传统 ADRC 需要  $1.68 \text{ s}$  回到初始位置，最大误差值为  $1.78^\circ$ ；而 WNN-ADRC 只需要  $0.78^\circ$  回到初始位置，最大误差值为  $1.39^\circ$ 。仿真结果表明，WNN-ADRC 在系统进入稳态后收到干扰能更迅速地恢复稳定，鲁棒性更强。

#### 2) 正弦输入测试。

为验证控制器的动态特性，将系统的输入设定角度区间为  $[-50, 50]$ 、角速度为  $1 \text{ rad/s}$  的正弦信号 ( $y=50 \sin(t)$ )。仿真时间为 3 个周期( $T=2\pi$ )。仿真结果如图 10 和 11 所示。

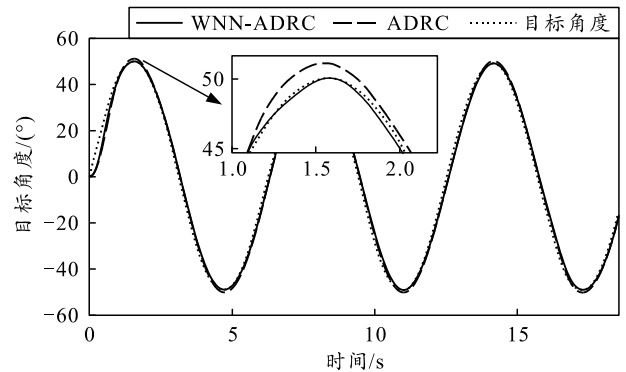


图 10 正弦响应曲线




图 11 正弦响应误差