

doi: 10.7690/bgzdh.2020.11.010

基于 WNN-ADRC 的高炮交流伺服系统控制

李佳恬¹, 高强¹, 巩晋², 侯远龙¹, 李俊杰¹

(1. 南京理工大学机械工程学院, 南京 210094; 2. 中国兵器工业导航与控制技术研究所, 北京 100089)

摘要: 为解决高炮交流伺服系统控制中外界扰动及非线性特性的问题, 提出一种基于小波神经网络的改进型自抗扰控制器(WNN-ADRC)。利用 LM(levenberg-marquardt)算法优化小波神经网络, 采用优化后的小波神经网络对扩张状态观测器的误差校正增益系数进行在线整定, 设计基于小波神经网络的自抗扰控制器, 以实现非线性特性的准确估计并予以补偿, 并通过仿真实验进行验证。仿真结果证明: 该控制策略使系统具有较好的稳态性能, 抗干扰能力强。

关键词: 小波神经网络; 交流伺服控制; 自抗扰控制; LM 算法

中图分类号: TJ35; TP273 **文献标志码:** A

AC Servo System Control of Antiaircraft Gun Based on WNN-ADRC

Li Jiatian¹, Gao Qiang¹, Gong Jin², Hou Yuanlong¹, Li Junjie¹

(1. School of Mechanical Engineering, Nanjing University of Science & Technology, Nanjing 210094, China;
2. Navigation & Control Technology Institute of China North Industries Group Corporation, Beijing 100089, China)

Abstract: To solve the problems of external disturbance and non-linear characteristics in the positioning control of the servo system of antiaircraft gun, an improved active disturbance rejection controller (WNN-ADRC) based on wavelet neural network is proposed. The Levenberg-marquardt algorithm is used to optimize the wavelet neural network. Using wavelet neural network adjust the error correction gain coefficient in the expanded state observer on-line, design an active disturbance rejection controller based on wavelet neural network to achieve accurate estimation and compensation of nonlinear characteristics, and verified by simulation experiments. Simulation results show that this control strategy makes the system has better steady-state performance and strong anti-interference ability.

Keywords: wavelet neural network; AC servo control; active disturbance rejection control; LM algorithm

0 引言

高炮武器系统作为末端防御武器, 在反空袭防空体系中有十分重要的作用。高炮武器必须具备快速反应能力以及良好的跟踪精度, 实现对目标的精准快速打击。高炮位置伺服系统采用永磁同步电机(permanent magnet synchronous motor, PMSM)作为驱动电机。PMSM 是一种具有非线性、强耦合、时变性的系统。在实际工作过程中, 温度上升、电机老化以及工况恶劣等因素都会导致 PMSM 的电气参数无法稳定在一固定值。除此之外, 高炮炮控交流伺服系统中存在着一些无法规避的非线性因素, 如齿轮间隙、摩擦力矩、负载变化, 以及工作环境变化引起的系统参数时变等问题。使用传统 PID 控制器, 实现系统的高精度跟踪较为困难, 也无法保证良好的鲁棒性^[1-2]。

为在内外负载扰动存在的前提下获得良好性能, 1998 年, 韩京清教授团队提出了自抗扰控制理

论(active disturbance rejection control, ADRC)。该理论的核心是将未建模动态部分以及外扰动归为总扰动量, 由扩张状态观测器(extended state observer, ESO)实时在线估计并予以补偿^[3]。

小波神经网络(wavelet neural network, WNN)能够进行在线学习, 逼近任意非线性连续函数能力强, 在时域频域都具有良好的分辨性能^[4]。与传统神经网络中的 Sigmoid 函数不同, 小波函数具有空间局部化特性。这一特性使得小波神经网络在控制及系统辨识上具有较好的学习能力^[5-7]。LM(levenberg-marquardt)算法同时具有 Gauss-Newton 法的局部收敛性以及梯度下降法的全局特性^[8], 可将其引入对 WNN 的连接权值与阈值进行优化, 增强其学习能力。

文献[9]为使用 PMSM 驱动的火箭炮提出了一种改进型分数阶自抗扰控制器, 抗负载干扰能力强, 动静特性良好; 文献[10]在对某武器伺服系统位置环控制研究中, 将 RBF 神经网络引入 ADRC, 可

收稿日期: 2020-07-12; 修回日期: 2020-08-08

作者简介: 李佳恬(1995—), 女, 天津人, 硕士, 从事智能检测与控制技术研究。E-mail: 767436520@qq.com。

对参数实时在线调整,抗扰动性能好,稳态精度高;文献[11]将 BP 神经网络引入 ADRC,设计自适应 ESO,实现参数的在线寻优;文献[12]将粒子群算法与人工免疫算法相融合,对 ADRC 中的参数进行优化。

笔者将基于 LM 算法优化的 WNN 与 ADRC 结合起来,在线整定扩张观测器反馈控制量的增益系数 β_{01} 、 β_{02} 、 β_{03} 。实现对信号的准确跟踪,以及对非线性特性的实时估计和补偿,使控制器获得更良好的抗扰性能。

1 小波神经网络及改进

1.1 小波神经网络

1992 年,法国 IRISA 的 Zhang Qinghua 提出小波神经网络。小波神经网络将传统神经网络的激活函数替换为小波元,实现了小波分析与人工神经网络的结合,兼具二者的优点。通过小波伸缩以及小波平移得到小波函数。小波的紧支性使其在学习非线性函数时具有较好的逼近性能,且收敛速度较快。小波神经网络包括松散型与紧密型。笔者选用紧密型小波神经网络,结构如图 1 所示。




图 1 小波神经网络模型结构

紧密型小波神经网络分为输入层、隐含层和输出层。小波神经网络在 BP 神经网络的基础上,使用小波基函数作为隐含层节点的激励函数。信号在向前传递的过程中,将误差反向传播。用小波函数的尺度替换输入层到隐含层的权值,用平移参数替换阈值。对小波神经网络的尺度因子和平移因子进行调整,可以使网络具有更强的数据处理能力。

$\psi(\cdot)$ 为激励函数,文中隐含层神经元激励函数选取 Morlet 小波,可表示为

$$\psi(x) = \cos(1.75x)e^{-x^2/2} \quad (1)$$

设网络输入变量为 $X=(x_1, x_2, \dots, x_n)^T$, $y(k)$ 为网络输出。小波神经网络的输出层计算公式为:

$$y(k) = \sum_{j=1}^l v_{jk} \psi_j(n_j), \quad k=1, 2, \dots, m \quad (2)$$

其中: $n_j = \left(\sum_{i=1}^n x_i w_{ij} - b_j \right) / a_j, \quad j=1, 2, \dots, l$; l 为隐含

层节点数; m 为输出层的节点个数; a_j 为小波基函数的伸缩因子, b_j 为平移因子; w_{ij} 为输入层的第 i 个神经元到第 j 个隐含层神经元的连接权值; v_{jk} 为第 j 个隐含层神经元到输出层第 k 个神经元的连接权值。

小波神经网络隐含层节点数对网络的训练学习十分重要,还会影响辨识效果。隐含层节点太少,网络无法保证学习速度,容易陷入局部极小值。隐含层节点过多,增加了网络结构的复杂性,会使训练时间增长,影响网络处理能力。根据经验公式 $N = \sqrt{nm + 1.6799n + 0.9298}$, 计算隐含层节点个数。 n 为输入节点数, m 为输出节点数。

WNN 的目标性能函数为:

$$E = \frac{1}{2} \sum_{k=1}^m (y(k) - y_d(k))^2 = \frac{1}{2} \sum_{k=1}^m e_k^2 \quad (3)$$

式中: $y(k)$ 为网络实际输出; $y_d(k)$ 为网络预期输出。利用梯度下降法修正网络权值及小波函数参数, η 为学习速率,迭代公式为:

$$w_{ij}(n+1) = w_{ij}(n) - \eta (\partial E / \partial w_{ij}); \quad (4)$$

$$v_{jk}(n+1) = v_{jk}(n) - \eta (\partial E / \partial v_{jk}); \quad (5)$$

$$a_j(n+1) = a_j(n) - \eta (\partial E / \partial a_j); \quad (6)$$

$$b_j(n+1) = b_j(n) - \eta (\partial E / \partial b_j) \quad (7)$$

其中:

$$\partial E / \partial w_{ij} = (y_d(k) - y(k)) \psi_j(n_j); \quad (8)$$

$$\partial E / \partial v_{jk} = ((y_d(k) - y(k)) w_{ij}) \psi_j(n_j) (x_i / a_j); \quad (9)$$

$$\frac{\partial E}{\partial a_j} = ((y_d(k) - y(k)) w_{ij}) \psi_j(n_j) \frac{\sum_{i=1}^n w_{ij} - b_j}{a_j^2}; \quad (10)$$

$$\partial E / \partial b_j = ((y_d(k) - y(k)) w_{ij}) \psi_j(n_j) (1/a_j) \quad (11)$$

1.2 基于 LM 算法优化的小波神经网络

利用梯度下降法训练的传统小波神经网络学习速率不易确定,且收敛速度慢;因此,笔者引入 LM 算法对小波神经网络算法进行优化。LM 算法利用近似 2 阶导数信息,减少了迭代次数,收敛速度相较于梯度下降法有明显提高。

$x^{(k)}$ 表示第 k 次迭代时由参数 a_j 、 b_j 、 w_{ij} 、 v_{ik} 构成的向量,即:

$$x = [w_{11}, w_{12}, \dots, w_{j1}, w_{j2}, \dots, w_{ij}, v_{11}, v_{12}, \dots, v_{1k}, \dots, v_{j1}, v_{j2}, \dots, v_{jk}, a_1, a_2, \dots, a_j, b_1, b_2, \dots, b_j] \quad (12)$$

则 $k+1$ 次时新参数向量可表示为:

$$x^{(k+1)}=x^{(k)}-\Delta x. \quad (13)$$

误差指标函数为：

$$E(x)=\frac{1}{2}\sum_{i=1}^N e_i^2(x). \quad (14)$$

LM 算法改进小波神经网络的权值修正量为：

$$\Delta x=[J^T(x)J(x)+\mu I]^{-1}J^T(x)e(x). \quad (15)$$

$J=\partial e_i(x)/\partial x_i$ 为雅克比矩阵，即

$$J(x)=\begin{bmatrix} \partial e_1(x)/\partial x_1 & \partial e_2(x)/\partial x_2 & \dots & \partial e_1(x)/\partial x_n \\ \partial e_1(x)/\partial x_1 & \partial e_2(x)/\partial x_2 & \dots & \partial e_2(x)/\partial x_n \\ \vdots & \vdots & & \vdots \\ \partial e_N(x)/\partial x_1 & \partial e_N(x)/\partial x_2 & \dots & \partial e_N(x)/\partial x_n \end{bmatrix}. \quad (16)$$

LM 改进型小波神经网络算法迭代步骤如下：

1) 确定网络训练误差允许值 ε ，最大训练次数 M 。对比例系数 μ 以及步进因子 $\beta(1<\beta<10)$ 进行初始化 $\mu=\mu_0, k=0$ 。

2) 计算网络输出及目标误差函数。

3) 计算 Jacobian 矩阵。

4) 计算权值修正量 Δx 。

5) 判断是否 $E<\varepsilon$ 或 $k>M$ ，若已经收敛或达到最大训练次数，则结束训练；否，则以 $x^{(k+1)}$ 计算新的权值向量，并求出 $E(x^{(k+1)})$ 。

6) 如果 $E(x^{(k+1)})<E(x^{(k)})$ ，则 $k=k+1, \mu=\mu/\beta$ ，转到 2)；否，则 $E(x^{(k+1)})=E(x^{(k)})$ ， $\mu=\mu\beta$ ，转到 4)。

7) 停止。

2 ADRC 概述

自抗扰控制器由非线性跟踪微分器 (nonlinear tracking differentiator, NTD)、扩张状态观测器 (extended state observer, ESO)、非线性状态误差反馈器 (nonlinear state error feedback control law, NLSEF) 3 部分组成。利用 NTD 安排过渡过程，提取连续信号以及微分信号。ESO 对未建模动态部分以及外扰动进行估计并予以补偿。利用 NLSEF 配置非线性结构，给出实际的控制信号。2 阶 ADRC 结构如图 2 所示。

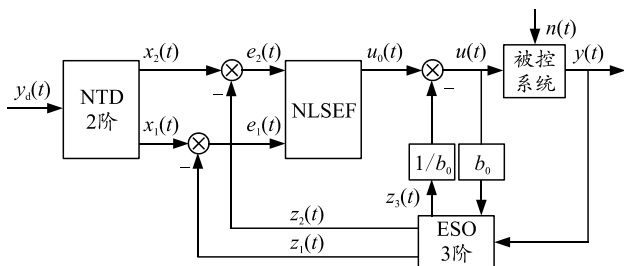


图 2 ADRC 结构

$y_d^{(i)}$ 为 2 阶系统输入值， $y(t)$ 实际目标输出， $n(t)$

为外扰作用。

2.1 NTD

NTD 的功能是安排过渡过程，对输入信号进行快速且无超调跟踪。通过 NTD 处理，可以实现 $x_1 \rightarrow y_d(t), x_2 \rightarrow \dot{y}_d(t)$ ，使控制目标信号缓慢变化；克服了常规微分器中出现的噪声放大效应，当参数设置突然发生变化时，能够有效抑制控制量的波动及输出的超调。

r 决定跟踪速度， h_0 为滤波因子， h 为积分步长，则 NTD 的离散表达式为：

$$\left. \begin{aligned} x_1(k+1) &= x_1(k) + hx_2(k) \\ x_2(k+1) &= x_2(k) + hfst(x_1(k) - y_d(k), x_2(k), r, h_0) \end{aligned} \right\}. \quad (17)$$

其中 $fst(\cdot)$ 为离散系统最速控制函数，展开为：

$$\left. \begin{aligned} fst(x_1(k), x_2(k), r, h) &= \begin{cases} -r(a/d), & |a| \leq d \\ -r \operatorname{sgn}(a), & |a| > d \end{cases} \\ a &= \begin{cases} x_2(k) + \frac{a_0 - d}{2} \operatorname{sgn}(y(k)), & |y(k)| > d_0 \\ x_2(k) + \frac{y(k)}{h}, & |y(k)| \leq d_0 \end{cases} \\ d &= rh, d_0 = dh, a_0 = \sqrt{d^2 + 8r|y(k)|} \\ y(k) &= x_1(k) + hx_2(k) \end{aligned} \right\}. \quad (18)$$

2.2 ESO

ESO 的核心是估计系统中的不确定动态。根据反馈线性化理论，对被控对象系统内外扰动进行动态估计及补偿，使其形成积分器串联型结构。该做法可消除对象的不确定性，达到更良好的闭环控制效果。ESO 将影响被控对象输出的扰动作用扩张成新的状态变量，且根据控制变量和输入目标值估计误差的变化率。对于常见的 2 阶系统，ESO 离散表达式如下：

$$\left. \begin{aligned} e(k) &= z_1(k) - y(k) \\ z_1(k+1) &= z_1(k) - h[z_2(k) - \beta_{01}e(k)] \\ z_2(k+1) &= z_2(k) + h[z_3(k) - \beta_{02}fal(e(k), \alpha_1, \delta_1) + b_0u(k)] \\ z_3(k+1) &= z_3(k) - h\beta_{03}fal(e(k), \alpha_2, \delta_1) \end{aligned} \right\}. \quad (19)$$

其中， $z_1(k)$ 跟踪 $y(k)$ ， $z_2(k)$ 跟踪 $\dot{y}(k)$ ， $z_3(k)$ 是系统内外扰动总估计值。为使 ESO 获得良好工作效果，可对误差校正增益 β_{01} 、 β_{02} 、 β_{03} ，非线性因子 α_1 、 α_2 与平滑滤波因子 δ_1 等参数进行优化设计。 $fal(\cdot)$ 具有误差与增益成反比的特点，为抑制高频震颤的发

生, 将非线性函数 $\text{fal}(e(k), \alpha, \delta)$ 定义如下:

$$\text{fal}(e(k), \alpha, \delta) = \begin{cases} |e(k)|^\alpha \text{sgn}(e(k)) & |e(k)| > \delta \\ \frac{e(k)}{\delta^{1-\alpha}} & |e(k)| \leq \delta \end{cases} \quad (20)$$

2.3 NLSEF

NLSEF 计算 ESO 中观测到的状态值与非线性跟踪微分器 (nonlinear tracking differentiator, NTD) 输出之间的误差值, 并将误差按一定的非线性组合形成控制量 u_0 。对 PID 中由线性组合得到的控制量不能随系统状态灵活取值的问题进行改进, 可得到更适合系统动态特性的非线性组合, 从而提高控制精度。 β_1 、 β_2 为非线性误差增益。NLSEF 离散表达式为:

$$\left. \begin{aligned} e_1(k+1) &= x_1(k+1) - z_1(k+1) \\ e_2(k+1) &= x_2(k+1) - z_2(k+1) \\ u_0(k+1) &= \beta_1 \text{fal}(e_1(k+1), \alpha_3, \delta_2) + \beta_2 \text{fal}(e_2(k+1), \alpha_4, \delta_3) \end{aligned} \right\} \quad (21)$$

实际的控制变量表示为:

$$u(k+1) = u_0(k+1) - z_3(k+1)/b_0 \quad (22)$$

其中 b_0 为调整因子。

3 WNN-ADRC 控制器设计

在实际工程应用中, ADRC 中需要设置的参数数量较多, 整定过程较为复杂。NTD 中, 主要与性能相关的参数为速度因子 r 与积分步长 h 。 r 可根据系统的响应时间以及承受能力进行选取。 h 则可以依据滤波因子 h_0 选取。对于 NLSEF 中的非线性增益 β_1 、 β_2 , 其选取需要大量的仿真实验作为基础, 较为依赖工程经验。

ESO 中, 有 3 个重要的参数 β_{01} 、 β_{02} 、 β_{03} , 取值与 h 有密切关系。 β_{01} 、 β_{02} 与状态变量的估计值有关。 β_{01} 、 β_{02} 越大, 对输出信号及其微分的跟踪也越快。 β_{03} 关系着扰动估计 z_3 , 而 z_3 决定着扰动补偿的精度, 继而影响系统的控制效果。将外扰以及被控对象变化作为依据, 调整 β_{01} 、 β_{02} 、 β_{03} 。提高估计精度, 改善系统的闭环动态特性, 从而获得更加良好的控制效果。

笔者将小波神经网络嵌入到 ADRC 中, 利用基于 LM 算法改进后的 WNN 对 β_{01} 、 β_{02} 、 β_{03} 进行在线整定, 设计基于小波神经网络的自抗扰控制器, 结构如图 3 所示。

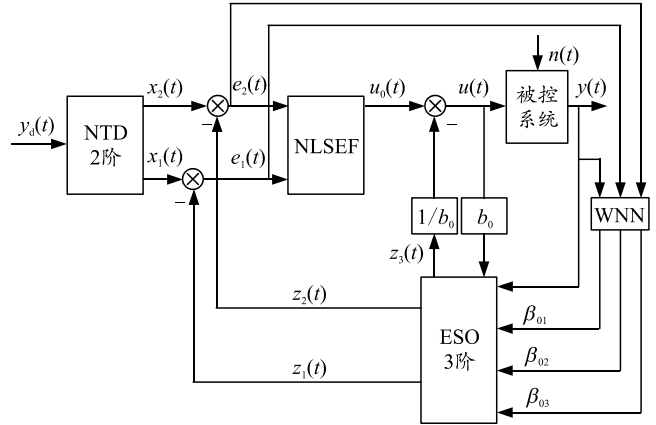


图 3 SRWNN-ADRC 控制器结构

笔者采用 3 层小波神经网络, 设置 WNN 输入节点个数为 4。令 WNN 输入为 $x_1=e_1(t)$ 、 $x_2=e_2(t)$ 、 $x_3=y(t)$ 、 $x_4=1$ 。 e_1 为信号误差, e_2 为信号微分误差。根据经验公式(编号), 确定隐含层节点数为 5。输出节点个数为 3, 分别表示 β_{01} 、 β_{02} 、 β_{03} 。

用于整定 ESO 中误差校正增益的小波神经网络结构为 4-5-3。WNN 的训练基于 LM 优化算法, 其输出权值的迭代函数由 1.2 节可知。小波神经网络输出为:

$$\beta_{0k} = y(k) = \sum_{j=1}^5 v_{jk} \psi \left(\frac{\sum_{i=1}^4 x_i w_{ij} - b_j}{a_j} \right), \quad k=1,2,3. \quad (23)$$

4 仿真实验与分析

为验证笔者设计的 WNN-ADRC 可行性及有效性, 在 Matlab 中进行仿真实验。在大量实验及总结后, 对 WNN-ADRC 中的参数进行以下设计: NTD 参数为 $r=1\ 000$, $h=0.01$, $h_0=0.1$; ESO 参数为 $\alpha_1=0.5$, $\alpha_2=0.25$, $\delta_1=0.1$, $b_0=526.5$, 初选 $\beta_{01}=1$, $\beta_{02}=15.8$, $\beta_{03}=318.5$; NLSEF 参数为: $\delta_2=0.01$, $\delta_3=0.01$, $\alpha_3=0.6$, $\alpha_4=0.3$, $\beta_1=10$, $\beta_2=5$ 。LM 算法学习参数 $\mu_0=0.04$ 。

设定参考目标输入值为 25° , 仿真时间 10 s。阶跃响应曲线如图 4 所示, 传统 ADRC 与 WNN-ADRC 控制器均无超调。采用 ADRC 控制器, 系统到达稳态所需时间为 2.15 s, 采用 WNN-ADRC 控制器所需时间仅为 1.81 s, 这表明 WNN-ADRC 响应速度更快。阶跃响应误差曲线如图 5 所示。图 6 中在 4 s 时加入 300 N·m 阶跃干扰信号, WNN-ADRC 仅需 0.20 s 即可恢复至目标位置, 而 ADRC 需要 0.48 s。对比结果可知: WNN-ADRC 对外界负载扰动具有更好的鲁棒性, 抗干扰的能力更强。




图 4 阶跃响应位置

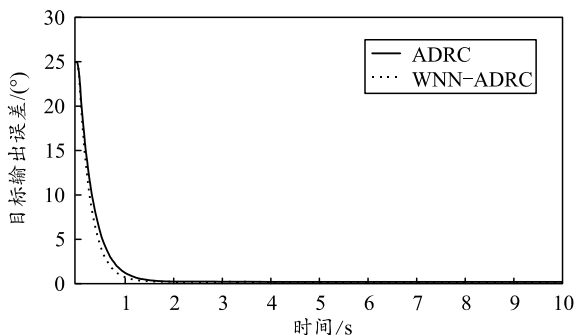


图 5 阶跃响应位置误差

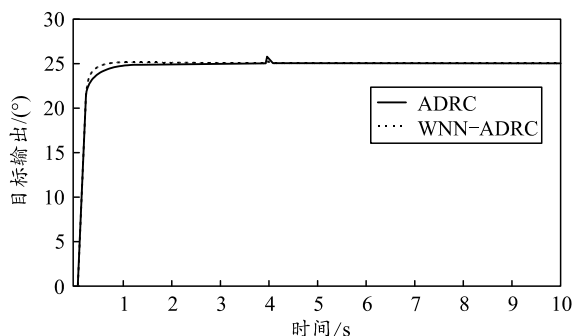


图 6 带负载扰动的阶跃响应

正弦跟踪误差曲线如图 7 所示，输入信号为 $y(t)=20\sin(t)$ ，幅值 20° ，仿真时间 20 s。在系统还未达到稳定前，WNN-ADRC 的正弦跟踪误差较大，但进入跟踪状态后，WNN-ADRC 最终误差峰值保持在 $\pm 0.05^\circ$ 内，而 ADRC 最大误差为 0.29° 。由仿真结果可知：WNN-ADRC 具有更加良好的动态特性，跟踪精度更高。

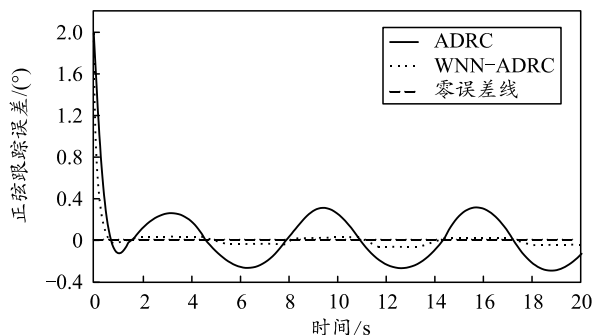


图 7 正弦跟踪误差

5 高炮随动系统实验与分析

高炮随动系统的输入为火控计算机给定的目标位置。位置环控制器将当前高炮身管位置量与目标值进行比较，通过嵌入的控制算法运算得到输出到执行机构的电压值。伺服驱动器驱动电机，减速器根据减速比调节转速及转矩的输出，使高炮身管调到目标位置。高炮随动系统的输出则为高炮转角。

高炮身管运动时高低角度大，重心变化也较大，非平衡力矩会造成外部扰动激励。高炮发射过程中燃气流造成的身管振动，冲击载荷以及系统阻尼的变化会作用于随动系统，导致高炮产生姿态角误差。高炮射频较高时，射击冲击载荷这种随机扰动造成的影响将会积累，造成高炮射击线复位误差。高炮工作时负载环境的变化，惯性力矩以及摩擦力矩等非线形因素都对位置随动系统存在干扰。永磁同步电机作为随动系统的执行元件，其自身的强耦合、非线性，以及多变量的复杂性也对位置随动系统的快速跟踪能力产生影响。

高炮随动系统为非线性系统，具有扰动不确定性。利用 ADRC 较强的抗干扰能力以及 WNN 的在线学习能力，为高炮位置随动系统设计 WNN-ADRC 控制器。

6 结论

针对高炮位置伺服系统中出现的非线性时变等问题，在经典 ADRC 基础上，笔者设计一种结合小波神经网络的 WNN-ADRC 控制器。该控制方案通过改进的小波神经网络算法，对 ESO 中参数在线整定，提高其稳定性以及观测补偿扰动的能力。由仿真结果可知：该控制方案响应速度快，提高了稳态控制精度，对系统参数不确定性及外部扰动具有更好的抗干扰能力。

参考文献：

- [1] WANG R L, LU B C, HOU Y L, et al. Passivity-based control for rocket launcher position servo system based on improved active disturbance rejection technology[J]. *Advances in Mechanical Engineering*, 2018, 10(3): 1-11.
- [2] WANG R L, LU B C, HOU Y L, et al. Passivity-Based Control for Rocket Launcher Position Servo System Based on ADRC Optimized by IPSO-BP Algorithm[J]. *Shock and Vibration*, 2018(2018): 1-14.
- [3] 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，2008：20-25.