

基于 RBF 神经网络的导弹智能控制系统设计

徐世昊, 崔乃刚, 韦常柱

(哈尔滨工业大学航天学院, 哈尔滨 150001)

摘要: 为智能化导弹所设计的导弹智能控制系统应能够充分利用战场信息, 自主而准确地生成控制指令完成目标打击。首先建立导弹控制系统模型, 并在特征点处设计符合性能要求的 PID 控制器。在深入分析径向基函数 (RBF) 网络的结构与训练方法的基础上, 通过大量仿真数据对 RBF 网络进行离线训练, 将其训练结果直接作为俯仰与偏航通道的控制器。而滚转通道为典型的 2 阶系统, 可采用滑模控制律, 并利用 RBF 网络实时逼近外界非线性干扰项以提高滑模控制器的性能。通过某型倾斜转弯导弹六自由度仿真说明了本文所设计的智能控制系统的有效性。

关键词: 智能化导弹; 智能控制; RBF 神经网络

中图分类号: V421

文献标志码: A

文章编号: 2096-4080 (2018) 06-0019-08

Design of Missile Intelligent Control System based on RBF Neural Network

XU Shihao, CUI Naigang, WEI Changzhu

(School of Aeronautics, Harbin Institute of Technology, Harbin 150001, China)

Abstract: The missile intelligent control system designed for intelligent missile should be able to make full use of battlefield information and generate control commands automatically and accurately to achieve the target attack mission. In this paper, a model of missile control system is established and a PID controller is designed at the feature point. On the basis of in-depth analysis of the structure and training methods of Radial Basis Function (RBF) network, RBF network is trained offline through a large amount of flight data, and its training results are directly used as the controller of pitch and yaw channels. The rolling channel is a typical second-order system, which can adopt the sliding mode control law and use the RBF network to approximate the external nonlinear interference term in real time to improve the performance of the sliding mode controller. The effectiveness of the intelligent control system designed in this paper is demonstrated by the simulation of a certain type of STT missile with six degrees of freedom.

Key words: Intelligent missile; Intelligent control; RBF neural network

0 引言

面对 21 世纪复杂多变、对抗激烈的战场环境, 世界各军事大国均积极发展以人工智能技术为核

心的新一代智能导弹武器系统^[1]。而智能导弹武器系统的发展, 离不开智能控制技术在导弹上的应用。

智能控制技术于 1971 年首次被提出之后, 由

收稿日期: 2018-08-15; 修订日期: 2018-10-17

基金项目: 国家自然科学基金 (61403100)

作者简介: 徐世昊 (1996-), 男, 硕士, 主要研究方向为导弹控制系统设计。E-mail: xsh_hit@163.com

于其强大的学习能力和对外界环境的适应能力,迅速成为控制领域的前沿研究方向。目前理论发展较完善,且取得广泛应用的智能控制方法主要有模糊控制、神经网络控制、专家控制和自适应控制、自组织控制和迭代学习控制等^[2]。国内外许多学者将智能控制技术运用到导弹控制系统设计中,取得了丰富的研究成果。其中,崔乃刚等^[3]为解决不确定海况对潜射导弹出水姿态的影响,设计了潜射导弹模糊 PID 分段控制器。王强等^[4]利用径向基函数网络与 K-means 最邻近聚类算法对导弹逆动力学系统进行动态模型辨识,实现了三通道解耦控制。Rong 等^[5]为倾斜转弯导弹设计了自学习模糊控制器,通过扩展序贯自适应模糊推理系统与传统 Back-Stepping 控制方法的结合,提高了控制系统应对气动偏差和外界干扰的能力。Ran 等^[6]在导弹制导控制一体化系统中加入自适应模糊系统以逼近系统不确定性,并推导了保证系统稳定性的模糊系统参数自适应调节律。Lee 等^[7]基于状态依赖 Riccati 方程与模块化神经网络设计了导弹助推段的自动驾驶仪。王枫等^[8]采用拟人控制方法,基于广义归约的方法将导弹姿态控制问题分解成若干本原问题,之后根据各本原问题的主次关系及耦合关系设计非线性控制律,最后利用遗传算法优化控制器中相应权值。其他学者的研究也主要集中在将智能控制与传统控制方法相结合,以提高导弹控制系统面对诸如舵控效率不足^[9]、多执行机构复合控制^[10]、气动偏差^[11]、模型不确定性^[12]等情况下的控制能力,而此类方法的性能往往受限于传统控制方法,且没有利用大量数据对神经网络进行离线训练,以充分发挥神经网络的强大学习能力。

本文利用神经网络强大的逼近能力和学习能力,俯仰/偏航通道采用飞行数据离线训练神经网络的方式,训练完成的神经网络可以直接用作控制器;滚转通道采用神经网络在线调整权值的方式以对系统误差实时逼近;并将两种控制器同时应用于某型倾斜转弯导弹非线性六自由度仿真中,验证了所设计控制器的有效性。

1 导弹控制模型建立及神经网络训练样本获取

1.1 控制模型建立

神经网络的离线训练需要大量样本的支撑,

而样本的获取又依赖于传统控制器产生的大量仿真数据。本文设计符合性能要求的 PID 控制器,然后通过仿真获得足够的神经网络训练样本。

将导弹运动方程组进行小扰动线性化处理,忽略由于重力影响等所产生的动力系数,可得三通道扰动运动方程组如下:

$$\begin{cases} \frac{d^2 \Delta \vartheta}{dt^2} - a_{22} \frac{d \Delta \vartheta}{dt} - a_{24} \Delta \alpha = a_{25} \Delta \delta_z \\ \frac{d \Delta \theta}{dt} - a_{34} \Delta \alpha = a_{35} \Delta \delta_z \\ \Delta \vartheta = \Delta \theta + \Delta \alpha \end{cases} \quad (1)$$

$$\begin{cases} \frac{d^2 \Delta \psi}{dt^2} - b_{22} \frac{d \Delta \psi}{dt} - b_{24} \Delta \beta = b_{25} \Delta \delta_y \\ \frac{d \Delta \psi_v}{dt} - b_{34} \Delta \beta = b_{35} \Delta \delta_y \\ \Delta \psi = \Delta \psi_v + \Delta \beta \end{cases} \quad (2)$$

$$\frac{d^2 \Delta \gamma}{dt^2} - c_{11} \frac{d \Delta \gamma}{dt} = c_{17} \Delta \delta_x \quad (3)$$

式中如 a_{22} 、 a_{24} 等所示动力系数可参考文献^[13]求得。

将式(1)~式(3)进行 Laplace 变换,可得到三通道传递函数,如下所示:

(1) 俯仰通道

$$\begin{aligned} \frac{n_y}{\delta_z} &= \frac{V}{g} \cdot \frac{a_{35}s^2 - a_{22}a_{35}s + a_{25}a_{34} - a_{24}a_{35}}{s^2 + (a_{34}a_{22})s - (a_{24} + a_{22}a_{34})} \\ \frac{\omega_z}{\delta_z} &= \frac{a_{25}s + a_{25}a_{34} - a_{24}a_{35}}{s^2 + (a_{34} - a_{22})s - (a_{24} + a_{22}a_{34})} \end{aligned} \quad (4)$$

(2) 偏航通道

$$\begin{aligned} \frac{n_z}{\delta_y} &= \frac{V}{g} \cdot \frac{-b_{35}s^2 + b_{22}b_{35}s + b_{25}b_{34} + b_{24}b_{35}}{s^2 + (b_{34} - b_{22})s - (b_{24} + b_{22}b_{34})} \\ \frac{\omega_y}{\delta_y} &= \frac{b_{25}s + b_{25}b_{34} + b_{24}b_{35}}{s^2 + (b_{34} - b_{22})s - (b_{24} + b_{22}b_{34})} \end{aligned} \quad (5)$$

(3) 滚转通道

$$\frac{\omega_x}{\delta_x} = \frac{c_{17}}{s - c_{11}} \quad (6)$$

式中, n_y 、 n_z 为导弹过载, δ_x 、 δ_y 、 δ_z 为舵偏角。

设定控制系统幅值裕度为 6dB, 相位裕度为 45°, 可通过频域分析法设计 PID 控制参数。

1.2 训练样本获取

通过在表 1 所示范围内随机改变导弹运动初始状态 $[x_0, y_0, z_0]$, 目标运动初始状态 $[x_{t0}, y_{t0}, z_{t0}]$ 与目标侧向机动过载 n_{zt} 进行 10 组六自由度仿真, 在每组仿真中取 1000 个弹道特征点处数据, 从而获取本文神经网络训练所需样本。

表 1 仿真参数变化范围

仿真参数	下界	上界
$[x_0, y_0, z_0]$	$[0, 6000, -500]$ m	$[1000, 8000, 500]$ m
$[x_{t0}, y_{t0}, z_{t0}]$	$[10000, 0, -500]$ m	$[15000, 0, 500]$ m
n_{zt}	$-0.02g$	$0.02g$

2 RBF 神经网络理论基础

RBF 网络于 1988 年提出后, 因其结构简单、收敛速度快和能够逼近任意非线性函数的特性, 逐渐地在函数逼近^[14]、模型预测^[15]、系统辨识^[16]和故障分类^[17]等领域得到广泛应用。常见的正则化 RBF 网络具有如下特征^[18]:

1) 正则化 RBF 网络的隐含层只要有足够多的隐含节点, 则网络对任意非线性多元连续函数具有良好的逼近能力, 这意味着正则 RBF 网络可以作为非线性函数的通用逼近器使用;

2) 给定一个未知的非线性函数 $f(\cdot)$, 总可以选择一组网络权值系数, 使得网络对于 $f(\cdot)$ 的逼近是最优的。

RBF 网络采用前馈形式, 一般包括输入层、隐含层和输出层, 其典型结构如图 1 所示。




图 1 RBF 网络结构图

Fig. 1 The structure of RBF network

图 1 中 RBF 网络具有 n 个输入, h 个隐层节点, m 个输出, 记作 $n-h-m$ 结构。 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ 表示网络的输入量, $\mathbf{W} = [\omega_{11}, \omega_{12}, \dots, \omega_{ij}, \dots, \omega_{hm}]$ 为隐含层到输出层的权值矩阵, b_0, \dots, b_m 为网络输出单元固定偏置量, $\mathbf{y} = (y_1, y_2, \dots, y_m)^T$ 为网络输出。 $\Phi(\cdot)$ 表示隐含层的激活函数, 采用径向基函数的形式, 因此隐含层的每一个神经元都具有一个数据中心 c_i , $\|\cdot\|$ 表示欧氏距离。网络输出层节点中的求和符号表示 RBF 网络的总输出是隐含层输出的线性叠加。

针对图 1 所示具有 $n-h-m$ 结构的 RBF 网络, 其输入可表示为 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$, 网络中第 i 个隐含层节点的数据中心值设为 c_i , 径向基函数的宽度设为 b_i , 网络的映射关系可分为 2 层^[19]:

1) 从输入层到隐含层的非线性映射, 选择 Gaussian 基函数, 则第 i 个隐含层单元的输出为:

$$h_i = \exp\left(-\frac{\|\mathbf{x} - c_i\|^2}{2b_i^2}\right), \quad (1 \leq i \leq h) \quad (7)$$

2) 从隐含层到输出层的线性映射, 则输出层第 j 个神经元的输出为:

$$y_j = \sum_{i=1}^h \omega_{ij} h_i, \quad (1 \leq j \leq m) \quad (8)$$

3 俯仰/偏航通道神经网络控制器设计

本文所设计的过载驾驶仪中, 输入偏差信号、导弹飞行状态与输出控制指令信号之间的关系可表示为函数映射, 通过导弹飞行过程中产生的偏差与飞行状态数据对 RBF 网络进行离线训练以逼近函数映射, 离线训练完成的 RBF 网络可以直接作为控制器使用。

对于俯仰通道而言, 神经网络的输入为 $n_{yc} - n_y$, 输出为舵偏角指令 δ_z ; 对于偏航通道而言, 神经网络的输入为 $n_{zc} - n_z$, 输出为舵偏角指令 δ_y 。两个通道的网络输入层节点数 $n = 1$, 输出层节点数 $m = 1$, 而隐含层节点数 h 需根据网络训练算法确定。

3.1 控制器设计过程

采用 Chen 等提出的正交最小二乘算法 (Orthogonal least squares learning algorithm, OLS)^[20] 进行 RBF 网络的离线训练, 具体步骤如下:

1) 计算 RBF 网络隐含层的输出矩阵 \mathbf{H} , 记 \mathbf{H} 的 N 个列向量为 $\mathbf{P}_1^1, \mathbf{P}_1^2, \dots, \mathbf{P}_1^N$, 它们构成 N 维欧氏空间 E_1^N 。

2) 将训练样本中的输出数据矢量 \mathbf{y} 投影到 E_1^N 的各个基向量 $\mathbf{P}_1^1, \mathbf{P}_1^2, \dots, \mathbf{P}_1^N$ 上, 如果 $(\|\mathbf{y}^T \mathbf{P}_1^k\|) / (\mathbf{y}^T \mathbf{P}_1^k)$ 的绝对值达到最大, 则 \mathbf{H} 的第 k 列向量 \mathbf{P}_1^k 对 \mathbf{y} 有最大的能量贡献, 将 \mathbf{P}_1^k 对应的样本输入 x_k 选作第一个数据中心, \mathbf{P}_1^k 所构成的欧氏空间记作 E_1 。

3) 在已知训练样本输入数据 \mathbf{x} 、输出数据 \mathbf{y} 与 RBF 网络数据中心 x_k 后, 隐含层与输出层之间的权值与偏移量可以通过广义逆方法求解隐含层输出与样本输出数据之间的线性方程组的方式得出。

4) 计算此时 RBF 网络输出相对于样本输出的均方误差 (Mean Square Error, MSE), 如果 MSE 小于目标值, 则终止算法, 否则进行步骤 5。

5) 对矩阵 \mathbf{H} 进行 Gram-Schmidt 正交化, 使得矩阵 \mathbf{H} 的第 k 列正交于第 $k-1$ 列。

6) 重复步骤 2~步骤 5, 直至 MSE 小于目标值或算法达到最大循环步骤。

3.2 仿真分析

采用本文所设计符合性能要求的 PID 控制器, 通过改变导弹运动的初始条件 $[x_0, y_0, z_0]$, 目标初始位置 $[x_{t0}, y_{t0}, z_{t0}]$ 与目标侧向机动过载 n_{zt} 进行 10 组六自由度仿真, 以获得 RBF 网络训练所需样本数据, 通过每组仿真获得 1000 组数据, 在获得的 10000 组数据中选取 9000 组作为训练数据, 剩余 1000 组作为测试数据。设定径向基函数宽度 $b_i = 0.8$, 网络输出误差目标为 $\lg(\text{MSE}) < -15$, RBF 网络设计结果如图 2~图 3 所示。




图 2 俯仰通道网络 MSE 变化曲线

Fig. 2 The MSE in recursions of pitch channel RBF network




图 3 偏航通道网络 MSE 变化曲线

Fig. 3 The MSE in recursions of yaw channel RBF network

由图 1 与图 2 可知, 随着隐含层神经元个数的增加, RBF 网络的拟合误差在逐渐减小, 对于俯仰通道而言, 隐含层节点增加至 507 个时, $\lg(\text{MSE}) < -15$; 对于偏航通道而言, 隐含层节点增加至 204 个时, $\lg(\text{MSE}) < -15$ 。所设计的 RBF 网络均满足精度要求。

利用 1000 组测试数据对训练所得的 RBF 网络进行性能验证, 结果如图 4~图 5 所示。




图 4 俯仰通道 RBF 网络拟合误差曲线

Fig. 4 The RBF network fitting error of pitch channel




图 5 偏航通道 RBF 网络拟合误差曲线

Fig. 5 The RBF network fitting error of yaw channel

由以上仿真结果可知, 俯仰通道拟合误差最大值在 10^{-5} 量级, 拟合误差平均值在 10^{-8} 量级。偏航通道拟合误差最大值在 10^{-8} 量级, 拟合误差平均值在 10^{-10} 量级, 见表 2。以上结果说明训练所得 RBF 网络能够很好拟合俯仰通道与偏航通道的控制器。

表 2 拟合误差统计

Tab. 2 The statistics of fitting error

	俯仰通道	偏航通道
平均值	3.4375×10^{-8}	3.2068×10^{-10}
最大值	5.3615×10^{-5}	4.1024×10^{-8}

4 滚转通道神经网络控制器设计

4.1 控制器设计过程

滚转通道采用姿态自动驾驶仪的形式, 将式 (3) 转化为状态空间表达式, 有:

$$\dot{\mathbf{X}} = \mathbf{A}\mathbf{X} + \mathbf{B}U + \Delta d \quad (9)$$

式中:

$$\mathbf{X} = [\gamma, \omega_x]^T, \mathbf{A} = \begin{bmatrix} 0 & 1 \\ 0 & b_{11} \end{bmatrix}, \mathbf{B} = \begin{bmatrix} 0 \\ b_{17} \end{bmatrix}, U = \delta_x$$

Δd 为系统非建模动态或扰动量, 设其上界为 D 。

取 $x_1 = \gamma, x_2 = \omega_x$, 将式 (9) 写为如下形式:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = f(\mathbf{x}) + g(\mathbf{x})u + d(\mathbf{x}, t) \end{cases} \quad (10)$$

设理想角度为 γ_d , 定义跟踪误差为 $e = \gamma_d - \gamma$, 取滑模面函数 $s = \dot{e} + ce, c > 0$, 则有:

$$\begin{aligned} \dot{s} &= \dot{e} + c\dot{e} = \ddot{\gamma}_d - \ddot{\gamma} + c\dot{e} \\ &= \ddot{\gamma}_d - f - gu - d(\mathbf{x}, t) + c\dot{e} \end{aligned} \quad (11)$$

设计控制律为:

$$u = \frac{1}{g}(-f + \ddot{\gamma}_d + c\dot{e} + \eta \text{signs}) \quad (12)$$

式中, sign 为符号函数。将控制律带入式 (11) 中, 可得:

$$\dot{s} = -\eta \text{signs} - d(\mathbf{x}, t) \quad (13)$$

取 $\eta \geq D$, 则有:

$$s\dot{s} = -\eta |s| - s \cdot d(\mathbf{x}, t) \leq 0 \quad (14)$$

上述控制律依赖于 $f(\mathbf{x})$ 的精确性, 若由于外部干扰以及系统未建模动态的影响使得 $f(\cdot)$ 为某一不确定非线性函数, 则可以采用 RBF 网络逼近 $f(\cdot)$ 来设计控制器。此时 RBF 网络的输入为 $\gamma_c - \gamma$, 输出为 $f(\cdot)$ 当前取值, 网络输入层节点数 $n = 1$, 输出层节点数 $m = 1$, 隐含层节点根据仿真寻优选择为 $h = 21$ 。

由式 (7) 可知, RBF 网络输入输出算法为:

$$h_i = \exp\left(-\frac{\|\mathbf{x} - c_i\|^2}{2b_i^2}\right)$$

$$f = \mathbf{W}^{*T} \mathbf{h}(\mathbf{x}) + \epsilon \quad (15)$$

式中, $\mathbf{x} = [e, \dot{e}]^T$ 为网络输入, i 表示网络输入层第 i 个输入, j 表示网络隐含层第 j 个网络输入, $\mathbf{h} = [h_1, \dots, h_j]^T$ 为 RBF 网络第一步映射后的输出。 \mathbf{W}^* 为理想网络权值, ϵ 为网络逼近误差, $\epsilon \leq \epsilon_N$, f 为期望网络输出。

在 RBF 网络的权值 $\hat{\mathbf{W}}$ 并非理想网络权值 \mathbf{W}^* 时, 网络输出为:

$$\hat{f}(\mathbf{x}) = \hat{\mathbf{W}}^T \mathbf{h}(\mathbf{x}) \quad (16)$$

代入式 (12) 中, 可得控制律:

$$u = \frac{1}{g}(-\hat{f} + \ddot{\gamma}_d + c\dot{e} + \eta \text{signs}) \quad (17)$$

将控制律式 (17) 代入式 (11) 中, 得:

$$\begin{aligned} \dot{s} &= -f + \hat{f} - \eta \text{signs} - d(\mathbf{x}, t) \\ &= -\tilde{f} - \eta \text{signs} - d(\mathbf{x}, t) \end{aligned} \quad (18)$$

式中:

$$\begin{aligned} \tilde{f} &= f - \hat{f} = \mathbf{W}^{*T} \mathbf{h}(\mathbf{x}) + \epsilon - \hat{\mathbf{W}}^T \mathbf{h}(\mathbf{x}) \\ &= \tilde{\mathbf{W}}^T \mathbf{h}(\mathbf{x}) + \epsilon, \tilde{\mathbf{W}} = \mathbf{W}^* - \hat{\mathbf{W}} \end{aligned}$$

设计 Lyapunov 函数为:

$$L = \frac{1}{2}s^2 + \frac{1}{2}\lambda \tilde{\mathbf{W}}^T \tilde{\mathbf{W}}, \lambda > 0 \quad (19)$$

对式 (19) 求导, 结合式 (17) 与式 (18) 可得:

$$\begin{aligned} \dot{L} &= s\dot{s} + \lambda \tilde{\mathbf{W}}^T \dot{\tilde{\mathbf{W}}} \\ &= s(-\tilde{f} - d(\mathbf{x}, t) - \eta \text{signs}) - \lambda \tilde{\mathbf{W}}^T \dot{\tilde{\mathbf{W}}} \\ &= -\tilde{\mathbf{W}}^T (s\mathbf{h}(\mathbf{x}) + \lambda \dot{\tilde{\mathbf{W}}}) - s(\epsilon + d(\mathbf{x}, t) + \eta \text{signs}) \end{aligned}$$

可见为保证 $\dot{L} \leq 0$, 应取 RBF 网络权值参数自适应律为:

$$\dot{\tilde{\mathbf{W}}} = -\frac{1}{\lambda} s\mathbf{h}(\mathbf{x}) \quad (20)$$

则有:

$$\begin{aligned} \dot{L} &= -s(\epsilon + d(\mathbf{x}, t) + \eta \text{signs}) \\ &= -s(\epsilon + d(\mathbf{x}, t)) - \eta |s| \end{aligned} \quad (21)$$

由于 RBF 网络逼近误差 ϵ 为较小的实数, 取 $\eta \geq \epsilon_N + D$, 则 $\dot{L} \leq 0$ 。当 $\dot{L} \equiv 0$ 时, $s \equiv 0$, 由 Lasalle 不变集原理, 闭环系统渐进稳定, $t \rightarrow \infty, s \rightarrow 0$ 。至此, 保证所设计的控制器的稳定性。

在实际仿真过程中, 为克服滑模抖振问题, 可采用准滑动模态控制方法^[21]。即利用连续的 Sigmoid 函数 $\theta(s)$ 代替符号函数 $\text{sign}(s)$, $\theta(s)$ 的表达式为:

$$\theta(s) = \frac{s}{|s| + \delta} \quad (22)$$

易知 $\lim_{\delta \rightarrow 0} \frac{s}{|s| + \delta} = \text{sign}(s)$ ，在实际应用中 δ 可取为一个很小的正常数。

4.2 仿真结果

取 30s 特征点处滚转通道动力系数，滑模面参数设为 $c=50$ ，变结构控制项参数 $\eta=10$ ，Sigmoid 函数中 $\delta=0.05$ 。RBF 网络中心向量设置为： $c_i = 0.01 \times [-1, -0.9, \dots, 0.9, 1]$ ，径向基函数宽度 $b_i=15$ ，网络初始权值 W 全部为 0；自适应律参数 $\lambda = 0.015$ ；仿真过程中滚转角指令为 $\gamma_d = 15\sin(t) \text{ deg}$ 。在仿真开始 1.5s 后，在 $f(x)$ 中加入非线性干扰项，使得 $f(\cdot) = f(x) + 0.1\sin(x_1)\cos(x_2)$ 。在不加入 RBF 网络逼近 $f(\cdot)$ ，即采用式 (6) 所示的控制律时，仿真结果如图 6~图 7 所示。




图 6 滚转角跟踪误差变化曲线

Fig. 6 The tracking error of roll angle




图 7 滑模面函数变化曲线

Fig. 7 The curve of sliding surface function

由图 6~图 7 所示仿真结果可知，在加入外部非线性干扰项后，单纯采用滑模控制不能消除滚

转角和滚转角速率跟踪误差，且滑模面也未能收敛至 0。在加入 RBF 网络对非线性干扰项进行逼近，即采用控制律式 (11) 与权值自适应律式 (14) 时，仿真结果如图 8~图 10 所示。




图 8 滚转角跟踪误差变化曲线

Fig. 8 The tracking error of roll angle




图 9 RBF 网络逼近误差曲线

Fig. 9 The approximation error of RBF network




图 10 滑模面函数变化曲线

Fig. 10 The curve of sliding surface function

由图 8~图 10 所示的仿真结果可知，在加入

RBF 网络的逼近作用后, 滚转角跟踪误差在 1s 内收敛至 0, 滚转角速率跟踪误差在 4s 内收敛至 0; 同时滑模面也于 2s 内收敛至 0 附近邻域; 在加入非线性干扰项后, RBF 网络能够在 2s 内通过调节权值逼近 $f(\cdot)$ 。

5 非线性六自由度仿真

本节将所设计的两种智能控制器加入某型倾斜转弯导弹非线性六自由度仿真中, 通过对比弹体实际的过载值与过载指令来评估过载自动驾驶仪的控制性能, 同时分析滚转角的大小。

导弹初始条件设为:

$$[v_0, \theta_0, \psi_0] = [350\text{m/s}, 0^\circ, 0^\circ]$$

$$[x_0, y_0, z_0] = [0, 8000, -500]\text{m}$$

$$[\omega_{x0}, \omega_{y0}, \omega_{z0}] = [0, 0, 0]\text{rad/s}$$

$$[\vartheta_0, \psi_0, \gamma_0] = [0^\circ, 0^\circ, 1^\circ]$$

目标坐标为 $[x_{t0}, y_{t0}, z_{t0}] = [15000, 0, 0]\text{m}$, 速度为 $[v_{tx0}, v_{ty0}, v_{tz0}] = [10, 0, 0]\text{m/s}$; 并进行侧向机动, 机动过载为 $0.03g$, 加入所设计的两种智能控制器, 仿真结果如图 11~图 15 所示。




图 11 三维弹道曲线

Fig. 11 The trajectory curve of missile




图 12 纵向过载跟踪曲线

Fig. 12 The tracking curve of vertical overload




图 13 侧向过载跟踪曲线

Fig. 13 The tracking curve of lateral overload




图 14 滚转角变化曲线

Fig. 14 The curve of roll angle




图 15 RBF 网络逼近误差曲线

Fig. 15 The approximation error of RBF network

由仿真结果可知, 导弹于 72.6s 成功命中地面机动目标, 脱靶量为 0.41m, RBF 网络逼近误差在仿真开始 3s 内由于权值调整而出现较大幅度的振荡现象, 之后逐渐收敛至 0, 滚转角也随之收敛到 0。纵向过载和侧向过载在 3s 内均能实现对指

令过载信号的稳定跟踪。

6 结论

1) 对于俯仰和偏航通道使用飞行过程中数据对 RBF 网络进行离线训练, 以直接得到神经网络控制器, 仿真结果表明, 随着 RBF 网络隐含层神经元的增加, 网络对于俯仰通道控制器的平均逼近误差减小至 3.4375×10^{-8} , 对于偏航通道控制器的平均逼近误差减小至 3.2068×10^{-10} 。

2) 对于滚转通道利用滑模控制理论, 采用 RBF 网络逼近系统中非线性不确定项, 结合 Lyapunov 稳定性理论推导了 RBF 网络权值自适应调节律, 并证明了所设计控制系统的稳定性。通过滚转通道对指令信号的跟踪仿真说明了所设计控制系统在外界存在非线性干扰的情况下, RBF 网络可通过调节权值在 2s 内逼近干扰项, 以提高传统滑模控制器的性能。

3) 通过六自由度仿真验证了所设计的智能控制系统能够控制导弹成功命中地面机动目标。

参考文献

- [1] 槐泽鹏, 佟泽友, 梁雪超, 等. 智能导弹武器系统综述 [J]. 导航与控制, 2017, 16 (5): 104-112.
- [2] 文苏丽, 陈琦, 苏鑫鑫, 等. 智能化导弹与导弹智能化研究 [J]. 战术导弹技术, 2015 (6): 21-26.
- [3] 崔乃刚, 曹春泉, 韦常柱. 潜射导弹水下运动过程仿真分析 [J]. 弹道学报, 2009, 21 (2): 95-99.
- [4] 王强, 王晓恩, 杨志峰. 基于神经网络的 BTT 导弹逆控制方案设计 [J]. 上海航天, 2010, 27 (2): 29-33.
- [5] Rong H J, Yang Z X, Wong P K, et al. Adaptive self-learning fuzzy autopilot design for uncertain bank-to-turn missiles [J]. Journal of Dynamic Systems, Measurement, and Control, 2017, 139 (4): 041002.
- [6] Ran M, Wang Q, Hou D, et al. Backstepping design of missile guidance and control based on adaptive fuzzy sliding mode control [J]. Chinese Journal of Aeronautics, 2014, 27 (3): 634-642.
- [7] Lee J, Lee Y, Kim Y, et al. Adaptive SDRE based boost-phase missile autopilot design using single and modular neural networks [J]. IFAC-PapersOnLine, 2015, 48 (9): 108-113.
- [8] 王枫, 袁飞, 王青, 等. 直接力控制导弹的拟人智能自动驾驶仪设计 [J]. 系统仿真学报, 2008 (22): 6226-6229.
- [9] 李若铭. 基于 T-S 模糊模型的防空导弹控制系统设计 [D]. 哈尔滨: 哈尔滨工业大学, 2016.
- [10] Zhen S, Ma W Q, Wang F, et al. Intelligent control algorithm for missile with lateral jets and aerodynamic surfaces [J]. Journal of Nanjing University of Science and Technology, 2014, 38 (4): 481-489.
- [11] McFarland M B, Calise A J. Adaptive nonlinear control of agile anti-air missiles using neural networks [J]. IEEE Transactions on Control Systems Technology, 2000, 8 (5): 749-756.
- [12] 朱成. 垂直发射防空导弹智能制导与控制 [D]. 南京: 南京航空航天大学, 2015.
- [13] 李新国, 方群. 有翼导弹飞行动力学 [M]. 西安: 西北工业大学出版社, 2005.
- [14] 罗绍华. 基于 RBF 网络逼近的机器人自适应动态面控制方法研究 [D]. 重庆: 重庆大学, 2013.
- [15] 李瑞莹, 康锐. 基于神经网络的故障率预测方法 [J]. 航空学报, 2008, 29 (2): 357-363.
- [16] 杜向党, 刘小雄. 基于自适应神经网络的飞控系统辨识技术研究 [J]. 弹箭与制导学报, 2007, 27 (1): 59-62.
- [17] Lin W M, Yang C D, Lin J H, et al. A fault classification method by RBF neural network with OLS learning procedure [J]. IEEE Transactions on Power Delivery, 2001, 16 (4): 473-477.
- [18] 王旭东, 邵惠鹤. RBF 神经网络理论及其在控制中的应用 [J]. 信息与控制, 1997, 26 (4): 272-284.
- [19] Bugmann G. Normalized Gaussian radial basis function networks [J]. Neurocomputing, 1998, 20 (1-3): 97-110.
- [20] Chen S, Cowan C F N, Grant P M. Orthogonal least squares learning algorithm for radial basis function networks [J]. IEEE Transactions on Neural Networks, 1991, 2 (2): 302-309.
- [21] 刘金琨, 孙富春. 滑模变结构控制理论及其算法研究与进展 [J]. 控制理论与应用, 2007, 24 (3): 407-418.

引用格式: 徐世昊, 崔乃刚, 韦常柱. 基于 RBF 神经网络的导弹智能控制系统设计 [J]. 宇航总体技术, 2018, 2 (6): 19-26.

Citation: Xu S H, Cui N G, Wei C Z. Design of missile intelligent control system based on RBF neural network [J]. Astronautical Systems Engineering Technology, 2018, 2 (6): 19-26.