某舰载武器随动系统滑模控制研究

覃晗 童仲志 唐东

(南京理工大学机械工程学院 江苏 南京 210094)

摘要: 为了提高某舰载武器随动系统响应的快速性和准确性,对其进行滑模控制研究。为了抑制船舶在海上航行时产生的剧烈摇摆,结合伺服系统的模型,设计了基于 RBF 神经网络的自适应滑模控制器,利用神经网络的自学习能力来消除传统滑模控制的抖振问题。分析得出,该方案有助于维护整体系统的稳定性,实现更为迅速的动态响应,提高控制精度,具有重要的实际工程应用价值。

关键词:舰载武器;神经网络;滑模控制

0 引言

舰载火箭炮在行进过程中对目标物进行瞄准射击, 不同于传统的静瞄火箭炮,因受到海上波浪带来的扰动 影响,会给火箭炮的随动系统控制带来了极大的考验, 这个问题值得深入研究。

PID 算法有着架构简易、稳定以及便于调节等极大 优势,但因为 PID 数据不变的特征,不适用非线性实变 系统,无法满足动态响应的性能要求。因此智能控制成 为了当下的研究热点。

为了更好的控制减摇鳍,文献 [1] 抑制船舶在海上航行时产生的剧烈摇摆,提出了一种基于 RBF 神经网络自适应的滑模控制系统,仿真结果表明系统具有良好的鲁棒性和自适应性。文献 [2] 针对电力系统负载预测的问题,提出了一种基于 RBF 神经网络的短期预测模型,通过仿真发现该模型具有优异的预测精度。

考虑到海上扰动,需要控制器有更快的响应速度,能够及时调控火箭炮,本文在位置环设计以 RBF 神经 网络为基础的滑模控制器。

1 舰载武器系统的数学模型

舰载武器方位角和高低角的随动系统的原理相似, 故本文只对高低角数学模型进行分析。位置环的分析设 计如图 1 所示。

位置环的传递函数为:

$$\theta(s) = G_s(s)\omega_{\text{ref}}(s) + G_T(s)T_L(s)$$

$$= \frac{K_p G_{\omega}(s)K_t i}{Js^2 + (B + K_p G_{\omega}(s)K_t K_{\beta})s}\omega_{\text{ref}}(s)$$

$$+ \frac{-i}{Js^2 + (B + K_p G_{\omega}(s)K_t K_{\beta})s}T_L(s)$$
(1)

式中: ω_{ref} —指令速度;

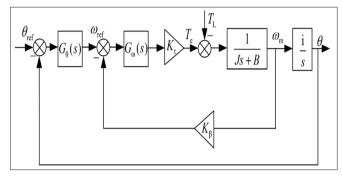


图 1 位置环简化框图

 K_n 一位置环控制器比例放大倍数;

 θ 一输出角;

 T_L 一负载转矩。

2 2RBF 神经网络滑模控制器设计

2.1 RBF 神经网络的结构

RBF 网络的典型结果,具体信息可参考图 2,设定输出层仅存在单一的结点,该结构更易扩充至多输出结点。输入至隐层,即对应权值 1 固定连接。隐含层包括对应的径向基函数相应的中心向量以及宽度即为 RBF 数据。隐含层各大结点,都运用同样的径向基函数,其有丰富的形式,一般设定为高斯函数。隐层输出进行相应的线性加权,最终建立对应的输出。

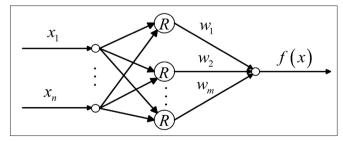


图 2 神经网络的结构图

网络输入与输出之间的映射关系为:

- 42 -

$$f(x): R^{n} \to R$$

$$y = f(x) = \sum_{i=1}^{m} w_{i} \varphi(\|x - c_{i}\|, \sigma_{i})$$

$$= \sum_{i=1}^{m} w_{i} \exp\left|-\frac{\|x - c_{i}\|^{2}}{2^{2} \sigma_{i}}\right|$$
(2)

式中: m—在上述算式中代表的参数即隐含层结点数;

|| - 在上述算式中代表的参数即欧几里德范数;

$$X, C_i \in \mathbb{R}^n; W \in \mathbb{R}^m, W = (w_1, ..., w_m)^R;$$

 w_i 一在上述算式中代表的参数即第 i 个基函数和输出结点之间的连接权值(i=1,2,...m)。

建立与训练 RBF 网络即应当借助该方式通过学习,确认基函数的 C_i 与 σ_i 等数据,可在此基础上构建输入和输出之间的映射关系。

2.2 RBF 神经网络基本学习算法

RBF 网络需求的数据有三部分: 隐含层基函数中心、方差,与隐含至输出之间的权值。RBF 网络之中,输出与隐含层处理的任务有所区别,因此其学习策略也会有所区别。输出层即围绕线性权开展对应的调控,运用了线性优化方案,因此有着较为迅速的特征。隐含层即围绕作用函数的数据开展调控,运用了非线性的方案,所以学习速度迟缓,下面介绍 RBF 网络的基础方案。

2.2.1 直接计算法

隐单元 RBF 中心,在相关输入样本之中以随机方式选定,中心为固定状态。RBF 中心正式确认之后,隐单元输出则是转化成已知状态,网络对应的连接权即可依靠计算线性方程组的方式加以确认。

当 RBF 选用高斯函数时,它可表示为:

$$G(\|X - t_i\|^2) = \exp\left(-\frac{M}{d_m^2} \|X - t_i\|^2\right)$$
 (3)

式中: M一中心数;

 $W = G^{\dagger}d, \lambda = 0$ 即选定中心的最大距离。

该情形中, 宽度固定: $\sigma = d_m/\sqrt{2M}$ 。

连接权量可结合下述公式进行计算:

$$W = G^+ \quad d, \lambda = 0 \tag{4}$$

式中: G+一矩阵的伪逆, 即:

$$G^{+} = \left(G^{T}G\right)^{-1}G^{T} \tag{5}$$

其中, G 由式 (6) 确定:

$$G = \left\{ g_{ji} \right\}, g_{ji} = \exp \left(-\frac{M}{d_m^2} \left\| X_j - t_i \right\|^2 \right) j = (1, 2, ...N)i = (1, 2, ...M)$$
 (6)

对给定问题,若是数据分布有代表性,其为简易、 具备可行性的方案。

2.2.2 自组织学习选取 RBF 中心

在该方法之中,RBF 中心处于可移动状态,借助自组织学习来确认具体的位置。输出层线性权,可依靠对应的学习规则加以计算。借助相关分析可得出,其为混

合式算法。自组织即围绕相关资源开展分配,处理目标即让 RBF 中心处于整个输入空间最关键的位置。RBF 中心选择,可运用 K 均值聚类的方案。其有着无监督的特征。实际流程为:

- (1) 初始化聚类中心 t_i (i = 1, 2, ...M)。通常会在输入样本 x_j (j = 1, 2, ...N) 之中,选定 M 个样本充当对应的初始中心。
- (2) 将相关输入样本依据邻近规则开展分组,将 x_j (j = 1, 2, ...N) 划分至最近的中心 t_i 所处的聚类集合 θ_i (i = 1, 2, ...M)。
- (3) 计算 $\theta_i(i=1,2...M)$ 的样本均值数据。获得新的中心 $t_i(i=1,2,...M)$,依据前述流程开展计算,直至中心并未产生变化方才停止,否则,转(2)。
- (4) 计算均方差 σ , $\sigma = d_m/\sqrt{2M}$, d_m 即选定中心间的最大距离。
 - (5) 计算矩阵 G 的各元素。
- (6)运用高斯消去法,对于(3)进行计算可获得权 W
- (7) 确认网络输出 Y=GW。因为输出、隐层间有着特殊的线性映射,关于输出权值的分析,可运用最小二乘等方案进行计算。

2.3 RBF 神经网络滑模控制器设计

状态轨迹实际存在的抖振,重点即相应切换增益 所产生,而且 相对较大的情况下,抖振则会更加显著。依托神经网络所具备的自学习以及自适应等功能开展调控,能够高效管控抖振。RBF 控制器的具体架构可参考图 3。

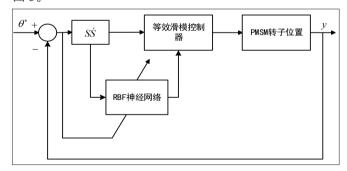


图 3 RBF 神经网络滑模控制器

图 3 中,RBF 神经网络对应输入 $q = [s\dot{s}]$,输出绝对值即相应的切换增益 K。则:

$$K = \left| w^T z(q) \right| \tag{7}$$

式中: z(q) — 高斯函数;

w-隐含至输出层之间的连接权值。

$$z_i(q) = \exp\left(-\frac{\|q - C_i\|^2}{2r_i^2}\right), i = 1, 2, 3$$
 (8)

式中: C_i 一第i个节点中心向量;

r:—基宽向量第 i 个值。

定义目标函数:

$$E = \frac{1}{2}e^2 \tag{9}$$

式中:e一偏差, $e = v - \theta^*$ 。

神经网络连接权值的调整算法为:

$$\Delta w = -\eta \frac{\partial E}{\partial w} = -\eta e \frac{\partial e}{\partial w} = -\eta e \frac{\partial y}{\partial w} = -\eta e \frac{\partial y}{\partial i_q} \frac{\partial i_q}{\partial K} \frac{\partial K}{\partial w} \approx$$

$$-\eta e \operatorname{sgn}\left(\frac{\partial y}{\partial i_q}\right) \frac{\partial i_q}{\partial K} \frac{\partial K}{\partial w}$$

$$(10)$$

式中: η —网络学习速率, $\eta \in (0,1)$ 。

 $y = i_q$ 之间为正相关, $\frac{\partial y}{\partial q}$ 仅需要观察正负号,参数可通过权值加以补偿,因此其中存在对应的

$$\operatorname{sgn}\left(\frac{\partial y}{\partial i_{a}}\right) = 1, \frac{\partial i_{q}}{\partial K} = -\operatorname{sgn}(s) \frac{\partial K}{\partial w} = z(q)\operatorname{sgn}(w^{T}z(q))$$

那么式(10)的数据是:

$$\Delta w \approx -\eta e(-1)\operatorname{sgn}(s)z(q)\operatorname{sgn}(w^{T}z(q))$$
(11)

神经网络最终学习算法为:

$$w(t) = w(t-1) + \Delta w(t) + \alpha \left(w(t) - w(t-1) \right)$$
 (12)
式中: α — 网络惯性系数, $\eta \in (0,1)$ 。

3 实验仿直

本文对位置环控制器进行仿真实验。

控制器数据: 滑模参数 c_1 =150, c_2 =200,学习速率 η =0.6,惯性系数 a=0.05,误差指标 E=0.15,切换增益 初始值 ε =1,权值初始参数 $0 \sim 1$ 随机值。

3.1 阶跃跟踪响应仿真实验

首先采用阶跃响应实验对系统的响应性能进行仿 真。图 4 为基于 RBF 神经网络的滑模控制和传统滑模 控制的阶跃响应曲线。

从图 4 中可得出 RBF+SMC 控制策略到达稳态时间

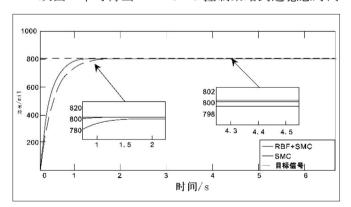


图 4 阶跃响应下系统响应曲线

为 1.1s, 稳态误差为 0.2mil。而 SMC 控制策略到达稳态时间为 1.9s, 稳态误差为 0.9mil。因此,本文设计的控制器相比传统滑模有着更好的控制效果,提高了系统的稳定性。

3.2 正弦跟踪响应仿真实验

进一步验证控制器的动态跟踪性能,采取正弦信号对系统进行仿真实验。图 5 为基于 RBF 神经网络的滑模控制和传统滑模控制的正弦跟踪误差曲线。

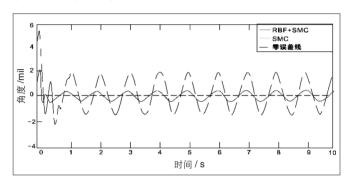


图 5 正弦跟踪误差曲线

从图 5 中可以看出 SMC 控制策略的稳态误差为 ±2mil 左右,而 RBF+SMC 的稳态误差保持在±0.5mil,误差要小得多,有效地提高了系统稳定性。

4 结语

本文研究了舰载火箭炮控系统的控制策略,设计了一种基于 RBF 的滑模控制器。仿真结果表明本文采用的控制策略能够更好地加快系统的响应速度,提高舰载武器精度以及稳定性。

参考文献:

- [1] 薛冬双.船舶减摇鳍系统模糊自适应滑模控制及动态仿真研究[D].大连:大连海事大学,2016.
- [2]Tran M D, Kang H J. A novel adaptive finite-time tracking control for robotic manipulators using nonsingular terminal sliding mode and RBF neural networks[J]. International Journal of Precision Engineering & Manufacturing, 2016, 17(7):863-870.
- [3] 岳远波. 基于改进脊波神经网络的电力系统短期符合预测研究 [D]. 青岛:青岛大学,2019.
- [4] 胡达. 复合积分滑模变结构在火箭炮交流伺服系统的控制研究 [D]. 南京:南京理工大学,2018.
- [5] 王永骥,涂健.神经元网络控制 [M].北京:机械工业出版社,1998.