

DOI: 10.19650/j.cnki.cjsi.J2311209

基于 GA-模糊 RBF 的发电机组滑模自抗扰控制^{*}

冯旭刚¹, 黄鹏辉¹, 张泽辰¹, 王正兵¹, 宋爱国²

(1. 安徽工业大学电气与信息工程学院 马鞍山 243000; 2. 东南大学仪器科学与工程学院 南京 210096)

摘 要:针对燃煤发电机组风烟系统大惯性、大滞后、参数不稳定等特点,提出一种基于发电机组的滑模自抗扰控制策略。选择模糊径向基函数(RBF)算法辨识模型,以梯度下降法和遗传算法分别对神经网络权值进行粗调和细调,通过扩张状态观测器估计系统内外部扰动,将非线性状态误差反馈控制律与滑模控制策略相结合以克服系统惯性、滞后和扰动的问题,并设计 Lyapunov 函数验证控制系统稳定性。仿真结果表明,滑模自抗扰控制与串级比例-积分-微分(PID)控制、滑模控制和自抗扰控制相比,在模型适配的情况下,所设计的控制策略在 38 s 达到设定值,无超调量;当向系统施加 20% 的反向阶跃干扰时,系统调节时间为 39.5 s,超调量为 3.4%。在模型失配情况下的调节时间为 43.2 s,无超调量;当向系统施加 20% 的反向阶跃干扰时,系统调节时间为 46.4 s,超调量为 3.87%。工程应用结果表明,一次风量控制偏差在 $\pm 10\ 000\ \text{m}^3/\text{h}$ 以内,相比串级 PID 控制策略波动范围降低 21%,系统抗干扰能力和鲁棒性得到有效提升。

关键词: 模糊 RBF; 遗传算法; 滑模自抗扰控制; 扩张状态观测器; 风烟系统

中图分类号: TH89 TF325 **文献标识码:** A **国家标准学科分类代码:** 470.40

Sliding mode active disturbance rejection control for generator sets based on GA-fuzzy RBF

Feng Xugang¹, Huang Penghui¹, Zhang Zechen¹, Wang Zhengbing¹, Song Aiguo²

(1. School of Electrical and Information Engineering, Anhui University of Technology, Ma'anshan 243000, China;

2. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: Aiming at the characteristics of large inertia, large hysteresis and unstable parameters of the air and flue gas system of coal-fired generator sets, a sliding mode active disturbance rejection control strategy based on generator sets is proposed. The fuzzy radial basis function (RBF) algorithm is selected to identify the model, the gradient descent method is used to coarse-tune the neural network weights, and the genetic algorithm is used to fine-tune the neural network weights. The internal and external disturbances of the system are estimated by the extended state observer, the nonlinear state error feedback rate is designed and sliding mode control strategies are designed to overcome the inertia, hysteresis and disturbances of the system, and Lyapunov functions are designed to evaluate the stability of the control system. The simulation results show that the designed control strategy reaches the set value in 38 s with no overshoot compared with the cascaded proportion integration differentiation (PID) control, sliding mode control and self-rejecting control in the case of model mismatch. When a 20% backward step disturbance is applied to the system, the system regulation time is 39.5 s with 3.4% overshoot. The regulation time in the case of model mismatch is 43.2 s with no overshoot. When the system applies 20% reverse step disturbance, the system regulation time is 46.4 s with 3.87% overshoot. The engineering application results show that the primary air volume control deviation is within $\pm 10\ 000\ \text{m}^3/\text{h}$, which is 21% lower than the fluctuation range of the cascaded PID control, and the anti-disturbance capability and robustness of the system are improved.

Keywords: fuzzy RBF; genetic algorithm; sliding mode active disturbance rejection control; extended state observer; air and flue gas system

0 引 言

我国经济社会进入高质量发展阶段,国家对环境保护越来越重视,对能源的利用率提出更高标准。燃煤发电机组主要采用煤粉为燃料,助燃空气和煤粉混合后,被一次风烘干后吹到磨煤机碾碎,二次风混合煤粉喷入炉膛充分燃烧^[1-2]。

近年来,在发电机组风烟系统上采用机理分析法已经不能得到满意的结果,一些新型的建模方法被运用在风烟系统上。文献[3]提出针对发电机组风烟系统的动态验证模型辨识方法,为实现动态参数自整定提供了一定的理论依据,但建立模型需要选取现场不同时间段的变负荷参数,造成模型的辨识难度大。文献[4]选用电站锅炉历史数据,设计人工神经网络(artificial neural network, ANN)模型对参数进行辨识和训练,构建预测风烟系统烟气含氧量的策略。该策略能较好实现预测功能,但是算法的误差只能满足工厂正常运行,若发生工况变动,没有自调节参数的神经网络将会花费更长时间来进行学习。文献[5]基于发电机组工艺流程图设计了风烟系统的流体网络模型,分析了风烟系统的流体场。但是未将数值模拟的模型转换为控制模型,在运用控制策略中,由于建立参数过多,需要对整个模型进行化简。

在传统风烟控制系统方面,大部分发电机组仍采用串级比例-积分-微分(proportion integration and differentiation, PID)控制方式,难以达到节能降耗的目的。文献[6]采用串级 PID 控制,该控制策略具有结构简单、适应力强、易于实现的特点。但是随着系统长时间不间断工作,发电机组的工况会受到内外部干扰,引起控制系统输入量发生跳变,原本镇定的 PID 控制参数无法适应被控对象的变化,导致燃烧不稳定。文献[7]提出滑模控制(sliding mode control, SMC)具有良好的参数变化适应能力,受到干扰后恢复时间快,并将滑模控制应用于二阶系统,提高了系统的动态性能,但滑模控制存在的抖振和带来的干扰并没抑制。文献[8]提出锅炉送风系统易受到外部干扰的影响,采用自抗扰控制(active disturbance rejection control, ADRC)能实现跟踪煤质变动和抑制外界干扰,但该方法为提高控制效果,延长了调节时间。文献[9]提出构造一个非线性扩张状态观测器跟踪系统状态,再设计基于状态观测器的非线性自抗扰控制策略实现对控制系统未知干扰的实时检测与补偿,最终将控制策略应用于火电机组的制粉系统中,验证了算法的有效性。

上述文献都为建立风烟系统模型和设计风烟控制系统提供了思路,具有很好的参考意义。本文针对风烟模型大惯性、大滞后和参数不稳定的特点,建立模糊径向基

函数(radial basis function, RBF)神经网络辨识模型,设计扩张状态观测器对系统的内外干扰进行估计,构建滑模自抗扰控制(sliding mode active disturbance rejection control, SM-ADRC)策略,实现抑制扰动的功能。

1 发电机组风烟系统的建立

1.1 风烟系统特性

发电机组风烟系统的工艺流程主要包括以下几部分,首先通过给煤机为锅炉提供燃料,其次空气经过空气预热器加热,最后经燃烧器与燃料混合进行充分燃烧。燃烧后产生的烟气经过除尘与脱硫装置经过烟道排出,产生的残渣在炉膛下方的排渣装置排出。当一次风量过大时,造成锅炉燃烧室内燃料不能充分燃烧就被风吹走,造成排烟温度升高,氮氧化物排放增加;当一次风量过小时,造成煤粉管道内煤粉浓度分布不均匀,易出现回火现象^[9]。

在工程实际中,由于燃煤发电机组风烟系统会受到来自外界诸多因素的影响,很难建立准确的数学模型用于理论分析。设计可用含未知量输入的状态方程^[9]表示风烟模型为:

$$\begin{cases} \dot{x}^{(n)} = f(\mathbf{X}, t) + d(t) + A u(\mathbf{X}, t - \tau) \\ y = x \end{cases} \quad (1)$$

式中: $\mathbf{X} = [x, \dot{x}, \ddot{x}, \dots, x^{(n)}]$ 为风烟系统的状态矢量; $f(\mathbf{X}, t) + d(t)$ 为系统的内外部干扰和不确定项; $u(\mathbf{X}, t - \tau)$ 为风烟系统的输入量; τ 为滞后时间; A 为控制系统未知增益。

由于系统输入是时滞变量,利用 Pade 对时滞变量^[10]进行近似处理:

$$L[u(t - \tau)] = e^{-\tau s} L[u(t) - w(t)] \approx \frac{1 - \tau s/2}{1 + \tau s/2} L[u(t) - w(t)] \quad (2)$$

式中: $w(t)$ 为时间变量输入。式(2)经过拉氏变换可得:

$$\dot{w}(t) = 4u(t)/\tau - 2w(t)/\tau \quad (3)$$

将式(3)代入式(1),同时将式(1)化简为二阶被控对象为:

$$\begin{cases} \dot{x} = f + A[u(\mathbf{X}, t) - w(t)] \\ \dot{w}(t) = 4u(t)/\tau - 2w(t)/\tau \\ y = x \end{cases} \quad (4)$$

参考文献[11]可得式(4)中 $w(t)$ 在控制系统中可作为系统外部扰动,同时式(4)采用提升相对阶数,提高系统控制性能的方法,最终可化简为:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = f + A[u(\mathbf{X}, t)] \\ y = x_1 \end{cases} \quad (5)$$

其中,总扰动 $f = f(\mathbf{X}, t) + d(t) - Aw(t)$ 。

在式(5)已经设计了状态方程,根据拉普拉斯变换并整理得:

$$G(s) = \frac{K_1 K_2}{(T_1 s + 1)(T_2 s + 1)} \quad (6)$$

式中: K_1 、 K_2 为系统增益, T_1 和 T_2 为一次风阀调节时间和一次风管导通时间,同时满足 $A = \frac{K_1 K_2}{T_1 T_2}$ 。

1.2 风烟系统模糊 RBF 网络结构建立

采用神经网络结构如图 1 所示,将整个结构分为输入层、模糊化层、模糊推理层和输出层^[12]。图 1 中 x_i 表示一次风量输入。




图 1 模糊 RBF 神经网络结构

Fig. 1 Fuzzy RBF neural network structure

第 1 层是输入层,该层级假设有 n 个节点,节点与输入分量直接连接,每 i 层输出结果为:

$$h_n(i) = x_i \quad (7)$$

第 2 层是模糊化层,针对风烟系统的非线性特点,采用高斯基函数作为隶属函数,隶属函数公式如下:

$$gus_j = \frac{-(h_1(i) - c_{ij})^2}{(b_j)^2} \quad (8)$$

$$h_2(i, j) = \exp(gus_j) \quad (9)$$

式中: c_{ij} 表示 RBF 在第 i 个输入变量第 j 个模糊集合的隶属函数的均值; b_j 表示隶属函数的标准差。

第 3 层是模糊推理层,模糊推理层共有 N 个节点,每个节点的输出为该节点输入所有模糊集合的乘积,如下:

$$h_3(j) = \prod_{i=1}^n h_2(i, j) \quad (10)$$

$$N = \prod_{i=1}^n N_i \quad (11)$$

第 4 层是输出层,实现规则间的推理的输出,即:

$$h_4(n) = V h_3 = \sum_{j=1}^N w(n, j) h_3(j) \quad (12)$$

式中: n 为输出层节点的个数; V 为输出层节点与模糊推理层各节点的权矩阵。

1.3 模糊 RBF 网络直接逼近模型

采用改进模糊 RBF 网络逼近风烟模型,目标是网络输出值与风烟模型输出值之间的误差达到最小且稳定的情况,且在模型适配和失配的情况下能同样达到逼近的效果。

如图 2 所示,定义控制系统输入为 $o(kT)$,网络输入为 $x_i(i = 1, 2, \dots, n)$,模糊 RBF 控制器输入为静态误差 $e(kT)$,静态误差如式(13)所示。模糊 RBF 辨识器输出为 $y_m(kT)$,风烟系统模型输出为 $F(kT)$,滑模自抗扰控制器输出为 $u(kT)$,被控对象输出为 $y(kT)$,网络逼近误差 $e_n(kT)$, $e_n(kT)$ 如式(14)所示。

$$e(kT) = o(kT) - y(kT) \quad (13)$$

$$e_n(kT) = F(kT) - y(kT) \quad (14)$$




图 2 控制系统流程

Fig. 2 Control system flow chart

1.4 模糊 RBF 学习算法

学习算法训练模糊 RBF 的实质是利用该算法找到高斯基函数的均值 c_{ij} ,标准差 b_j 和连接权系数 W 的全局最优解。为避免使用遗传算法(genetic algorithm, GA)参数选取的范围过大,先采用梯度下降法修正初始参数,然后在这组参数的周围利用遗传算法进行寻优^[13]。

1) 梯度下降法粗调初始参数

根据风烟系统特性,定义目标函数^[14]为:

$$E = 0.5 e_n(kT)^2 \quad (15)$$

首先对输出层权值采用如下方法调整:

$$\Delta W(k) = -\eta \frac{\partial E}{\partial w} = -\eta \frac{\partial E}{\partial e_n} \frac{\partial e_n}{\partial y} \frac{\partial y}{\partial w} = \eta e_n(k) h_3 \quad (16)$$

其次对隶属函数均值进行调整:

$$\Delta c_{ij}(k) = -\eta \frac{\partial E}{\partial c_{ij}} = -\eta \frac{\partial E}{\partial gus_j} \frac{\partial gus_j}{\partial c_{ij}} = \eta W e_n(k) h_3 \frac{2(h_1(i) - c_{ij})}{(b_j)^2} \quad (17)$$

最后对隶属函数标准差进行调整:

$$\Delta b_j(k) = -\eta \frac{\partial E}{\partial b_j} = -\eta \frac{\partial E}{\partial g_{us_j}} \frac{\partial g_{us_j}}{\partial b_j} = -\eta W e_n(k) h_3 \frac{(h_1(i) - c_{ij})}{(b_j)^3} \tag{18}$$

式中: η 为学习速率,其取值范围为 $\eta \in (0,1)$ 。

参数学习算法通式如下:

$$w(k) = w(k-1) + \Delta w(k) + \alpha(w(k-1) - w(k-2)) \tag{19}$$

式中: α 为动量因子,其取值范围为 $\alpha \in (0,1)$ 。

2) 遗传算法细调参数

本文采用遗传算法具体步骤如下。

(1) 生成一个初始种群^[15]。采用均匀分布的方式划分梯度下降法产生的均值、标准差和权值。首先将主空间划分为 S 个子空间,其次量化每个子空间,运用均匀数组选择 M 个个体,最后从 $S \times M$ 个个体中,选择适应度最优的 B 个作为初始群体。

如图 2 所示,辨识算法是为了降低风烟系统模型与实际输出的误差值,故选择输出适应度函数为理想值与实际值之间的欧氏距离,适应度函数公式如下:

$$D(x_i) = \sqrt{\sum_{T=1}^n (y_m(kT) - y_m(kT + T))^2} \tag{20}$$

式中: $y_m(kT)$ 是模糊 RBF 的实际输出; $y_m(kT + T)$ 是预测输出; i 表示选取的种群个数;再选取如下目标函数:

$$F(x) = \frac{1}{D(x) + 1} \tag{21}$$

当式(21)达到目标参数值,也就表示辨识算法输出的数值与实际参数值之间误差最小。从而实现选择最优风烟系统参数的过程,避免系统陷入局部最优。

(2) 选择方法是锦标赛选择策略,由于风烟系统具有参数不稳定特性,在拟合参数时,需要权值能更适应多变参数。基本思想是:每次从种群中取出一定数量个体(放回抽样),然后选择其中适应度最好的一个进入子代种群^[16]。重复该操作,直到新的种群规模达到原来的种群规模。新种群集合为:

$$P(i) = D^*(x_i) \tag{22}$$

式中: N 为种群规模; $i = 1, 2, \dots, n$ 。

(3) 本文采用有序交叉方式,交叉概率是 p_c 。交叉示意图如图 3 所示。

交叉完成后的个体再采用倒置变异法,将种群中个体编码上的某些基因位的值以变异概率 p_m 进行变动。编码个体被随机选择某两个基因位,倒置两个基因位中间部分,产生新的个体。若新个体适应度值优于原个体,则保留新个体,否则仍保留原个体,变异示意图如图 4 所示。

(4) 最终遗传算法优化后的均值 $\hat{c}_{ij}$ 、标准差 $\hat{b}_j$ 和权值 $\hat{w}$,代回风烟系统模糊 RBF 神经网络的高斯基函数内。




图 3 交叉示意图
Fig. 3 Crossover diagram




图 4 变异示意图
Fig. 4 Variation diagram

2 滑模自抗扰控制器

2.1 自抗扰控制策略设计

ADRC 由跟踪微分器(tracking-differentiator, TD)、扩张状态观测器(extended state observer, ESO)和非线性状态误差反馈控制律(nonlinear state error feedback, NLSEF)3 部分组成。由式(5)设计的风烟系统状态方程,设定 TD 方程为:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = Rx_2 - C(x_1 - x_2) \end{cases} \tag{23}$$

式中: x_1 是跟踪风烟系统一次风量输出信号; x_2 是输出信号 x_1 的变化率; R 为风烟模型滤波因子; C 是风烟模型变化因子, C 越大,跟踪速度越快。

但风烟系统在采集一次风量信号时会遇到噪声干扰,为减少噪声干扰,用饱和函数 $sat()$ 改进跟踪微分器。改进后的公式为:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = Rx_2 - Csat(x_1 - x_2, \sigma) \end{cases} \tag{24}$$

$$sat(x, \sigma) = \begin{cases} sign(x), & |x| \geq \sigma \\ \frac{x}{\sigma}, & |x| \leq \sigma \end{cases} \tag{25}$$

式中: σ 为输出信号开关变量。

通过对模型实际输出 y 设计风烟系统扩张状态观测器, 把风烟系统内含有未知扰动的对象转化为积分对象, 扩张状态观测器方程为:

$$\begin{cases} \dot{\theta}_1 = z_1 - y \\ \dot{z}_1 = z_2 - \alpha_1 r_1(\theta_1) \\ \dot{z}_2 = z_3 - \alpha_2 r_2(\theta_1) + Au(t) \\ \dot{z}_3 = -\alpha_3 r_3(\theta_1) \end{cases} \quad (26)$$

式中: $r(\theta_1)$ 为风烟控制器输出的扰动估计量; z_1, z_2 表示辨识风烟系统输出 y 的跟踪信号和跟踪信号的微分量; z_3 为风烟系统非线性函数的观测值; α_1, α_2 和 α_3 为误差校正增益。为验证 ESO 能够收敛, 设观测器的带宽为 w_0 ($w_0 > 0$), 要求 ESO 极点均处于左半平面 w_0 处。参考文献[17] 选择合适的增益值 α_1, α_2 和 α_3 , 使 $s^3 + \alpha_1 s^2 + \alpha_2 s + \alpha_3 = (s + w_0)^3$ 满足 Hurwitz 条件。当 $t \rightarrow \infty$, 同时 w_0 选择合适值时, ESO 处于稳定状态, 保证 z_3 能正常观测系统干扰量。




图 5 控制结构

Fig. 5 Control structure diagram

设计滑模切换函数为:

$$s = c_1 e_1 + c_2 e_2^\gamma \quad (30)$$

式中: c_1, c_2, γ 为 > 0 的常数, 选取适当常数, 构成稳定的滑模面。

由于控制系统存在线性量和非线性量^[19], 将滑模控制律设计为线性控制分量和非线性控制分量:

$$u_c = u_l + u_{nl} \quad (31)$$

再对 s 求导有:

$$\begin{aligned} \dot{s} &= c_1 \dot{e}_1 + c_2 \gamma e_2^{\gamma-1} \dot{e}_2 = \\ &= c_1 e_2 + c_2 \gamma e_2^{\gamma-1} \{f + A[u(X, t)]\} \end{aligned} \quad (32)$$

令 $\dot{s} = 0$, 可以找寻到线性控制分量为:

$$u_l = - \left(\frac{c_1}{c_2 \gamma} e_2^{2-\gamma} + f \right) / A \quad (33)$$

在已知一次风量跟踪输出信号 x_1, x_2 和 ESO 的输出值 z_1, z_2 , 构造系统的跟踪一次风量误差信号为:

$$\begin{cases} e_1 = x_1 - z_1 \\ e_2 = x_2 - z_2 \end{cases} \quad (27)$$

根据式(27)所提供的误差, 设计如下非线性配置实现 NLSEF:

$$u_0 = \beta_1 fal(e_1) + \beta_2 fal(e_2) \quad (28)$$

式中: β_i 为可调参数; $fal(e)$ 为控制函数。

$$fal(e) = \begin{cases} |e|^\lambda sign(e), & |e| > \delta \\ \frac{e}{\delta^{1-\lambda}}, & |e| < \delta \end{cases} \quad (29)$$

式中: λ 为非线性因子; δ 为开关变量。

2.2 滑模自抗扰控制策略设计

已知 NLSEF 控制律, 但是风烟系统存在大惯性和参数不稳定问题, 为实现控制系统对风烟系统的稳定性同时, 降低系统的需要选择参数^[18]。但是 ADRC 中涉及控制参数较多, 为简化控制参数, 同时加快误差收敛速度, 本文将 SMC 和 ADRC 相结合, 设计结构框图如图 5 所示。

再设计满足 $s\dot{s} \leq 0$ 条件的滑模趋近律, 为减少风烟系统的控制时间, 此处选择幂次趋近律^[20], 令 $\dot{s} = -c_3 |s|^\epsilon sgn(s)$ 满足条件 $0 < c_3, 0 < \epsilon < 1$ 。通过调整 c_3 的数值, 实现降低抖振的效果, 得到非线性控制分量为:

$$u_{nl} = (-c_3 |s|^\epsilon sgn(s)) / A \quad (34)$$

将式(33)、(34)代入式(31)中, 可得滑模控制器的控制律为:

$$u_c = - \left(\frac{c_1}{c_2 \gamma} e_2^{2-\gamma} + f + c_3 |s|^\epsilon sgn(s) \right) / A \quad (35)$$

2.3 稳定性分析

已知系统为式(5), 跟踪误差必须有界。根据所选滑模面和所设计滑模控制, 选取 Lyapunov 函数^[21]为:

$$V_s = s^2 / 2 \quad (36)$$

对 Lyapunov 函数进行微分处理得:

$$\begin{aligned} \dot{V}_s &= s\dot{s} = s(c_1\dot{e}_1 + c_2\gamma e_2^{\gamma-1}\dot{e}_2 - c_3|s|^e \operatorname{sgn}(s)) = \\ &= sc_1e_2 + sc_2\gamma e_2^{\gamma-1}\{f + A[u(\mathbf{X}, t)]\} - c_3s|s|^e \operatorname{sgn}(s) = \\ &= sc_1e_2 + sc_2\gamma e_2^{\gamma-1}\dot{x}_2 - c_3|s|^{e+1} \end{aligned} \quad (37)$$

当 ESO 跟踪系统状态时 $e_1、e_2$ 趋近于 0, $c_1、c_2、c_3$ 均为 >0 的常数, $1 < \gamma < 2$, 所以 $\dot{V}_s < 0$ 在设计滑模控制律下, 当且仅当 $s = 0$ 时, $\dot{s} = 0$, 在任意 $s \neq 0$ 的初始状态, 总能保证在有限时间收敛为 0。当风烟控制系统远离滑模面时, 能以较快收敛速度回到滑模面, 当风烟控制系统趋近滑模面时, 采用较小的控制增益, 能有效降低抖振。

3 系统辨识和仿真分析

3.1 辨识模型

由于辨识过程中, 样本参数来源于工厂实际数据, 所以需要在式(6)二阶惯性环节上增加滞后环节, 可得:

$$G(s) = \frac{K_1 K_2}{(T_1 s + 1)(T_2 s + 1)} e^{-\tau s} \quad (38)$$

为验证遗传算法优化的模糊 RBF 算法的有效性, 采集某 330 MW 发电机组某日正常运行数据 100 组, 其中输入数据为一次风阀开度, 输出数据为一次风量, 并对采集数据进行剔除异值预处理。算法辨识循环次数为 50 次, 定义辨识精度为 0.001, 当辨识精度达到定义值, 得到风烟数学模型, 其传递函数为:

$$G(s) = \frac{6.22}{(16.53s^2 + 11.25s + 1)} e^{-40s} \quad (39)$$

参考文献[22]选取遗传算法优化的模糊 RBF 相关参数分别为学习速率为 0.05, 动量因子为 0.3, 种群数为 100, 每个染色体含有参数个数为 10, 迭代次数为 50 次, 初始交叉率为 0.1, 初始变异率为 0.2, 目标精度为 0.001。采用 MATLAB 仿真 GA 优化的模糊 RBF 逼近图像和传统模糊 RBF 逼近图像对比如图 6 所示。




图 6 模糊 RBF 网络预测结果对比

Fig. 6 Comparison of prediction results of fuzzy RBF networks

100 组数据的误差分析如图 7 所示, 可得, GA-fuzzyRBF 误差均方和为 0.678 7, 传统 fuzzyRBF 误差均方和为 19.408 3。遗传算法优化的模糊 RBF 算法比传统模糊 RBF 算法误差均方和低两个数量级, 能有效逼近风烟系统模型。




图 7 输出误差对比

Fig. 7 Comparison of output error

3.2 控制系统抗扰控制仿真

为验证本文控制算法在火力发电机组风烟控制系统的效果, 运用 MATLAB 软件进行仿真。滑模自抗扰控制系统控制参数参考文献[23]的选取, 跟踪微分器模型变化因子 $C=100$, 模型滤波因子 $R=0.03$, 扩张状态观测器校正增益 $\alpha_1=30, \alpha_2=300, \alpha_3=1\,000$, 非线性状态误差反馈滑模控制律 (nonlinear state error feedback sliding mode, NLSEFSM) 中参数 $\varepsilon=0.03$ 。为防止峰值现象, 跟踪信号初值取 0。

在输入为阶跃响应的情况下, 对比串级 PID, 滑模控制, 自抗扰控制和滑模自抗扰控制 4 种控制策略。控制系统效果如图 8 所示。同时为观察系统抗干扰能力, 在系统运行 200 s 时施加 10% 的干扰。




图 8 系统适配一次风量效果对比

Fig. 8 The system adapts the primary air volume effect comparison diagram

由图8可知,当系统模型适配时,施加扰动前。串级PID控制超调量为31.96%,调节时间为57.2 s;滑模控制超调量为12.06%,调节时间为48.8 s;自抗扰控制超调量为7.6%,调节时间为43.9 s。滑模自抗扰控制由于良好的跟踪效果,没有超调量,同时调节时间为38 s。

200 s后施加幅值为20%反向阶跃扰动,串级PID控制超调量为21.33%,调节时间为57.8 s;滑模控制超调量为11.9%,调节时间为48.9 s;自抗扰超调量为10.83%,调节时间为42.3 s;滑模自抗扰超调量为3.4%,调节时间为39.5 s。对比可知,滑模自抗扰控制兼具良好的抗干扰性能和调节时间短的优点。

当风烟系统更换煤质时会出现失配现象,经过风烟系统模糊RBF辨识的系统传递函数为:

$$G(s) = \frac{3.22}{(19.53s^2 + 8.65s + 1)} e^{-40s} \quad (40)$$

系统失配控制效果如图9所示。为验证控制系统在系统失配下抗干扰能力,在系统运行第200 s施加幅值为20%的反向阶跃干扰。




图9 系统失配一次风量阶跃效果对比

Fig. 9 Step effect comparison diagram of system mismatch primary air volume

由图9可知,施加扰动前,串级PID控制、滑模控制、自抗扰控制和滑模自抗扰控制超调量分别为34.86%、11.8%、3.67%和0,调节时间分别为78.1、74.1、68.5和43.2 s。200 s后施加幅值为20%的反向阶跃扰动,串级PID控制、滑模控制、自抗扰控制和滑模自抗扰控制的超调量分别为20.9%、10.67%、9.5%和3.87%,调节时间分别为79.8、75.6、58.8和46.4 s。对比可知,滑模自抗扰控制相比较传统滑模控制和自抗扰控制在模型失配时控制效果更好,响应速度更快。

为验证滑模自抗扰算法在面对强干扰时的优越性,增加设计滑模自抗扰算法和相近的施加干扰观测器的滑模算法对比。在设定参数不变的情况下,给系统在200 s处施加正向10%的干扰,文献[18]选择含干扰观测器的滑模算法运用于已辨识的适配风烟系统,控制效果对比

如图10所示。




图10 滑模控制效果对比

Fig. 10 Comparison diagram of sliding mode control effect

由图10可知,当控制系统模型相同时,施加扰动前,含干扰观测器的滑模控制和滑模自抗扰控制超调量分别为7.23%和0%,调节时间分别为48.7和43.2 s。200 s后施加幅值为10%的正向阶跃扰动,含干扰观测器的滑模控制和滑模自抗扰超调量分别为9.22%和3.89%,调节时间分别为43.5和41.4 s。对比可知,滑模自抗扰控制相比较含干扰观测器的滑模控制在遇到干扰时,两种控制策略均能在较快速时间响应,但是滑模自抗扰控制策略产生的超调量更小,系统稳定性更优越。

3.3 控制系统跟踪控制仿真

上述仿真只验证了阶跃信号的情况,但是发电机组运行过程中存在变负荷运行,所以增加验证变负荷运行跟踪控制的仿真实验^[21-22],运行过程中加入白噪声,在150 s处负荷增加50%,在300 s处负荷降低30%,结果如图11所示。由图11可知,跟踪微分器能良好跟踪输入信号,在运行过程中出现变动时,跟踪微分器可以在2 s内进行响应。




图11 跟踪效果实现图

Fig. 11 Tracking effect realization diagram

扩张状态观测器对内外扰动的观测值,由图12可知,观测的内外扰动信息与实际值进行比较的差值较小,

扩张状态观测器能很好的跟踪到系统的干扰信号,利于后续进行的变负荷跟踪控制。




图12 扩张状态观测器内外扰动输出

Fig. 12 Output diagram of internal and external disturbances of the extended state observer

对比滑模自抗扰控制和自抗扰控制的控制效果如图13所示。由图13可知,滑模自抗扰控制具有较好的工况适应性,在变负荷的工况下,控制效果优于自抗扰控制,在第1次负荷变动时,PID控制所需调节时间为56.2 s,自抗扰控制所需调节时间为49.4 s,滑模自抗扰控制所需调节时间为32.2 s。在第2次负荷变动时,PID控制所需调节时间为62.3 s,自抗扰控制所需调节时间为50.6 s,滑模自抗扰控制所需调节时间为36.2 s。说明滑模自抗扰控制在变负荷工况下能及时跟踪输入变化量,且输出稳定,同时具备系统调节时间短、超调量小的优点。




图13 变负荷控制效果对比

Fig. 13 Variable load control effect comparison diagram

4 工程应用

为验证滑模自抗扰控制系统在实际中应用的有效性,本文选取某炼钢厂的330 MW发电机组为研究对象。该机组采用的控制系统是西门子PLC^[24],在不改变原系

统的结构和配置的情况下,增加一套由优化控制器和工业计算机组成的风烟优化控制系统。工业计算机与优化控制器通过工业以太网以OPC协议进行数据交互,用户可通过工业计算机进行数据采集、参数设置、集中监控等功能^[25]。控制系统通过OPC协议从原系统读取燃煤发电机组各项数据,承担优化运行、实时监控和系统报警等功能。

本文将滑模自抗扰控制策略投入现场运行,发电机组在额定负荷下采用串级PID控制和SM-ADRC的主蒸汽压力实时曲线如图14所示,根据现场实际运行要求,将一次风量控制在300 000 m³/h左右,检测时间为4 h,得到应用实际效果。




图14 一次风量实际应用效果

Fig. 14 Actual application of primary air volume effect diagram

由图14可知,滑模自抗扰控制系统运行期间,一次风量最高值为30.44,最低为29.26,上下波动为3.9%,一次风量的控制偏差在±10 000 m³/h以内,符合现场实际运行要求。而原串级PID控制策略下一次风量最高值为34.38,最低为26.91,一次风量的控制偏差在±50 000 m³/h以内,上下波动为24.9%。与串级PID控制相比,本文设计的优化控制系统,波动变化范围降低21%,受现场干扰影响小,鲁棒性强。

5 结论

燃煤发电机组风烟控制系统存在大惯性、大滞后和参数不稳定等问题,鉴于常规控制方法难以达到理想控制效果,本文提出了一种基于滑模自抗扰控制一次风量的策略,利用遗传算法优化的模糊RBF算法辨识系统模型,便于本文进行控制系统仿真。采用滑模自抗扰控制算法,设计非线性误差反馈滑模控制律,有效提高控制系统抗干扰能力和加快控制系统收敛速度,保证了发电机组运行的安全性和控制系统的鲁棒性。

采用 MATLAB 软件对该方法进行了仿真,结果表明遗传算法优化的模糊 RBF 算法具有良好的逼近效果。滑模自抗扰控制策略与传统滑模控制和自抗扰控制相比,使系统调节作用平稳,抗干扰能力强,负荷适应能力强,超调量小。最后,将本文控制策略应用于某钢厂燃煤发电机组,一次风量的控制偏差在 $\pm 10\,000\text{ m}^3/\text{h}$ 以内,较原控制策略波动范围降低 21%,有效地提高了控制系统的稳定性和鲁棒性。

参考文献

- [1] 李皓宇. 燃煤锅炉劣质煤数字化智能深度掺烧系统研发与应用[J]. 中国电机工程学报, 2021, 41(13): 4543-4552.
- LI H Y. Research and application of digital intelligent mixedly burning inferior coal deeply system in coal-fired boiler[J]. Proceedings of the CESS, 2021, 41(13): 4543-4552.
- [2] 王东风, 刘千, 韩璞, 等. 基于大数据驱动案例匹配的电站锅炉燃烧优化[J]. 仪器仪表学报, 2016, 37(2): 420-428.
- WANG D F, LIU Q, HAN P, et al. Power plant boiler combustion optimization based on big data-driven case matching[J]. Chinese Journal of Scientific Instrument, 2016, 37(2): 420-428.
- [3] 杜阔. 超超临界界锅炉制粉和风烟系统动态仿真及其参数自整定[D]. 南京: 东南大学, 2019.
- DU K. Dynamic simulation and parameter self-tuning of pulverizing and fume system of ultra-supercritical boiler[D]. Nanjing: Southeast University, 2019.
- [4] 马良玉, 左晓桐, 王永军. 神经网络在风烟系统含氧量软测量中的应用[J]. 自动化仪表, 2019, 40(3): 12-16, 22.
- MA L Y, ZUO X T, WANG Y J. The application of neural networks in soft measurement of oxygen content in wind and smoke systems[J]. Process Automation Instrumentation, 2019, 40(3): 12-16, 22.
- [5] ZHANG Y, MEN Y H, HAN P. Modeling and simulation of complex fluid networks in the flue gas system of a boiler[J]. Energies, 2017, 10(9): 1432-1444.
- [6] 卓旭升, 杨帆, 秦实宏, 等. 火电机组协调系统的非线性串级控制研究[J]. 华中科技大学学报(自然科学版), 2012, 40(4): 43-45, 75.
- ZHUO X SH, YANG F, QIN SH H, et al. Nonlinear cascade control research of a drum boiler turbine unit in thermal power plants[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2012, 40(4): 43-45, 75.
- [7] 黎青鑫, 陈机林, 侯远龙, 等. 某随动平台模糊 RBF 神经网络终端滑模控制设计[J]. 电光与控制, 2020, 27(12): 90-94, 104.
- LI Q X, CHEN J L, HOU Y L, et al. Design of terminal sliding mode control based on fuzzy RBF neural network for a servo platform[J]. Electronics Optics & Control, 2020, 27(12): 90-94, 104.
- [8] 付颜, 潘蕾, 王钱超. 基于机器学习的锅炉送风控制系统仿真及优化[J]. 工程热物理学报, 2022, 43(7): 1777-1782.
- FU Y, PAN L, WANG Q CH. Simulation and optimization of boiler air supply control system based on machine learning[J]. Journal of Engineering Thermophysics, 2022, 43(7): 1777-1782.
- [9] 冯旭刚, 张泽辰, 王正兵, 等. 基于 IGPC-NADRC 火电机组制粉系统控制策略[J]. 中南大学学报(自然科学版), 2023, 54(7): 2904-2918.
- FENG X G, ZHANG Z CH, WANG ZH B, et al. Control strategy of coal pulverizing system based on igpc-nadrc[J]. Journal of Central South University (Science and Technology), 2023, 54(7): 2904-2918.
- [10] 王素珍, 刘庆龙, 孙国法. 基于扩张状态观测器的换热器动态面控制[J]. 化工学报, 2018, 69(12): 5139-5145.
- WANG S ZH, LIU Q L, SUN G F. Dynamic surface control of heat exchanger based on extended state observer[J]. CIESC Journal, 2018, 69(12): 5139-5145.
- [11] 张世华, 齐晓慧, 万慧. 广义非线性扩张状态观测器设计及性能分析[J]. 控制理论与应用, 2021, 38(12): 2059-2068.
- ZHANG SH H, QI X H, WAN H. Design and performance analysis of generalized nonlinear extended state observer[J]. Control Theory and Applications, 2021, 38(12): 2059-2068.
- [12] 赵岩, 周秦源, 邵念锋, 等. 基于 RBF 神经网络模糊 PID 控制的电液伺服系统[J]. 机电工程, 2022, 39(2): 244-249.
- ZHAO Y, ZHOU Q Y, SHAO N F, et al. Electrohydraulic servo system based on RBF neural network fuzzy PID control[J]. Journal of Mechanical & Electrical Engineering, 2022, 39(2): 244-249.
- [13] 李壮年, 储满生, 柳政根, 等. 基于机器学习和遗传算法的高炉参数预测与优化[J]. 东北大学学报(自然科学版), 2020, 41(9): 1262-1267.
- LI ZH N, CHU M SH, LIU ZH G, et al. Prediction and optimization of blast furnace parameters based on machine learning and genetic algorithm[J]. Journal of North-

- eastern University (Natural Science), 2020, 41(9): 1262-1267.
- [14] 曹丽华, 丁皓轩, 葛维春, 等. 基于遗传算法的热电机组储热罐最优运行策略[J]. 中国电机工程学报, 2020, 40(11): 3574-3583.
- CAO L H, DING H X, GE W CH, et al. Optimal operation strategy of heat storage tank in CHP unit based on genetic algorithm [J]. Proceedings of the CESS, 2020, 40(11): 3574-3583.
- [15] WANG ZH ZH, CAO L H, SI H Y. An improved genetic algorithm for determining the optimal operation strategy of thermal energy storage tank in combined heat and power units[J]. Journal of Energy Storage, 2021, 43: 103313.
- [16] WU ZH L, SHI G J, LI D H, et al. Control of the fluidized bed combustor based on active disturbance rejection control and bode ideal cut-off[J]. IFAC Papers on Line, 2020, 53(2): 12517-12522.
- [17] NADIA D, MAAMAR B, SAID D. Sliding mode active disturbance rejection control for uncertain nonlinear fractional-order systems [J]. European Journal of Control, 2021, 57: 54-67.
- [18] 章家岩, 王胜, 冯旭刚, 等. 燃气发电锅炉主汽压滑模预测优化控制策略[J]. 西安交通大学学报, 2021, 55(1): 60-67.
- ZHANG J Y, WANG SH, FENG X G, et al. Sliding mode prediction and optimization control strategy for main steam pressure of gas-fired power generation boiler[J]. Journal of Xi'an Jiaotong University, 2021, 55(1): 60-67.
- [19] 韩俊庆, 吴爱国, 董娜. 基于滑模干扰观测器的机械臂终端滑模控制[J]. 中南大学学报(自然科学版), 2020, 51(10): 2749-2757.
- HAN J Q, WU AI G, DONG N. Terminal sliding mode control of manipulator based on sliding mode disturbance observer[J]. Journal of Central South University (Science and Technology), 2020, 51(10): 2749-2757.
- [20] TIAN ZH, YUAN J Q, XU L, et al. Model-based adaptive sliding mode control of the subcritical boiler-turbine system with uncertainties[J]. ISA Transactions, 2018, 79: 161-171.
- [21] XIA K, XIA SH SH, SHEN Q, et al. Moisture spectral characteristics and hyperspectral inversion of fly ash-filled reconstructed soil [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 253: 119590.
- [22] WANG F, CHAO ZH Q, HUANG L B, et al. Trajectory tracking control of robot manipulator based on RBF neural network and fuzzy sliding mode[J]. Cluster Computing, 2019, 22(3): 5799-5809.
- [23] SUN L, HUA Q S, LI D H, et al. Direct energy balance based active disturbance rejection control for coal-fired power plant[J]. ISA Transactions, 2017, 70: 486-493.
- [24] 耿林霄, 郭亦文, 杨猛, 等. 基于大数据智能控制一体化平台架构的智慧监盘关键技术研究[J]. 热力发电, 2021, 50(9): 43-48.
- GENG L X, GUO Y W, YANG M, et al. Research on key technologies of smart disk monitoring based on big data intelligent control integrated platform architecture[J]. Thermal Power Generation, 2021, 50(9): 43-48.
- [25] 冯旭刚, 张泽辰, 刘圣晶, 等. 基于 IGPC 的火力发电机组主汽温预测控制策略[J]. 中国电机工程学报, 2022, 42(9): 3307-3317.
- FENG X G, ZHANG Z CH, LIU SH J, et al. Based on the main steam temperature for coal-fired power units IGPC predictive control strategy[J]. Proceedings of the CESS, 2022, 42(9): 3307-3317.

作者简介



冯旭刚(通信作者), 2011 年于合肥工业大学获得博士学位, 现为安徽工业大学教授, 硕士生导师, 主要研究方向为工业炉窑智能优化控制。

E-mail: fxg@ahut.edu.cn

Feng Xugang (Corresponding author)

received his Ph. D. degree from Hefei University of Technology in 2011. He is currently a professor and a M. Sc. supervisor at Anhui University of Technology. His main research interest includes intelligent and optimized control of industrial furnaces.



宋爱国, 1993 年于南京航空航天大学获得硕士学位, 1996 年于东南大学获得博士学位, 现为东南大学教授, 主要研究方向为遥控操作技术、人机交互、康复机器人等。

E-mail: a. g. song@seu.edu.cn

Song Aiguo received his M. Sc. degree from

Nanjing Aeronautics and Astronautics University in 1993, and Ph. D. degree from Southeast University in 1996. He is currently a professor at Southeast University. His main research interests include teleoperation, human computer interaction, rehabilitation robot, etc.