

基于改进PSO算法的过热汽温神经网络预测控制

肖本贤¹, 王晓伟¹, 朱志国¹, 刘一福²

(1. 合肥工业大学 自动化研究所, 安徽 合肥 230009; 2. 安徽省电力科学研究院 热控自动化所, 安徽 合肥 230022)

摘要: 将改进粒子群优化算法(MPSO)融合到神经网络预测控制中, 提出了基于MPSO-RBF混合优化策略的模型预测器, 以及基于MPSO算法的非线性优化控制器. 针对过热汽温的控制, 构造了基于神经网络预测控制的串级控制系统, 并就该系统在实现时所涉及到的预测模型、滚动优化算法、反馈校正、仿真参数设置问题等进行了分析, 给出了MPSO算法的粒子编码、操作设计和混合优化算法步骤. 对某超临界600 MW直流锅炉高温过热器的过热汽温控制, 进行了仿真试验, 结果表明该方法具有良好的性能指标和应用前景.

关键词: 改进PSO算法; RBF神经网络; 优化策略; 神经网络预测控制; 过热汽温

中图分类号: TP273 **文献标识码:** A

Neural network predictive control for superheated steam temperature based on modified particle swarm optimization

XIAO Ben-xian¹, WANG Xiao-wei¹, ZHU Zhi-guo¹, LIU Yi-fu²

(1. Institute of Industrial Automation, Hefei University of Technology, Hefei Anhui 230009, China;

2. Institute of Thermo Dynamic Automation, Anhui Electric Power Research Institute, Hefei Anhui 230022, China)

Abstract: Combining modified particle swarm optimization (MPSO) with neural network predictive control (NNPC), we propose a model-prediction controller, based-on modified particle swarm optimization (MPSO) and radial basis function (RBF) hybrid optimization strategy (MPSO-RBF), and a nonlinear optimization controller, based-on MPSO. For the superheated steam temperature control, we construct a cascade control system based on the neural network predictive control, and analyze all related problems, including the predictive model, the rolling optimizing algorithm, the feedback adjusting and the simulation-parameter setting. We also present the particle encoded format of MPSO, operating design method, and steps in hybrid optimization algorithm. Simulation experiments of the superheated steam temperature control were done in a super-critical-600 MW direct-current boiler, demonstrating the validity, the superior performance and the application prospects.

Key words: modified particle swarm optimization (MPSO); RBF neural networks; optimized strategy; neural network predictive control (NNPC); superheated steam temperature

1 引言(Introduction)

火电厂锅炉高温过热器的过热汽温是一类非线性、时变性、大时滞、大惯性的典型对象. 目前主要采用常规串级式PID控制, 在干扰量大、工况发生变化时, 难以达到理想的控制效果. 为解决这一问题, 人们从不同角度进行了大量研究^[1,2]. NNPC充分利用了神经网络的非线性映射能力以及预测控制滚动优化、反馈校正的机理, 更符合复杂系统控制的不确定性和时变性的实际情况. 为进一步改善NNPC的性能, 本文将具有全局搜索能力、实用性强的PSO算法^[3~5]融合到NNPC中, 并通过通过对过热汽温系统进行

设计和仿真研究.

2 神经网络预测控制系统结构(Structure of NNPC system)

预测控制不论算法的形式如何, 其本质特征都包括3个部分: 预测模型、滚动优化、反馈校正. 本文采用的NNPC结构如图1.

神经网络预测器建立了非线性被控对象的预测模型, 利用该模型, 可以从当前的系统控制信息中预测出在未来 P 步的输出值 $y_R(k+P)$. 再通过设计优化性能指标, 利用非线性优化控制器可求出优化的

控制量.




图1 NNPC原理图

Fig. 1 Schematic diagram of NNPC

3 改进的粒子群优化算法(MPSO)

假设在一个 D 维搜索空间, 有 M 个粒子组成一个群体, 第 i 个粒子在 D 维空间里的位置表示为矢量 $x_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$, $i = 1, 2, \dots, M$, 速度矢量 $\nu_i = [\nu_{i1}, \nu_{i2}, \dots, \nu_{iD}]$, 通过粒子群的目标函数对粒子当前位置做出评价. 第 i 个粒子当前找到的最佳位置记 $p_{best} = [p_{i1}, p_{i2}, \dots, p_{iD}]$, 即粒子个体极值; 所有粒子当前找到的最佳位置记 $g_{best} = [p_{g1}, p_{g2}, \dots, p_{gD}]$, 即群体全局极值. 对于第 k 次迭代, PSO中的每一粒子速度、位置按下式更新:

$$\begin{aligned} \nu_{id}^{k+1} &= w\nu_{id}^k + c_1 r_1 (p_{id} - x_{id}^k) + c_2 r_2 (p_{gd} - x_{id}^k), \\ x_{id}^{k+1} &= x_{id}^k + \nu_{id}^{k+1}. \end{aligned} \quad (1)$$

ν_{id}^k : 第 k 次迭代粒子 i 速度矢量的第 d 维分量; x_{id}^k : 第 k 次迭代粒子 i 位置矢量的第 d 维分量; p_{id} : 粒子 i 个体极值 p_{best} 的第 d 维分量; p_{gd} : g_{best} 的第 d 维分量; c_1, c_2 : 加速因子; r_1, r_2 : $[0, 1]$ 间随机数; w : 惯性权重. 为避免粒子在全局最优解附近振荡, w 随迭代的进行^[4], 由最大加权因子 w_{max} 线性减小到最小 w_{min} . 即:

$$w = w_{max} - iter \times \frac{w_{max} - w_{min}}{iter_{max}}. \quad (3)$$

$iter$ 为当前迭代数, $iter_{max}$ 为总的迭代次数. 为进一步保证搜索收敛性, Clerc^[5]引入了收缩因子, 将式(1)变为

$$\begin{aligned} \nu_{id}^{k+1} &= k' [w\nu_{id}^k + c_1 r_1 (p_{id} - x_{id}^k) + c_2 r_2 (p_{gd} - x_{id}^k)], \\ k' &= \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|}, \varphi = c_1 + c_2 > 4. \end{aligned} \quad (5)$$

收缩因子方法在数学理论上保证了搜索过程收敛性, 为此文章采用引入收缩因子的MPSO.

4 基于MPSO的神经网络预测器结构与算法 (Structure and algorithms of NN predictor based on MPSO)

4.1 非线性系统的神经网络表达方式 (NN expression for non-linear system)

系统中预测模型由带有延时结构的RBF网络来

实现, 其单步预测模型如图2. RBF由输入层、径向基层和输出层构成. 径向基层单元的作用函数取高斯基函数, 该层神经元 j 的输出为式(6):

$$h_j = \exp\left(-\frac{\|X - C_j\|^2}{2b_j^2}\right), j = 1, 2, \dots, m. \quad (6)$$

式中: X 是一个 $n = n_u + n_\nu$ 维的输入向量, C_j 为中心向量, b_j 是基宽参数, m 是径向基层神经元数. 单输出的RBF网络非线性函数映射关系为

$$f(X) = WH = \sum_{j=1}^m w_j h_j, \quad (7)$$

式中 W 是径向基层与输出层间的网络权向量. RBF网络模型单步预测的输出为

$$\begin{aligned} y_R(k+1) &= f[y(k), y(k-1), \dots, y(k-n_\nu+1), \\ &\quad u(k), u(k-1), \dots, u(k-n_u+1)] = \\ &\quad f_R[X(k+1)]. \end{aligned} \quad (8)$$

对于RBF多步预测模型, 只要将NARMAX模型写成

$$y_R(k+j) = f_R[X(k+j)], \quad (9)$$

$$\begin{aligned} X(k+j) &= [y(k+j-1), \dots, y(k+j-n_\nu), \\ &\quad u(k+j-1), \dots, u(k+j-n_u)], \end{aligned} \quad (10)$$

其中 $j = 1, 2, \dots, P$ 为预测步数. 在 k 时刻, 由于式(10)中 $y(k+j-1), \dots, y(k+j-n_\nu)$ 是未来的输出值, 所以用RBF网络的模型预测值 $y_R(k+j-1), \dots, y_R(k+j-n_\nu)$ 来代替, 实现基于一歩预报的多步递推的 k 时刻神经网络模型的多步预测. RBF网络在应用时, 需确定3类参数: 中心矢量 C_j 、基宽向量 B 、网络权值 W ^[6].




图2 带延时结构的RBF单步预测模型

Fig. 2 Single step predictive model of RBF with time delay

4.2 MPSO-RBF混合优化策略 (MPSO-RBF hybrid optimization strategy)

1) MPSO的粒子编码.

将要优化的 B, C_j 和 W 初值整合到一个向量中, 作为MPSO要寻优的位置向量, 采用浮点编码.

在 D 维空间内搜索的粒子编码格式为

|粒子位置||粒子速度||目标函数|,

对应

$|x_1, x_2, \dots, x_D||\nu_1, \nu_2, \dots, \nu_D||f(x_1, x_2, \dots, x_D)|$.

若RBF网络结构为2-4-1, 则需要优化的参数共16个. 粒子个体 X 记作

$$X = [x_1, x_2, \dots, x_{16}, \nu_1, \nu_2, \dots, \nu_{16}, f(x_1, x_2, \dots, x_{16})],$$

式中: $[x_1, x_2, x_3, x_4]$ 对应 $B = [b_1, b_2, b_3, b_4]$; $[x_5, x_6, \dots, x_{12}]$ 对应 $C_1 = [c_{11}, c_{12}, c_{13}, c_{14}]$, $C_2 = [c_{21}, c_{22}, c_{23}, c_{24}]$; $[x_{13}, x_{14}, x_{15}, x_{16}]$ 对应 $W = [w_1, w_2, w_3, w_4]$.

2) MPSO参数设置.

文献[7]给出了MPSO的实现, 其典型设置为 $w_{\max} = 0.9$, $w_{\min} = 0.4$, $c_1 = 2.05$, $c_2 = 2.05$. 粒子群规模一般取20~40就可取得好的结果.

3) 混合优化算法步骤.

步骤1 给定网络的 N 组输入、输出训练样本集;

步骤2 确定RBF网络结构后, 进行MPSO的编码, 并对粒子群初始化;

步骤3 译码每一粒子个体串, 得到每个粒子对应的RBF网络参数, 计算 N 组输入样本在此RBF下 N 组的输出, 将其和输出样本带入RBF网络逼近的性能指标函数, 即得到该粒子的 p_{best} ;

步骤4 评价各粒子的目标函数, 得出粒子群的 g_{best} ;

步骤5 判断 g_{best} 是否满足MPSO结束条件. 满足就退出MPSO寻优, 转入RBF局部优化即第7步;

步骤6 对每一粒子进行速度和位置更新, 再转入第3步;

步骤7 译码 g_{best} 所对应的那个粒子的个体串, 以此进化值为RBF网络的初值, 进行局部优化;

步骤8 对局部优化后的参数进行编码, 判断是否满足MPSO结束条件, 这里采用的结束条件为 g_{best} 达到一定的设定值, 若偏差超出设定目标, 再返回6, 进行MPSO全局搜索.

4.3 仿真比较(Simulation comparison)

1) 仿真模型.

为显示MPSO-RBF网络辨识效果的优越性, 采用文献[8]中的基于GA的RBF网络逼近仿真实例, 并对两者作比较.

非线性系统模型:

$$y(k) = u(k)^3 + \frac{y(k-1)}{1 + y(k-1)^2}.$$

输入:

$$u(k) = \sin(10\pi \times k \times t_s).$$

目标函数:

$$J_e = \frac{1}{2} \sum_{k=1}^n [y(k) - y_R(k)]^2.$$

2) 参数设置.

RBF网络结构为2-4-1. 采集200组样本, 各100组作训练和测试样本. 仿真时 $t_s = 0.001$, b_j 范围 $[0.1, +3]$, c_{ij} 范围 $[-3, +3]$, w_j 范围 $[-1, +1]$. 网络学习参数 $\alpha = 0.05$, $\eta = 0.85$. GA中, 采用二进制编码, 种群数 $Size = 30$, 交叉概率 $P_c = 0.60$, 采用自适应变异概率 $P_m = 0.001 - [1 : 1 : Size] \times 0.001 / Size$. MPSO中, 粒子群数 $Size = 30$, 粒子速度范围 $[0, +100]$.

3) 结果比较.

训练过程中, 使两种算法同样进化200代, 其目标函数值的变化如图3, 可以看出MPSO-RBF可以达到更优的辨识精度.




图3 MPSO/GA-RBF训练过程

Fig. 3 MPSO/GA-RBF training process

5 基于MPSO的非线性优化控制器(Non-linear optimization controller based-on MPSO)

5.1 滚动优化算法(Rolling optimizing)

NNPC中滚动优化的基本思想, 是通过迭代算法在有限的预测步数内, 搜索控制向量 $U = [u(k), u(k+1), \dots, u(k+L-1)]$, 使目标函数达到最小. 非线性优化器的目标函数为

$$\min J(k) =$$

$$\sum_{j=1}^p [y_p(k+j) - y_d(k+j)]^2 + \sum_{i=0}^{L-1} r_i [\Delta u(k+i)]^2. \quad (11)$$

$P(P \geq 1)$ 为预测步数, $L(0 \leq L \leq P)$ 为控制域长度, y_d 为参考轨迹, y_p 为经反馈校正后预测输出, r_i 为控制加权, $\Delta u(k+i) = u(k+i) - u(k+i-1)$.

实际中, 大多数系统存在约束条件: 如对控制量、输出量的限幅等, 在考虑约束的情况下则需求解

有约束的二次规划. 本文采用MPSO进行滚动优化, 同样将控制域上的一组控制变量序列作为MPSO要寻优的位置向量, 粒子的目标函数取滚动优化的目标函数, 以目标函数最小为评价标准.

5.2 反馈校正(Feedback compensation)

由于噪声干扰、模型失调等, 预测模型输出与过程输出之间常存在误差. 为此, 以 $y_R(k)$ 作反馈量构成闭环系统, 对未来控制域中的误差进行预测. k 时刻预测误差:

$$e(k) = y(k) - y_R(k). \quad (12)$$

校正后系统的闭环预测输出为

$$y_p(k+j) = y_R(k+j) + e(k), j=1, 2, \dots, P. \quad (13)$$

5.3 MPSO在滚动优化中的应用与仿真比较(Simulation comparison for MPSO)

仿真模型同4.3节, 分别用MPSO和Newton-Raphson滚动优化算法^[9]进行跟踪 $r(t) = 1$. 其中控制量 $U \in [-1, 1]$, 控制增量 $\Delta U \in [-0.3, 0.3]$. 最大迭代次数100, 整个优化过程中, 两种算法的目标函数值变化如图4, 可见采用MPSO进行滚动优化可获更优解.




图4 MPSO/Newton-Raphson滚动优化过程

Fig. 4 MPSO/Newton-Raphson rolling optimizing process

6 仿真研究(Simulation studying)

6.1 仿真对象 (Simulation object)

文献[1]给出了某超临界600 MW直流锅炉高温过热器在100%, 75%等负荷下汽温对喷水扰动的动态特性, 其输入为喷水流量, 输出为主蒸汽温度.

表1 过热汽温对喷水扰动的动态特性

Table 1 Dynamic characteristic with water spray disturbance

工况点	负荷	导前区/($^{\circ}\text{C}/(\text{kg} \cdot \text{s}^{-1})$)	惯性区/($^{\circ}\text{C}/^{\circ}\text{C}$)
1	100%	0.815	1.276
	$D=527.8\text{kg/s}$	$\frac{0.815}{(1+18S)^2}$	$\frac{1.276}{(1+18.4S)^6}$
2	75%	1.675	1.202
	$D=347.9\text{kg/s}$	$\frac{1.675}{(1+20S)^2}$	$\frac{1.202}{(1+27.1S)^7}$

现有的过热汽温控制采用串级PID控制, 内环采用P, 外环采用PID. 这里不改变串级系统的内环特性, 仅用NNPC取代外环主调节器. 则过热汽温控制辨识对象模型如图5, 其中 $P = 25$.




图5 过热汽温控制辨识对象模型

Fig. 5 Superheated steam temperature model identification

6.2 参数设置(Parameters setting)

1) MATLAB仿真中, 仿真采样时间取20 s. 为模拟现场情况. 在控制量加载时叠加随机干扰 $N = 0.5\text{randn}()$.

2) NN预测器中, 取 $n_v = 2$, $n_u = 6$, RBF网络结构选8-16-1, b_j 取值 $[0.1, +10]$, c_{ij} 取值 $[-10, +10]$; 混合优化结束条件取目标函数值 $J_e \leq 0.002$ 或最大进化代数400. 利用过热汽温模型, 取输入为变化幅度 $[-20, 20]$ 的随机信号, 仿真得到400组数据, 离线训练网络初值, 网络参数在线调整. 非线性优化器中, 经过仿真, 最终设置 $P = 9$, $L = 6$, $r_i = 0.8$.

3) 采用未融合MPSO的常规RBF的NNPC进行控制效果比较.

6.3 仿真结果(Simulation result)

选取受控对象为100%负荷的过热汽温模型, 系统跟踪温度设定值的控制效果比较如图6.




图6 100%负荷时系统跟踪温度设定值曲线

Fig. 6 Simulation results comparison 100% load

由结果看, 即使工作点变化较大时, 采用基于MPSO的NNPC所组成的串级过热汽温系统, 可以得到良好的控制品质. 而常规NNPC控制方法, 控制效果相对较差.

在NNPC中, 由于采用了5.3节的优化策略, MPSO在线优化所花时间约为2.414 s, 进行一次在线辨识系统非线性模型所花费时间约为6.822 s, 能

够满足对过热汽温实时控制的需要. 同时可根据具体控制对象, 在工况变化不大的情况下, 采取间断性地在线模型辨识, 可满足实时性更高的系统.

7 结论(Conclusion)

本文将MPSO算法融合到NNPC中, 提出基于MPSO-RBF混合优化策略的模型预测, 以及基于MPSO的滚动优化. 针对过热汽温的控制, 构造了基于此NNPC的串级控制系统, 通过仿真试验, 表明该方法具有良好的控制性能.

参考文献(References):

- [1] 范永胜, 徐本皋, 陈来九. 基于动态特性机理分析的锅炉过热汽温自适应模糊控制系统研究[J]. 中国电机工程学报, 1997, 17(1): 23 – 28.
(FAN Yongsheng, XU Bengao, CHEN Laijiu. Study of adaptive fuzzy control of boiler superheated steam temperature based on dynamic mechanism analysis[J]. *Proceedings of the Chinese Society for Electrical Engineering*, 1997, 17(1): 23 – 28.)
- [2] LAZAR M, PASTRAVANU O. A neural predictive controller for non-linear systems[J]. *Mathematics and Computers in Simulation*, 2002, 60(3/5): 315 – 324.
- [3] 王俊年, 申群太, 沈洪远, 等. 基于多种群协同进化微粒群算法的径向基神经网络设计[J]. 控制理论与应用, 2006, 23(2): 251 – 255.
(WANG Junnian, SHEN Quntai, SHEN Hongyuan, et al. Evolutionary design of RBF neural network based on multi-species cooperative particles warm optimizer[J]. *Control Theory & Applications*, 2006, 23(2): 251 – 255.)
- [4] SHI Y, EBERHART R C. A modified particle swarm optimizer[C] // *IEEE International Conference of Evolutionary Computation*. Anchorage, Alaska: [s.n.], 1998: 69 – 73.
- [5] CLERC M. The swarm and the queen: towards a deterministic and adaptive particle swarm optimization[C] // *Proceedings of the 1999 Congress on Evolutionary Computation*. Washington, USA: [s.n.], 1999: 1951 – 1957.
- [6] 左兴权, 李士勇. 采用免疫进化算法优化设计径向基函数模糊神经网络控制器[J]. 控制理论与应用, 2004, 21(6): 521 – 525.
(ZUO Xingquan, LI Shiyong. Optimal design of radial basis function fuzzy neural network controller based on immune evolutionary algorithm[J]. *Control Theory & Applications*, 2004, 21(4): 521 – 525.)
- [7] EBERHART R, SHI Y H. Particle swarm optimization: developments, applications and resources[C] // *IEEE International Conference of Evolutionary Computation*. Seoul, South Korea: [s.n.], 2001: 81 – 86.
- [8] 刘金琨. 智能控制[M]. 北京: 电子工业出版社, 2005.
- [9] SOLOWAY D, HALEY P J. Neural generalized predictive control[C] // *Proceedings of the 1996 IEEE International Symposium on Intelligent Control*. Dearborn, MI, USA: [s.n.], 1996: 277 – 282.

作者简介:

- 肖本贤** (1964—), 男, 教授, 博士, 主要研究方向为智能控制, E-mail: xiaobenxian@126.com;
- 王晓伟** (1982—), 男, 硕士研究生, 主要研究方向为智能控制, E-mail: feixiangwei@hotmail.com;
- 朱志国** (1980—), 男, 硕士研究生, 主要研究方向为智能控制, E-mail: tree20000@163.com;
- 刘一福** (1962—), 男, 高级工程师, 主要研究方向为热控自动化, E-mail: dcs2008@ah163.com.

(上接第568页)

作者简介:

- 慕香永** (1971—), 男, 哈尔滨工业大学控制科学与工程系博士研究生, 主要研究方向为负载模拟器的复杂控制技术、机器人控制, E-mail: muxy005@hit.edu.cn;
- 裴润** (1939—), 男, 哈尔滨工业大学控制科学与工程系教

授、博士生导师, 主要研究方向为计算机控制、机器人控制;

刘志林 (1977—), 男, 哈尔滨工业大学控制科学与工程系博士研究生, 主要研究方向为混杂系统、预测控制;

张军 (1972—), 男, 上海航天技术研究院副研究员, 主要研究方向为预测控制、信号处理.