

7-20-2022

Modeling and Simulation of Ultra Supercritical Unit Using A Composite Weighted Human Learning Network

Chuanliang Cheng

1.School of Mechanical and Electrical Engineering and Automation, Shanghai University, Shanghai 200444, China;, chengch1017@163.com

Chen Peng

1.School of Mechanical and Electrical Engineering and Automation, Shanghai University, Shanghai 200444, China;, c.peng@shu.edu.cn

Deliang Zeng

2.School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

Tengfei Zhang

3.College of Automation and College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Invited Papers & Special Columns is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Modeling and Simulation of Ultra Supercritical Unit Using A Composite Weighted Human Learning Network

Abstract

Abstract: Intermediate point temperature is an important parameter in ultra supercritical (USC) unit. However, due to strong nonlinearity, it is difficult to determine the form and coefficients of the corresponding model by using traditional methods. *In order to get a better control effect, a novel composite weighted human learning optimization network (CWHLON) is proposed to tackle the above-mentioned problems. Though the real-time dynamic linear model, the characteristics of the object are accurately simulated.* In the simulation experiment, CWHLON is compared with the traditional recursive least squares and other three meta heuristic methods. The data show that the proposed method improves the model accuracy by 77.93% on average and 78.65% on maximum, effectively improving the identification accuracy.

Keywords

intermediate point temperature, strong nonlinearity, modeling, CWHLON, USC

Recommended Citation

Chuanliang Cheng, Chen Peng, Deliang Zeng, Tengfei Zhang. Modeling and Simulation of Ultra Supercritical Unit Using A Composite Weighted Human Learning Network[J]. Journal of System Simulation, 2022, 34(7): 1430-1438.

基于复合加权人类学习网络的超超临界机组建模与仿真

程传良¹, 彭晨^{1*}, 曾德良², 张腾飞³

(1. 上海大学 机电工程与自动化学院, 上海 200444; 2. 华北电力大学 控制与计算机工程学院, 北京 102206;
3. 南京邮电大学 自动化学院和人工智能学院, 江苏 南京 210023)

摘要: 中间点温度是超超临界 (ultra supercritical, USC) 机组的一个重要参数, 其系统具有强非线性, 常规方法很难对其进行建模。为了解决非线性问题, 并获得良好的建模效果, 提出了一种基于复合加权人类学习优化网络 (composite weighted human learning optimization network, CWHLON) 的建模方法, 以动态线性模型的形式来模拟对象的非线性动态过程。在仿真实验部分, 将CWHLON模型与传统的递推最小二乘法和其他三种元启发式方法得到的模型进行综合比较, 数据显示本文提出的方法在模型精度方面平均提高了77.93%, 最大提高了78.65%, 实现了辨识精度的有效提升。

关键词: 中间点温度; 强非线性; 建模; 复合加权人类学习优化网络; 超超临界机组

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2022)07-1430-09

DOI: 10.16182/j.issn1004731x.joss.22-0259

Modeling and Simulation of Ultra Supercritical Unit Using A Composite Weighted Human Learning Network

Cheng Chuanliang¹, Peng Chen^{1*}, Zeng Deliang², Zhang Tengfei³

(1. School of Mechanical and Electrical Engineering and Automation, Shanghai University, Shanghai 200444, China;
2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;
3. College of Automation and College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Intermediate point temperature is an important parameter in ultra supercritical (USC) unit. However, due to strong nonlinearity, it is difficult to determine the form and coefficients of the corresponding model by using traditional methods. In order to get a better control effect, a novel composite weighted human learning optimization network (CWHLON) is proposed to tackle the above-mentioned problems. Though the real-time dynamic linear model, the characteristics of the object are accurately simulated. In the simulation experiment, CWHLON is compared with the traditional recursive least squares and other three meta heuristic methods. The data show that the proposed method improves the model accuracy by 77.93% on average and 78.65% on maximum, effectively improving the identification accuracy.

Keywords: intermediate point temperature; strong nonlinearity; modeling; CWHLON; USC

引言

在当前的发电系统中, USC 机组以其热效率

高、污染排放少、单机容量大等特点成为发电厂的首选设备^[1-2]。USC(ultra supercritical)火力发电厂主要由锅炉、汽轮机和蒸汽管道组成。其中,

收稿日期: 2022-03-25 修回日期: 2022-04-27

基金项目: 国家自然科学基金(61833011)

第一作者: 程传良(1989-), 男, 博士生, 研究方向为燃煤发电系统建模与优化控制。E-mail: chengch1017@163.com

通讯作者: 彭晨(1972-), 男, 博士, 教授, 研究方向为网络化控制、安全控制、工业炉窑能效优化等。E-mail: c.peng@shu.edu.cn

蒸汽温度将达到600°C以上,热效率高达46%,比传统发电厂高出近10%,比超临界发电厂高出4%,具有显著的节能效果。此外,随着燃料转化率的提高和与CO₂捕集技术的充分结合,CO₂的排放量最多可减少30%,满足了我国对保护环境的要求。与传统发电机组不同,USC机组采用直流锅炉,没有明显的汽水两相区。在高负荷长时间运行情况下,蒸汽温度接近管道蠕变水平,给机组的安全运行带来巨大威胁。因此,蒸汽温度必须控制在允许范围内。中间点温度(分离器出口蒸汽温度)可以快速反应锅炉燃烧的变化,也可以作为控制量来实现过热蒸汽温度的控制。因此,中间点温度的有效控制一直是USC机组中非常关注的问题。

文献[3-5]表明,准确的模型是有效控制方法的基础。在参数辨识方面已存在很多方法,如最小二乘法^[6]、最大似然估计法^[7]、梯度下降法^[8]。这些方法可以在电厂运行点附近获得令人满意的辨识结果。然而,在大多数火电厂中,由于耦合性、非线性和大范围运行的特点,这些方法的性能可能会大幅度降低。因此,应引入更合适的非线性建模方法^[9-10]。人类学习优化(human learning optimization, HLO)算法是一种模仿人类学习行为的元启发式方法^[11]。由于其控制参数少、结构简单、运行时间短、易于实现,越来越多地被研究者们采用。随后通过一系列改进,并与其他各种算法对多维背包问题、CEC(congress on evolutionary computation)标准函数等测试集进行了对比,显示了其在搜索最优值方面更强大的学习能力^[12-14]。与传统的参数辨识方法不同,HLO算法通过逐步进化,建立了更精确的对象的受控自回归积分滑动平均过程模型(controlled auto regression and moving average model, CARIMA)。尽管如此,由于USC机组的强非线性,仍然很难用线性模型来描述其运行过程。为了解决此问题,需要对HLO算法进行扩展。

本文受社会中人们分工协作现象的启发,提

出了一种新的基于聚类、局部识别和模糊推理的复合加权人类学习优化网络建模方法,以逼近中间点温度系统的非线性动态过程。通过CWHLON(composite weighted human learning optimization network)的建模,整个运行范围内的动态信息被合理地划分为几个局部区域,大幅度降低了非线性。然后通过标准HLO算法来辨识具有CARIMA形式的线性函数映射。最后,根据先行变量将局部模型动态组合在一起,以线性模型的形式精确模拟中间点温度的非线性动态过程。

1 问题描述

本文所考虑的对象是功率为1 000 MW USC机组,蒸汽流量为2 980 T/h,额定过热蒸汽压力和温度分别为26.15 MPa和605 °C。其中,蒸汽温度控制系统是一条长传输控制链。如图1所示,给水在水冷壁中蒸发,并在炉子顶部的分离器中与杂质分离。然后,在多级过热器中进一步加热。最后,蒸汽进入汽轮机并驱动其工作。其中,过热器出口的蒸汽温度最高,接近金属的蠕变温度。因此,应严格控制蒸汽温度,尤其是过热蒸汽温度^[15-17]。




图1 USC机组的布局
Fig. 1 Layout of the USC unit

由于一次锅炉没有汽包的缓冲,随着给水和燃料的改变,蒸汽温度会发生明显的变化。而且,随着蒸汽压力的增加,蒸汽温度波动的惯性、时

间常数和延迟时间也相应增加，这给控制系统带来了更困难的挑战。一般来说，驱动汽轮机的过热蒸汽是发电厂最应注意的参数之一。从图 1 可以看出，过热蒸汽的控制变量主要包括过热器的多级喷水系统和锅炉内的工况。如果系统严重依赖喷水减温方式来修正过热蒸汽温度，则需要大量的水，这不仅会进一步加剧燃水比的不平衡，而且会影响锅炉的安全运行。此外，远距离调节过程意味着过热蒸汽不能快速响应锅炉工况的变化。因此，从锅炉燃料、水供应到过热器蒸汽温度调节，很难对这样一个系统进行建模和控制。

中间点温度(分离器出口蒸汽温度)可以快速反映锅炉内部条件的影响。将锅炉和分离器视为一个系统，其中输入为燃料流量和给水流量，输出为中间点温度。然后，在有效控制中间点温度的基础上，结合过热器喷雾流量的微调，很容易达到控制过热蒸汽温度的目的^[18-19]。

2 中间点温度的建模

CWHLON 是一个具有自学习和自组织能力的信息处理网络。该网络通过模糊规则和补偿机制将局部运行信息连接起来，以学习中间点温度的复杂非线性函数映射。本文用它建立多变量非线性系统模型，以捕捉中间点温度的动态特性。

2.1 CWHLON 的框架

考虑下面的多输入多输出的非线性系统：

$$Y(t) = f[Y(t-1), \dots, Y(t-n_y), U(t-d), \dots, U(t-n_u-d), e(t), \dots, e(t-n_e)] + e(t)/\Delta \quad (1)$$

式中： f 为一个光滑非线性函数； $Y(t)$ 和 $U(t)$ 分别为输出量和输入量； n_y 、 n_u 和 n_e 为系统的阶数； $e(t)$ 为零均值白噪声； Δ 为差分算子。一般来说，在发电过程中，由于难以确定非线性模型复杂的结构和系数，几乎不可能用式(1)的数学模型准确表达中间点温度的运行机制。此外，即使得到了满意的非线性模型，基于复杂模型的执行控制器

也可能需要大量的计算，不适合在线应用。这种困难在一定程度上可以通过使用 CWHLON 来解决，因为目标的非线性通过分区得到了大幅度的降低，并且通过一系列的线性模型的动态组合来模拟中间点温度的非线性动态过程，给线上控制过程节约了大量时间。CWHLON 的示意图如图 2 所示，可以看到系统由 5 层组成，即输入层、模糊化层、归一化层、建模层和输出层。

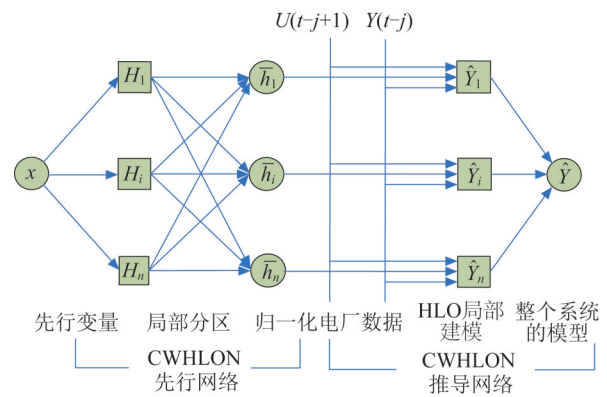


图 2 CWHLON 的示意图
Fig. 2 Schematic diagram of CWHLON

在第一层中，输入 x 代表先行变量。本文将发电量作为先行变量，使整个运行区域划分为 7 个部分：“非常高”、“高”、“中高”、“中”、“中低”、“低”和“非常低”。

第二层是模糊化层，本文提出了一种新的聚类方法，以目标系统的非线性最小化为目的，将其应用于第二层的数据划分中(具体的聚类过程在第 2.2 节中介绍)。每个局部区域的激活权重描述为：① 如果先行变量只属于一个局部区域，则表示该区域的权重为 100%，而其他区域的权重为 0%。② 如果先行变量属于两个局部区域，则这些区域的权重为

$$h_1 = (0 - 1) / (center_2 - center_1) \cdot (x - center_1) + 1 \quad (2)$$

$$h_2 = 1 - h_1 \quad (3)$$

式中： $center_1$ 、 $center_2$ 分别为这两个局部区域的中心点。

值得注意的是，即使全工况的运行过程被划

分为几个区域,仍有局部区域具有相对较高的非线性。在这种情况下,引入了一种补偿机制,利用评价系统和高斯函数对高度非线性的局部区域进行识别和补偿。一般来说,有两种情况需要补偿机制:

1) 强非线性局部区域是独立存在的(如图3(a)所示)。局部模型通过高斯函数由低非线性的相邻模型进行补偿:

$$h_2 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_1 = 1 - h_2 \quad (4)$$

$$h_2 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_3 = 1 - h_2 \quad (5)$$

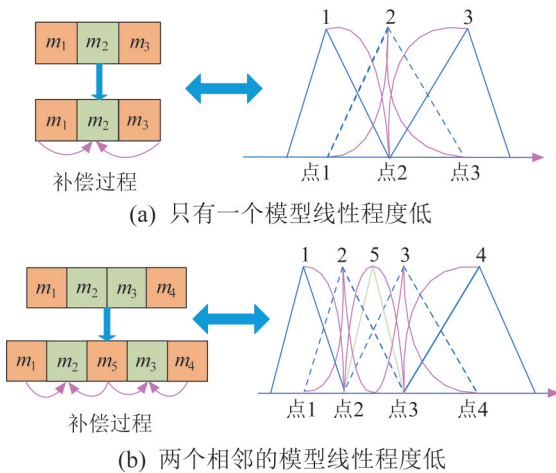


图3 CWHLON 补偿过程示意图

Fig. 3 Schematic diagram of compensation process of CWHLON

2) 具有高非线性的局部区域是相邻存在的(如图3(b)所示)。在这种情况下,会产生一个新的较小的局部区域。一般来说,由于需要识别的数据较少,新区域的非线性程度将低于两个区域。弥补过程由两个新的激活权重来实现:

$$h_2 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_1 = 1 - h_2 \quad (6)$$

$$h_2 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_5 = 1 - h_2 \quad (7)$$

$$h_3 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_5 = 1 - h_3 \quad (8)$$

$$h_3 = e^{-\frac{(x - center_2)^2}{2 \cdot 0.5477^2}}, h_4 = 1 - h_3 \quad (9)$$

然后,所有局部区域的权重在第三层被归一

化为

$$\bar{h}_i = \frac{h_i}{\sum_{i=1}^n h_i} \quad (10)$$

式中: n 为局部区域的总个数; \bar{h} 为归一化后的每个局部区域的权重。值得说明的是,在网络中设计了一个形如 $[\bar{h}_1, \bar{h}_2, \dots, \bar{h}_n]$ 的调度程序,用于记录每个局部区域的激活权重,以便所有局部区域的模型能够以透明的方式更高效地参与建模。

局部区域的线性建模是在第四层中实现的(具体算法见第2.3节),其表现为以下模糊规则:

R_i : 如果先行变量是 i ,那么局部线性模型为

$$A_i(z^{-1})\hat{Y}_i(k) = B_i(z^{-1})U_i(k) + C_i(z^{-1})e_i(k)/\Delta \quad (11)$$

式中: A_i, B_i, C_i 为辨识出的多项式系数矩阵; e_i 为零均值的白噪声; Y_i 和 U_i 分别为输出量和输入量。

然后应用调度程序在第五层的执行解模糊化,将整个系统的输出表示为局部区域输出的加权和:

$$\hat{Y}(t) = \frac{\sum_{i=1}^n \hat{Y}_i(t)h_i(t)}{\sum_{i=1}^n h_i(t)} = \sum_{i=1}^n \hat{Y}_i(t)\bar{h}_i(t) \quad (12)$$

2.2 一个新的聚类分区方法

一个简单的线性模型很难揭示USC机组的内部机理。为了解决这个问题,文献[10]引入了模糊 K 均值聚类的方法,对整个运行区域进行了分区,有效地降低了系统的非线性。本文受此启发,在CWHLON中引入了一种新的聚类分区方法。此方法将进化算法整合到CWHLON中,更有效地降低了系统的非线性。

考虑到先验知识不足,在初始阶段对整个运行范围的动态信息进行了均匀划分。通过计算适应度值(线性程度),找到性能最差的局部区域,然后对相应的端点进行随机调整,旨在以一定的概率增加最差区域及其相邻区域的线性程度。最后,当达到最大进化次数时,算法停止。流程如算法1所示。

算法1 新型聚类方法

输入 电厂运行数据;

局部区域个数, n ;

总进化代数, epoch;

输出 当前进化代数, t ;

新的局部区域;

1. 将整个运行区域平均分成 n 个局部区域;
2. 进入循环, 从 $i=1$ 到 epoch, 执行;
3. 找到非线性程度最高的局部区域, 按从大到小的尺度随机调整其端点;
4. 更新局部区域, 并计算对应的适应度(线性程度);
5. 如果新的局部区域适应度高于原适应度, 则
6. 记录并更新端点;
7. 否则
8. 保持原局部区域端点不变;
9. 小概率调整适应度高的局部区域, 以增加搜索的多样性;
10. 重复执行步骤3, 4, 5, 6, 7, 8, 9;
11. 结束循环。

2.3 CWHLON的局部建模

如图3所示, 第四层中的节点通过HLO算法实现局部线性建模。考虑下面的线性方程:

$$A_i(z^{-1})\hat{Y}_i(k) = B_i(z^{-1})U_i(k) + C_i(z^{-1})e_i(k)/\Delta \quad (13)$$

虽然已有多种传统的辨识方法可进行局部建模, 但由于自身的缺点, 无法准确地进行辨识。HLO算法通过启发式搜索可以连续逼近局部区域的信息, 其搜索过程包括: 随机学习、个体学习和社会学习。

由于缺乏先前的经验, 随机学习在最初的搜索中非常重要。随机学习算子(random learning operator, RLO)表示为

$$x_{ij} = x_{\min,j} + r \cdot (x_{\max,j} - x_{\min,j}) \quad (14)$$

式中: x_{ij} 为第 i 个个体的第 j 个解, r 为 0~1 之间的随机数。

个体学习算子(individual learning operator, ILO)是在掌握一定知识后实现的。个体知识数据库为

$$IKD = [ikd_1, ikd_2, \dots, ikd_N] \quad (15)$$

$$IKD_i = \begin{bmatrix} ikd_{i1} \\ ikd_{i2} \\ \vdots \\ ikd_{iT} \end{bmatrix} = \begin{bmatrix} ik_{i11} & ik_{i12} & \dots & ik_{i1M} \\ ik_{i21} & ik_{i22} & \dots & ik_{i2M} \\ \vdots & \vdots & & \vdots \\ ik_{iT1} & ik_{iT2} & \dots & ik_{iT M} \end{bmatrix} \quad (16)$$

式中: N 为个体的数量; ikd_{ipj} 为第 i 个个体的第 p 个解的第 j 个元素; T 和 M 为预先设定的数。

通过个体搜索, 得到新的解:

$$x_{ij} = ik_{ipj} + I_L \cdot r \cdot (sk_{qj} - ik_{ipj}) \quad (17)$$

式中: I_L 为个体学习因子; 整个学习过程包含两个方面, 一方面是继承先前的知识。另一方面是新的学习行为。其中, 搜索范围根据 $|sk_{qj} - ik_{ipj}|$ 而动态改变, 其中可能存在着更好的解决方案, 因此, 在执行个体学习时, 搜索有效性得到了保证。

社会学习算子(social learning operator, SLO)是在所有个体掌握足够的知识后实施的。社会知识数据库表示为

$$SKD = \begin{bmatrix} skd_1 \\ skd_2 \\ \vdots \\ skd_H \end{bmatrix} = \begin{bmatrix} sk_{11} & sk_{12} & \dots & sk_{1M} \\ sk_{21} & sk_{22} & \dots & sk_{2M} \\ \vdots & \vdots & & \vdots \\ sk_{H1} & sk_{H2} & \dots & sk_{HM} \end{bmatrix} \quad (18)$$

式中: sk_{ij} 为第 i 个个体的第 j 个解; H 为社会知识数据库的大小。

通过社会搜索, 得到新的解:

$$x_{ij} = sk_{pj} + S_L \cdot r \cdot (sk_{qj} - ik_{ipj}) \quad (19)$$

式中: S_L 代表社会学习因子。

每次迭代只执行一个搜索算子, 概率为

$$x_{ij} = \begin{cases} RLO, & 0 \leq r_4 \leq pr \\ ILO, & pr < r_4 \leq pi \\ SLO, & pi < r_4 \leq 1 \end{cases} \quad (20)$$

式中: pr 和 pi 分别为决定执行哪个算子的 2 个参数。

当所有局部区域的模型建立好以后, 在调度程序的安排下, 使得最终的CWHLON线性模型可以准确表达USC机组中间点温度的动态运行信息。算法2描述了CWHLON算法的细节。首先将整个工作区域整齐地划分为几个区域。在每个局

部区域, HLO 算法执行 3 个主要搜索算子, 在随机学习中, 利用新的解空间来保持种群的多样性。在个体学习中, 为了提高学习的效率和有效性, 模拟了人类从知识库中学习的现象。在社会学习中, 通过不同个体的相互学习, 探索出更具前景的解决方案。当达到最大评估次数时, 算法停止。利用已识别的局部模型, 通过分布式信息融合(由调度程序确定的组合)设计出整个系统模型。与其他建模方法不同的是, CWHLON 利用线性模型解决了非线性, 这对于其他控制方法来说也更加方便。

算法2 CWHLON 伪代码

输入 HLO 的参数 pr , pi , T , H , M ; 局部区域个数 n ; 最大进化代数 $epoch$; 当前进化代数 t ;

输出 整个系统的模型 Y ; 选择发电量 x 作为网络的先行变量; 利用新型聚类方法将整个运行区域分成 n 个局部区域, 利用 HLO 算法局部区域线性建模, 当 $t < epoch$ 时, 执行如果 $0 \leq r4 \leq pr$ 那么随机搜索; 如果 $pr < r4 \leq pi$ 那么个体搜索; 更新 IKD; 如果 $pi < r4 \leq 1$ 那么社会搜索更新 SKD; 输出 n 个局部模型, 局部模型融合, 输出整个系统的模型。

3 CWHLON 模型辨识仿真

使用 CWHLON 对 1 000 MW USC 火电厂中间点温度的非线性运行过程进行建模。为了建立 CWHLON 模型, 从电厂运行日志中的大量记录中仔细选择一组 I/O 数据, 这些数据涵盖了对象动态特性的足够变化。如前所述, 通过一种新的聚类方法将这些具有高度非线性的数据划分为多个区域, 以获得更精准的模型。图 4, 5 分别展示了整体非线性程度和中心点的变化情况。值得说明的是, 局部模型辨识过程是线下完成的。在实际操作中, 需要做的是设计一个调度程序, 将所有线性模型结合各自权重相加, 得到整个运行范围的

动态线性模型。




图4 新型聚类方法的非线性度的变化趋势
Fig. 4 Changing trend of nonlinear degree by using the new clustering method




图5 新型聚类方法的中心点的变化趋势
Fig. 5 Changing trend of center points by using the new clustering method

3.1 CWHLON 在局部区域的辨识仿真

选取发电量作为先行变量。将全工况运行范围划分为 7 个区域: “非常高”、“高”、“中”、“中低”、“低”和“非常低”。利用标准 HLO 算法对局部地区的中间点温度进行建模。定义积分绝对误差 (integral absolute error, IAE)^[20] 来评价模型性能:

$$IAE = \sum_{l=1}^L (\hat{y}_l - y_l) \quad (21)$$

式中: \hat{y}_l 为模型输出, y_l 为实际电厂输出; L 为数据总个数。为了进行比较, 还采用粒子群优化 (particle swarm optimization, PSO) 算法^[21]、遗传算法 (genetic algorithm, GA)^[22]、果蝇优化算法 (fruit fly optimization algorithm, FOA)^[23] 和递归最小二乘 (recursive least squares, RLS) 算法进行建模并进行比较, 它们采用了相同的最大函数计算次数和推荐参

数值。表1列出了几种方法的IAE，每种方法在每个局部区域运行了5次。可以看出，元启发式算法明显优于RLS算法。因为这4种元启发式算法是基于RLS算法进行的更精确的搜索，这意味着得到的模型更接近局部地区的动态过程。在元启发式算法中，HLO算法在所有局部区域都优于其他算法，最大改善率为55.79%。这是因为在PSO算法中，搜索机制是利用当前位置、全局极值和个体极值3个信息，确定粒子下一步迭代位置。这导致它容易产生早熟收敛(尤其是在处理复杂的多峰搜索问题中)，且局部寻优能力较差等。而GA对初始种群的选择有一定的依赖性，这需要工作人员丰富的经验。而且GA没有能够及时利用网络的反馈信息，故算法的搜索效

率和速度无法达到理想要求。果蝇算法的搜索机制是当前最优解引导着果蝇种群的搜索方向，配合嗅觉操作的全局随机搜索，可快速寻找到较好的解。但是，当果蝇群体的位置范围很大而单次飞行范围较小时，单次飞行的变化对解的影响很小，使得FOA面对复杂问题时容易早熟。而对于HLO算法，算法引入了随机学习、个人学习、社会学习算子，弥补了以上3种算法的缺点，既通过随机学习算子保证了搜索的宽度，又通过个人学习、社会学习算子保证了算法的精度和速度。此外，HLO算法引入了不同个体竞争机制，促进了所有个体的发展，最大限度地提高了找到最优模型的可能性。

表1 局部区域不同模型IAE对比
Table 1 Comparison of IAE between different models in local regions

算法		区域						
		1	2	3	4	5	6	7
HLO	平均值	2 115.12	9 796.88	8 626.31	2 844.95	3 372.69	15 180.81	9 456.23
	最优值	2 092.03	9 652.79	8 227.71	2 754.01	3 299.48	14 820.49	8 901.65
GA	平均值	2 183.91	11 151.97	10 507.71	2 952.17	3 507.09	17 059.41	10 104.06
	最优值	2 168.95	10 160.47	9 319.92	2 831.99	3 420.46	15 506.13	9 976.25
	与HLO的对比/%	-3.54	-4.99	-11.71	-2.75	-3.53	-6.66	-10.44
FOA	平均值	2 159.90	10 563.81	10 028.80	3 080.06	3 483.02	16 109.71	9 858.62
	最优值	2 132.61	10 059.84	8 595.51	2 929.17	3 401.07	15 507.88	9 559.49
	与HLO的对比/%	-1.90	-4.04	-4.27	-5.97	-2.98	-6.68	-6.39
PSO	平均值	2 210.42	13 244.72	13 356.23	3 447.11	3 623.23	18 425.82	10 145.52
	最优值	2 159.55	13 169.40	12 265.53	3 438.49	3 612.51	17 318.87	9 995.49
	与HLO的对比/%	-3.12	-26.7	-32.92	-19.90	-8.66	-24.28	-10.63
RLS	平均/最优	2 212.00	13 302.77	17 131.33	3 916.18	4 292.47	20 560.36	10 306.90
	与HLO的对比/%	-5.42	-27.43	-51.97	-29.67	-23.13	-55.79	-13.66

3.2 CWHLON在全工况范围的辨识仿真

在第3.1节，中间点温度的局部区域采用线性模型的形式来表示。在实际应用中，局部线性模型不能反映全厂范围内的运行特性。随着调度程序的设计和应用，这些局部区域将与各自的权重进行组合，从而得到更加精准的全工况范围的线性模型。图6显示了CWHLON模型在全工况范围内的模拟情况。表2是常见几种方法的对比情况。可以看出，在整个操作过程中CWHLON的改善率可达78.65%，这不仅

是因为HLO算法的性能优于其他4种方法，而且通过局部线性模型的合理组合，以动态线性模型的形式表达了中间点温度的非线性动态过程。

此外，使用一组不同的操作数据来验证识别模型的准确性，CWHLON模型输出曲线和实际输出曲线如图7所示。表3列出了获得的模型的比较，其中CWHLON的IAE是最小的，因为它具有很强的识别性，这意味着CWHLON模型能够充分反映中间点温度的实际运行过程。




图6 全工况运行范围内系统输出和CWHLON模型的对比

Fig. 6 Comparison between the USC unit and the CWHLON system under the plant-wide range

表2 全工况运行范围内系统输出和CWHLON模型的IAE对比

Table 2 Comparison of IAE between the USC unit and the CWHLON system under the plant-wide range

算法	平均值	最优值
CWHLON	28 589.04	28 589.04
HLO	127 332.19	126 686.65
GA	128 905.70	128 187.74
FOA	127 796.35	126 798.73
PSO	129 830.12	127 881.61
RLS	133 919.77	133 919.77




图7 系统输出和CWHLON模型的对比(测试)

Fig. 7 Comparison between the USC unit and the CWHLON (testing)

表3 系统输出和CWHLON模型的IAE对比(测试)

Table 3 Comparison of IAE between the USC unit and the CWHLON (testing)

算法	平均值	最优值
CWHLON	7 961.99	7 961.99
HLO	15 482.03	15 360.01
GA	15 666.85	15 391.30
FOA	15 769.38	15 447.75
PSO	16 232.63	15 666.78
RLS	17 975.07	17 975.07

4 结论

本文提出了CWHLON对1 000 MW USC机组的中间点温度进行建模。在CWHLON中,充分考虑了历史数据的统计特性,利用一种新的聚类分区方法将全厂运行区域划分为7个局部区域,在此基础上通过HLO算法辨识出相应的线性CARIMA模型。然后设计了一个调度程序,来确定选择被激活的局部模型,并实时的组合在一起来模拟整个运行区域的非线性动态过程。仿真结果表明,与HLO, GA, POS, FOA和RLS相比,该策略更适用于模拟所研究系统的动态特性。如何利用所得到的CWHLON模型设计出有效的优化控制器是需要进一步研究的工作。

参考文献:

- [1] 王建录, 张晓东, 侯明军. 超超临界二次再热机组汽轮机应用现状与展望[J]. 热力发电, 2017, 46(8): 11-15.
Wang Jianlu, Zhang Xiaodong, Hou Mingjun. Development and Expectation of Application of Ultra-supercritical Double-reheat Steam Turbines. Thermal Power Generation, 2017, 46(8): 11-15.
- [2] 孙宇贞, 唐毅伟, 李帅. 基于改进粒子群算法的超超临界燃煤机组负荷系统建模[J]. 系统仿真学报, 2021, 33(4): 875-882.
Sun Yuzhen, Tang Yiwei, Li Shuai. Load System Modeling of Ultra-Supercritical Coal-Fired Power Unit Based on Improved Particle Swarm Optimization [J]. Journal of System Simulation, 2021, 33(4): 875-882.
- [3] 孙燕平, 常永亮, 李振林. 基于SIS的火电机组热工对象数学模型辨识[J]. 仪器仪表用户, 2022, 29(1): 97-99.
Sun Yanping, Chang Yongliang, Li Zhenlin. Identification of Mathematical Model of Thermal Power Plant's Thermal Object Based on SIS[J]. Instrumentation, 2022, 29(1): 97-99.
- [4] 陈琛, 潘蕾, Kwang Y Lee. 超超临界机组机炉协调系统的min-max模糊模型预测跟踪控制[J]. 东南大学学报: 英文版, 2021, 37(1): 42-51.
Chen Chen, Pan Lei, Kwang Y Lee. Min-max Fuzzy Model Predictive Tracking Control of Boiler-Turbine System for Ultra-Supercritical Units[J]. Journal of Southeast University: English Edition, 2021, 37(1): 42-51.
- [5] 闫妹. 超超临界机组非线性控制模型研究[D]. 北京: 华北

- 电力大学, 2013.
- Yan Shu. A Non-linear Control Model of Ultra-supercritical Unit[D]. Beijing: North China Electric Power University, 2013.
- [6] 熊小伏, 陈康, 郑伟, 等. 基于最小二乘法的光伏逆变器模型辨识[J]. 电力系统保护与控制, 2012, 40(22): 52-57.
Xiong Xiaofu, Chen Kang, Zheng Wei, et al. Photovoltaic Inverter Model Identification Based on Least Squares Method[J]. Power System Protection and Control, 2012, 40(22): 52-57.
- [7] 吴刘仓, 马婷, 戴琳. 基于StN分布下联合位置与尺度模型的极大似然估计[J]. 应用数学, 2013, 26(3):671-676.
Wu Liucang, Ma Ting, Dai Lin. Maximum Likelihood Estimation for Joint Location and Scale Models of the Skew-t-normal Distribution[J]. Applied Mathematics, 2013, 26(3): 671-676.
- [8] 李太福,熊隽迪. 基于梯度下降法的自适应模糊控制系统研究[J]. 系统仿真学报, 2007, 19(6): 1265-1268.
Li Taifu, Xiong Jundi. Time Series Modeling Method based on Boosting Gradient Descent Theory[J]. Journal of System Simulation, 2007, 19(6): 1265-1268.
- [9] 梁庆姣, 刘吉臻, 薛彦广, 等. 超超临界直流炉核心模型的建立与仿真分析[J]. 计算机仿真, 2012, 29(3): 338-343.
Liang Qingjiao, Liu Jizhen, Xue Yanguang, et al. Establishment and Simulation Analysis of Core Model for Ultra-supercritical Once-through boiler[J]. Computer Simulation, 2012, 29(3): 338-343.
- [10] Cheng Chuanliang, Peng Chen, Zhang Tengfei. Fuzzy K-means Cluster Based Generalized Predictive Control of Ultra Supercritical Power Plant[J]. IEEE Transactions on Industrial Informatics (S1941-0050), 2021, 17(7): 4575-4583.
- [11] Wang L, Ni H, Yang. A Simple Human Learning Optimization Algorithm [J]. Communications in Computer and Information Science (S1865-0937), 2014, 462: 56-65.
- [12] Wang L, Yang R X. A Human Learning Optimization Algorithm and Its Application to Multi-dimensional Knapsack Problems[J]. Applied Soft Computing (S2666-2221), 2015, 34: 736-743.
- [13] Cao J, Yan Z, Xu X, et al. Optimal Power Flow Calculation in AC/DC Hybrid Power System Based on Adaptive Simplified Human Learning Optimization Algorithm [J]. Journal of Modern Power Systems & Clean Energy (S2196-5625), 2016, 4(4): 690-701.
- [14] Wang L, An L, Pi J, et al. A Diverse Human Learning Optimization Algorithm[J]. Journal of Global Optimization (S1573-2916), 2017, 67(1/2): 1-41.
- [15] 杨硕, 张悦. 基于改进广义预测控制的过热蒸汽温度优化[J]. 电力科学与工程, 2021, 37(12):47-56.
Yang Shuo, Zhang Yue. Optimal Temperature Control of Superheated Steam in Boiler Based on Improved GPC[J]. Electric Power Science and Engineering, 2021, 37(12): 47-56.
- [16] 唐飞, 董斌, 赵敏. 超超临界机组在我国的发展及应用[J]. 电力建设, 2010, 3(1): 80-82.
Tang Fei, Dong Bin, Zhao Min. USC Unit Development and Application in China[J]. Electric Power Construction, 2010, 3(1): 80-82.
- [17] 杨敏, 牟文彪, 陆陆, 等. 一种RB工况下超临界机组主蒸汽温度控制策略[J]. 电力科学与工程, 2020, 36(7): 61-67.
Yang Min, Mou Wenbiao, Lu Lu, et al. A Main Steam Temperature Control Strategy of Supercritical Unit Under RB Condition[J]. Power science and Engineering, 2020, 36(7): 61-67.
- [18] 梁伟平, 鲍鹏凯. 基于PCA-RF直流炉中间点温度预测控制[J]. 仪器仪表用户, 2021, 28(7): 86-89.
Liang Weiping, Bao Pengkai. Based on PCA-RF DC Furnace Temperature Prediction Control[J]. Instrumentation, 2021, 28(7): 86-89.
- [19] 梁伟平, 王文成, 张旭. 基于中间点温度前馈的主汽温模糊PID控制系统[J]. 电力科学与工程, 2019, 35(1): 71-77.
Liang Weiping, Wang Wencheng, Zhang Xu. Fuzzy-PID Control System of Main Steam Temperature Based on Intermediate Point Temperature Feedforward[J]. Electric Power Science and Engineering, 2019, 35(1): 71-77.
- [20] 杨启文, 阳外玲, 薛云灿, 等. 基于Maclaurin展开的时间绝对误差积分次优时滞系统设计[J]. 控制理论与应用, 2011, 28(12): 1831-1836.
Yang Qiwen, Yang Wailing, Xue Yuncan, et al. Design of Integral Time Absolute Error Suboptimal Time-Delay System Based on Maclaurin Expansion[J]. Control Theory and Application, 2011, 28(12): 1831-1836.
- [21] Vb A, Ag A, Mr B, et al. Identification of Fractional Water Transport Model With Caputo Derivatives Using Particle Swarm Optimization Algorithm[J]. Applied Mathematics and Computation (S0096-3003), 2021, 390(1): 125665.
- [22] Hu W K, Fang Y J. Multimodel Parameters Identification for Main Steam Temperature of Ultra-Supercritical Units Using an Improved Genetic Algorithm[J]. Journal of Energy Engineering (S0733-9402), 2013, 139: 290-298.
- [23] Zheng T, Liu J, Luo W, et al. Structural Damage Identification Using Cloud Model Based Fruit Fly Optimization Algorithm[J]. Structural Engineering and Mechanics (S1225-4568), 2018, 67(3): 245-254.