

DOI: 10.19666/j.rlfed.202305088

基于双深度输入凸神经网络多模型的 中间点过热度预测控制

钟信¹, 冯磊华¹, 何金奇², 杨锋³

(1.长沙理工大学能源与动力工程学院, 湖南 长沙 410114;

2.陕西高业能源科技有限公司, 陕西 西安 710061; 3.华自科技股份有限公司, 湖南 长沙 410006)

[摘要] 新能源大量并网, 超临界火电机组参与调峰容易造成中间点过热度较大波动, 从而导致过热蒸汽超温等问题。为较好控制中间点过热度达到稳定, 提出了一种基于双深度输入凸神经网络多模型 (muti-DDICNN model) 的中间点过热度预测方法, 分别训练了不同预测步长下子模型, 构建了中间点过热度状态预测网络 (SPNN) 和误差预测网络 (EPNN)。利用此预测网络凸性质, 设计了一种基于双深度输入凸神经网络多模型预测控制器 (DDICNN-MPC), 将控制问题转化为凸优化问题, 求取控制矩阵对目标函数的雅可比矩阵, 采用梯度下降法计算控制矩阵最优解。仿真结果表明, DDICNN-MPC 能快速平稳地跟踪中间点过热度设定值, 且稳态误差较小, 具有较好的调节能力。

[关键词] 中间点过热度; 输入凸神经网络; 模型预测控制; 梯度下降法; 凸优化

[引用本文格式] 钟信, 冯磊华, 何金奇, 等. 基于双深度输入凸神经网络多模型的中间点过热度预测控制[J]. 热力发电, 2024, 53(1): 107-114. ZHONG Xin, FENG Leihua, HE Jinqi, et al. Intermediate point superheat predictive control based on double-depth input convex neural network with multi-model[J]. Thermal Power Generation, 2024, 53(1): 107-114.

Intermediate point superheat predictive control based on double-depth input convex neural network with multi-model

ZHONG Xin¹, FENG Leihua¹, HE Jinqi², YANG Feng³

(1.School of Energy and Power Engineering, Changsha University of Science and Technology, Changsha 410114, China; 2.Shaanxi Gaoye Energy Technology Co., Ltd., Xi'an 710061, China; 3. HNAC Technology Co., Ltd., Changsha 410006, China)

Abstract: As a large number of new energy is connected to the grid, the participation of supercritical thermal power units in peak regulation tends to cause the superheat of intermediate points to fluctuate greatly, resulting in superheated steam over temperature and other problems. In order to better control the intermediate point superheat to achieve stability, a prediction method of intermediate point superheat based on double-depth input convex neural network multi-model (muti-DDICNN model) was proposed. Sub-models with different prediction step sizes were trained respectively, and the intermediate point superheat state prediction network (SPNN) and error prediction network (EPNN) were constructed. Based on the convex property of prediction network, a multi-model predictive controller (DDICNN-MPC) based on convex neural network with double-depth input is designed. The control problem is transformed into a convex optimization problem, the Jacobian matrix of control matrix to objective function is obtained, and the optimal solution of control matrix is calculated by gradient descent method. The simulation results show that, the DDICNN-MPC can track the intermediate point superheat setting quickly and stably, and the steady-state error is small, so it has good adjustment ability.

Key words: intermediate point superheat; input convex neural network; model predictive control; gradient descent algorithm; convex optimization

收稿日期: 2023-05-15

基金项目: 湖南省自然科学基金项目 (2018JJ3552)

Supported by: Natural Science Foundation of Hunan Province (2018JJ3552)

第一作者简介: 钟信 (2000), 男, 硕士研究生, 主要研究方向为热工过程控制建模与优化控制, zx232323zx@163.com。

通信作者简介: 冯磊华 (1980), 女, 博士, 副教授, 主要研究方向为热工过程建模与优化控制, fengleihua80@126.com。

21 世纪以来,在改善全球气候变化和满足经济发展的能源需求下,我国在 2020 年提出“双碳”目标,节能减排也在全球范围受到更加广泛关注^[1-3]。太阳能、风能等可再生能源成为实现节能减排最有效的途径之一,但风力发电出力的随机波动性、光伏发电的间歇性仍是其根本性缺陷。现有的大型火电厂被视为间歇可再生能源的重要补充。提高火电机组的灵活性,特别是效率更高、污染更少的超临界机组,对短、中期增加利用可再生能源至关重要。在超临界机组大规模调峰背景下,维持机组重要运行参数的稳定成为亟待解决的问题。中间点过热度作为超临界机组最重要的运行参数之一,直接影响到锅炉过热蒸汽、水冷壁和过热器金属温度,控制其稳定至关重要^[4-5]。

有关学者在超临界机组动态特性建模与模型预测控制方面做了大量研究。Fan 等人^[6-7]根据热力学原理建立超临界机组动力学模型结构,通过改进免疫遗传算法辨识得到不同载荷范围下参数集,所得模型有较好的精度和动态性能。刘萌等^[8]采用一种多策略分区粒子群算法优化 PID 控制器参数,提高了标准粒子群算法的寻优精度和收敛速度。李炳楠等^[9]在机组状态子空间模型上分别采用模型预测控制和常规 PI 解耦控制算法,证明了模型预测控制(MPC)算法在机组协调控制中的优越性。马增辉等^[10]运用间隙度量理论建立主蒸汽温度多模型集,并引入 Smith 预估控制策略,实现主蒸汽温度系统不同工况下的自适应控制。Wang 等人^[11]建立了三输入三输出分段动态矩阵控制的阶跃响应模型,设计了一种双层多模型预测控制器,仿真验证了其控制效果。郭嘉曦等^[12]采用迁移学习理论建立了主蒸汽温度数字孪生模型,仿真验证该模型在预测控制下的控制品质和鲁棒性。目前,对于非线性系统控制对象的模型预测控制还存在 2 方面问题:1) 针对非线性对象建模精度不够、导致控制过程中模型失配,影响控制品质;2) 非线性对象的预测控制算法计算量大,难以采用迅速有序的算法快速找到全局最优解。

Amos 等人^[13]在 2017 年提出的输入凸神经网络(input convex neural network, ICNN)能以非线性凸函数形式参数化描述输出与输入特征之间的关系。与一般神经网络相比,ICNN 可以有效避免利用非凸边界约束训练神经网络导致的模型收敛困难或出现局部最优问题^[14-15]。由于 ICNN 的超参边界凸性质,基于 ICNN 建模的对象能够通过快速

梯度决策算法求取全局最优解^[16],使得基于神经网络的预测控制器应用在高阶对象的快速控制成为可能。目前,国内外对于输入凸神经网络相关研究文献相对较少,在火力发电控制方面,Zhu 等人^[17]在 2022 年首次引入输入凸神经网络对超超临界 1 000 MW 汽轮机组的动力学进行建模,并提出了一种新的非线性模型预测控制方法。仿真研究结果表明,该方法能够同时保证模型预测精度和提高机组发电控制灵活性。

本文提出了一种基于双深度输入凸神经网络多模型(multi-DDICNN model)的中间点过热度预测方法,引入 ICNN 来建立超临界 660 MW 机组锅炉中间点过热度预测模型,在不丢失非线性的前提下,建立中间点过热度凸模型,并设计了基于双深度输入凸神经网络多模型预测控制器(DDICNN-MPC),采用反向传播算法求解目标函数对控制变量的雅可比矩阵,通过梯度下降实现了中间点过热度快速预测控制。

1 输入凸神经网络

用一般函数关系来描述 ICNN 有:

$$y = f(x) \quad (1)$$

式中: x 为输入矩阵; y 为输出矩阵。

具有 L 层隐藏层数的 ICNN 的结构如图 1 所示。与 BP 神经网络相比,其凸性主要取决于权值和激活函数,当网络激活函数均为非递减凸函数、且权值为非负时,可保证其凸性^[18-19]。因此,可以通过在训练时将前向层权值 W_i^z 限制为非负,并选择 LeakyRelu 函数作为激活函数来获得 ICNN,由于将前向层权值限制为非负,网络的表示能力可能会下降。为了保证 ICNN 凸性的同时提高预测网络的表示能力,ICNN 添加了直接连接输入层和各隐藏层的“直通”层,其权重为 W_i^x 。其中, z_i 为神经网络隐藏层^[20]。

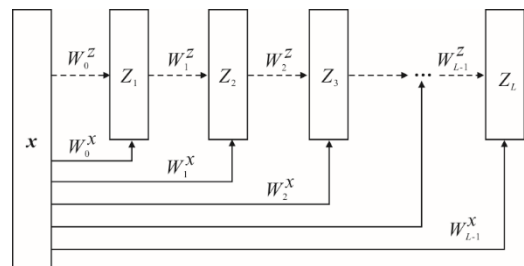


图 1 输入凸神经网络结构

Fig.1 Architecture of an input convex neural network

ICNN 前向传播数学表达式如式(2)所示, φ_i 为第 i 层神经元激活函数, b_i 为第 i 层偏置系数:

$$z_{i+1} = \varphi_i(W_i^z z_i + W_i^x x + b_i) \quad (2)$$

式中: $i=1, 2, 3, \dots, L-1$ 。

当最后一层隐藏层线性节点数与输出层参数数量相同时有:

$$y = z_L \quad (3)$$

2 双深度输入凸神经网络中间点过热度预测模型

单深度的输入凸神经网络预测模型在预测控制过程中由于被控对象输出变化, 可能造成模型失配、影响控制品质等问题。因此, 本文中间点过热度预测模型采用包括中间点过热度状态预测网络 (SPNN)、误差预测网络 (EPNN) 的“双深度”预测模型, 在控制范围内及时预测并矫正模型误差, 能够保证模型精度、改善预测控制品质, 具体实现方法如下。

超临界 660 MW 机组直流锅炉结构如图 2 所示。汽水分离器出口处过饱和蒸汽的过热度即为中间点过热度。

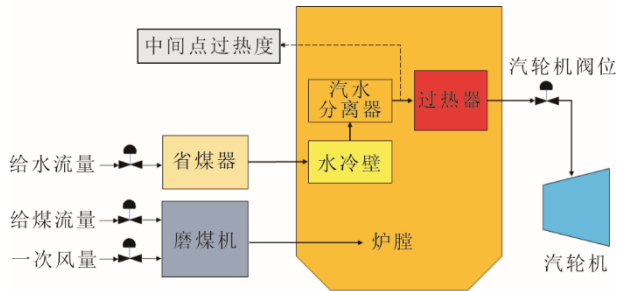


图 2 超临界 660 MW 机组直流锅炉结构

Fig.2 Architecture of the 660 MW boiler-turbine unit

2.1 输入变量选取

给水流量、给煤流量、汽轮机阀位是超临界 660 MW 机组直流锅炉 3 个最重要的控制变量。机组实际运行主要通过协调 3 个变量间的关系来响应负荷指令、控制中间点过热度的稳定。中间点过热度直接取决于中间点温度和分离器出口处蒸汽压力, 而这二者主要受过热段前锅炉汽水侧和锅炉烟气侧换热情况影响。汽水测工质、烟气侧燃料燃烧情况除了受给水流量、给煤流量、汽轮机阀位控制之外, 一次风量和一次风温同样影响锅炉实际入炉煤量和炉内燃烧条件。因此, 中间点过热度预测模型选取给水流量、给煤流量、汽轮机阀位、一次风量、一次风温等 5 个变量作为模型的输入变量^[21]。

将 5 个输入变量组合成向量 $u(k)$ 有:

$$u(k) = [u_B(k), D_{fw}(k), \mu_i(k), q_{m,air}(k), T_{m,air}(k)] \quad (4)$$

将输出变量定义为 $y(k)$ 有:

$$y(k) = [T_m(k)] \quad (5)$$

式中: k 为当前采样时刻; u_B 为给煤机给煤量, t/h; D_{fw} 为锅炉给水流量, t/h; $\mu_i(k)$ 为汽轮机综合阀位, %; $q_{m,air}$ 为一次风流量, t/h; $T_{m,air}(k)$ 为中间点过热度, $^{\circ}\text{C}$ 。

2.2 状态预测网络

基于单步神经网络模型的预测网络会导致模型复用和误差累积, 并且模型反复使用比直接预测未来时刻的计算量和耗时更大, 这些因素可能导致模型预测不准确, 控制质量不高。为解决这一问题, 本研究的中间点过热度 SPNN 采用一种多模型预测方法。在这种建模方法中, 预测范围内的每个采样瞬间都使用独立的子模型, 子模型的数量 N 由 MPC 控制器的预测范围和采样时间间隔确定。多模型预测网络子模型输出可表示为:

$$\hat{y}(k+1) = f_1(u(k), x_p(k)) + e(k+1) \quad (6)$$

$$\hat{y}(k+2) = f_2(u(k+1), u(k), x_p(k)) + e(k+2) \quad (7)$$

$$\hat{y}(k+p) = f_p(u(k+p-1), u(k+p-2), \dots, u(k), x_p(k)) + e(k+p) \quad (8)$$

式中: k 为当前采样瞬间; f_p 为 $k+p$ 时刻的预测子模型; $e(k+p)$ 为 $k+p$ 时刻的子模型和实际对象误差的估计; $x_p(k)$ 为系统过去状态向量, 将其定义为:

$$x_p(k) = [u(k-1), \dots, u(k-n_B), y(k), y(k-1), \dots, y(k-n_A)] \quad (9)$$

式中: n_A 为过去输出变量深度; n_B 则为过去输入变量深度。将 $u(k+p-1), u(k+p-2), \dots, u(k)$ 组合成系统未来输入向量 $x_f(k+p)$ 得:

$$x_f(k+p) = [u(k+p-1), u(k+p-2), \dots, u(k)] \quad (10)$$

因此, 在 k 采样瞬间预测 $k+p$ 时刻的中间点过热度状态预测子模型为:

$$y(k+p) = f_p(x_f(k+p), x_p(k)) \quad (11)$$

2.3 误差预测网络

由于每个采样瞬间都使用了不同的子模型 f_p , 对于每个子模型的输出, 都应该使用独立的误差估计 $e(k+p)$ 。它们被计算为当前采样瞬间的测量过程输出信号 $y(k)$ 与连续子模型输出之间的差异, 可以得到:

$$e(k+p) = y(k) - f_p(x_f(k+p), x_{p,e}(k+p)) \quad (12)$$

为了得到 k 时刻 (当前采样时刻) 子模型输出,

将系统过去状态向量 $\mathbf{x}_p(k)$ 和 $\mathbf{x}_f(k+p)$ 向后移动 p 个步长得到误差预测网络连续子模型的输入 $\mathbf{x}_{p,e}(k+p)$ 和 $\mathbf{x}_{f,e}(k+p)$, 其表达式分别为:

$$\mathbf{x}_{p,e}(k) = [u(k-1-p), \dots, u(k-n_B-p), y(k-p), \dots, y(k-n_A-p)] \quad (13)$$

$$\mathbf{x}_{f,e}(k+p) = [u(k-1), u(k-2), \dots, u(k-p)] \quad (14)$$

将 EPNN 子模型输入 $\mathbf{x}_{p,e}(k+p)$ 和 $\mathbf{x}_{f,e}(k+p)$ 合并为一个向量 $\mathbf{x}_e(k+p)$ 为:

$$\mathbf{x}_e(k+p) = [\mathbf{x}_{f,e}(k+p), \mathbf{x}_{p,e}(k+p)] \quad (15)$$

误差预测网络 EPNN 输出 $e(k+p)$ 可表示为:

$$e(k+p) = y(k) - f_p(\mathbf{x}_e(k+p)) \quad (16)$$

基于双深度输入凸神经网络多模型中间点过热度预测模型结构如图 3 所示, 该模型包括 SPNN 和 EPNN。SPNN 用来预测中间点过热度状态, EPNN 用来估算中间点过热度子模型与实际对象之间的误差。

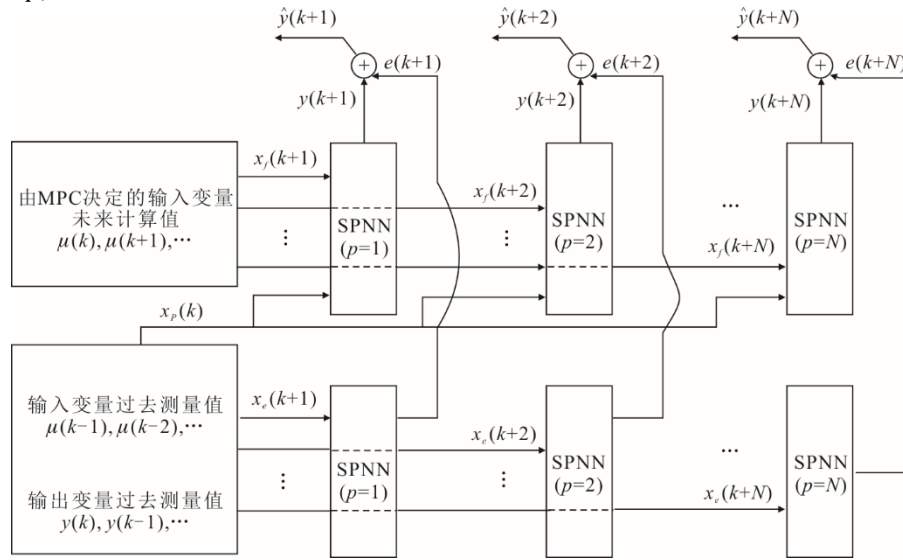


图 3 双深度输入凸神经网络多模型预测模型
Fig.3 The multi-DDICNN model

2.4 ICNN 子模型训练

在某超临界 660 MW 机组实际运行过程采集数据, 数据涵盖机组从 270 MW 到 660 MW 变负荷工况范围内各参数变化情况, 采样时间间隔为 3 s。采集数据包括给水流量、给煤量、汽轮机综合阀位、一次风量、一次风温和中间点过热度等各参数, 共 28 800 组。为降低数据噪声对预测样本的影响, 对各参数设置 4 个采样点并取平均值。选取数据的 80% 作为训练集, 20% 作为验证集, MPC 控制器预测范围为 30 s。需要训练子模型数量 $N=10$, 确定过去输出变量深度 $n_A=1$, 过去输入变量深度 $n_B=2$, 选择 Adam 作为训练神经网络的优化器, 为减小数据离群值对训练结果的影响, 选择 Min-Max 归一化算法对数据预处理, 损失计算为模型预测值和过热度真实值的均方根误差 (δ_{RMSE}), 确定模型最优隐藏层层数为 2, 最佳隐藏层节点数为 4, 迭代次数设置为 1 000 次, 训练 10 个 ICNN 子模型。所得子模型验证集输出值与实际输出值比较如图 4 所示。

为对比 ICNN 子模型与 BP 神经网络 (BPNN) 子模型、多元线性回归 (MLR) 子模型预测效果, 用

相同数据分别训练 10 个 BPNN、MLR 子模型, 训练结果对比见表 1。当 $p=1$ 时, MLR、BPNN、ICNN 子模型验证集损失分别为 1.03×10^{-2} 、 7.91×10^{-3} 、 7.91×10^{-3} ; 当 $p=10$ 时, MLR、BPNN、ICNN 子模型验证集损失分别为 5.91×10^{-1} 、 3.85×10^{-1} 、 3.45×10^{-1} 。且 MLR 验证集及训练集损失均大于 BPNN、ICNN, 3 种子模型预测误差由大到小依次为 MLR、BPNN、ICNN, 反映了 ICNN 具有较好的非线性拟合能力, 中间点过热度 ICNN 子模型相比 BPNN 子模型、MLR 子模型更加合理, 具有更高的拟合精度。

3 基于双深度输入凸神经网络的中间点过热度预测控制

3.1 目标函数设计

为研究基于所建双深度输入凸神经网络中间点过热度预测模型在预测控制算法下的控制效果, 设置 MPC 控制器的预测范围和控制范围都为 30 s, 子模型数量 $N=10$, 控制器的目标是控制 10 个输入向量 $\mathbf{u}(k)$ 使中间点过热度达到设定值, 选取控制目标函数 J 为:

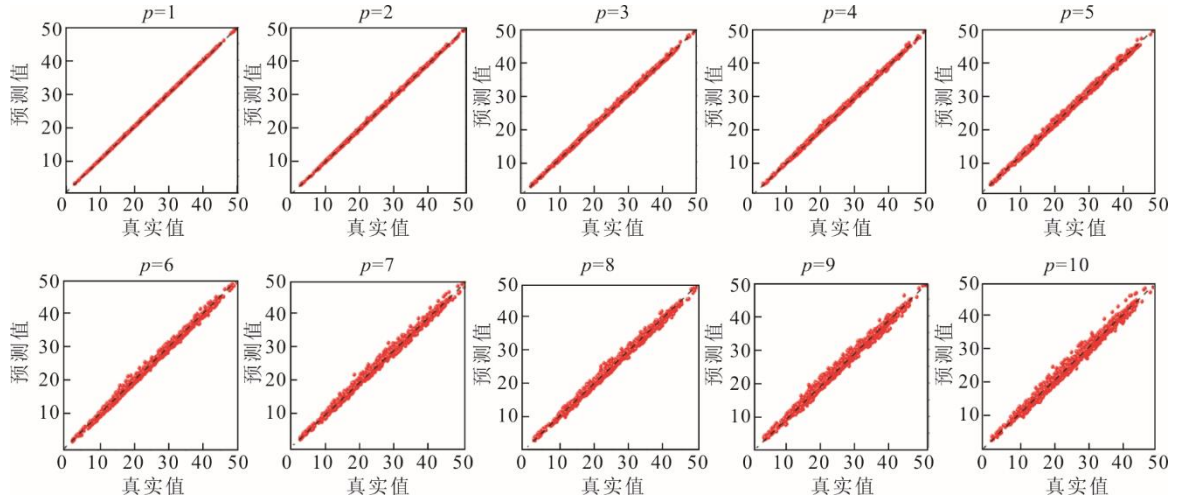


图 4 ICNN 子模型验证集输出与实际值对比 ($p=1, 2, \dots, 10$)

Fig.4 Comparison between output values of the ICNN sub-model verification set and the actual values ($p=1, 2, \dots, 10$)

表 1 不同子模型训练集和验证集损失

Tab.1 The losses of different sub-model training sets and validation sets

p	输入参数	训练集损失			验证集损失		
		MLR	BPNN	ICNN	MLR	BPNN	ICNN
1	17	1.10×10^{-2}	4.41×10^{-2}	9.30×10^{-2}	1.03×10^{-2}	7.91×10^{-2}	7.91×10^{-2}
2	22	3.75×10^{-2}	2.74×10^{-2}	1.56×10^{-2}	3.74×10^{-2}	2.17×10^{-2}	1.11×10^{-2}
3	27	5.57×10^{-2}	3.27×10^{-2}	1.10×10^{-1}	1.10×10^{-1}	4.54×10^{-2}	3.22×10^{-2}
4	32	1.05×10^{-1}	5.29×10^{-2}	5.82×10^{-2}	1.09×10^{-1}	4.26×10^{-2}	5.31×10^{-2}
5	37	1.56×10^{-1}	1.16×10^{-1}	1.38×10^{-1}	1.82×10^{-1}	1.03×10^{-1}	9.33×10^{-2}
6	42	3.45×10^{-1}	1.24×10^{-1}	1.09×10^{-1}	2.41×10^{-1}	9.68×10^{-2}	2.00×10^{-1}
7	47	2.46×10^{-1}	1.93×10^{-1}	2.36×10^{-1}	3.35×10^{-1}	2.02×10^{-1}	1.78×10^{-1}
8	52	2.65×10^{-1}	3.22×10^{-1}	2.25×10^{-1}	4.59×10^{-1}	2.81×10^{-1}	2.01×10^{-1}
9	57	5.90×10^{-1}	3.59×10^{-1}	3.43×10^{-1}	5.33×10^{-1}	3.35×10^{-1}	2.92×10^{-1}
10	62	5.93×10^{-1}	3.14×10^{-1}	3.24×10^{-1}	5.91×10^{-1}	3.85×10^{-1}	3.45×10^{-1}

$$J = \sum_{p=1}^{10} (\hat{y}(k+p) - y_r(k+p))^2 \quad (17)$$

将式(8)和式(11)代入式(17)可得目标函数式(18):

$$J = \sum_{p=1}^{10} (y(k+p) + e(k+p) - y_r(k+p))^2 \quad (18)$$

式中: $y_r(k+p)$ 为控制器参考值。由于采样时 10 个预测子模型输出是由输入向量 $\mathbf{u}(k+1), \mathbf{u}(k+2), \dots, \mathbf{u}(k+10)$ 控制, 将其合并为控制矩阵 $\mathbf{U}(k)$:

$$\mathbf{U}(k) = [\mathbf{u}(k+1)^T, \mathbf{u}(k+2)^T, \dots, \mathbf{u}(k+10)^T]^T \quad (19)$$

$$\mathbf{U}(k) = \text{agr min}(J)$$

s.t.:

$$150 \text{ t/h} \leq u_B \leq 300 \text{ t/h}, |u_B(k) - u_B(k-1)| \leq 10 \text{ t/h},$$

$$800 \text{ t/h} \leq D_{fw} \leq 1700 \text{ t/h}, |D_{fw}(k) - D_{fw}(k-1)| \leq 50 \text{ t/h},$$

$$50\% \leq \mu_t \leq 99\%, |\mu_t(k) - \mu_t(k-1)| \leq 1\%,$$

$$400 \text{ t/h} \leq q_{m,air} \leq 640 \text{ t/h}, |q_{m,air}(k) - q_{m,air}(k-1)| \leq 40 \text{ t/h},$$

$$220 \text{ }^\circ\text{C} \leq T_{m,air} \leq 280 \text{ }^\circ\text{C}, |T_{m,air}(k) - T_{m,air}(k-1)| \leq 3 \text{ }^\circ\text{C}$$

(20)

在超临界火电机组协调控制系统中,出于安全性和可实施性的考虑,必须根据现场实际情况把给煤量、给水量、汽轮机综合阀位、一次风量、一次风温等输入量约束在一定范围内。因此,根据机组实际运行允许情况,控制器求解过程需要对控制矩阵中 5 个变量做如下约束,控制问题转换为在约束条件下最小化目标函数 J 的问题。因此,控制目标可看作求解使目标函数 J 最小的控制矩阵 $\mathbf{U}(k)$:

3.2 目标函数凸性分析

在目标函数 J 中: $y(k)$ 是 ICNN 训练的对 $u(k)$ 的凸函数; $e(k)$ 则是前一个控制步长子模型输出和实际测量输出的差值, 在采样时刻就已经被确定了, 可看作常量; $y_r(k)$ 是参考值, 为常量。因此, 由凸函数性质^[22-23]分析得出, J 可看作是对 $y(k)$ 的凸函数, 进一步推导得, J 可看作是对控制矩阵 $U(k)$ 的凸函数。

由于 J 是对于 $U(k)$ 的凸函数, 可以由 J 对 $U(k)$ 中的所有元素求梯度, 获得 $U(k)$ 对目标函数 J 的雅可比矩阵 $Y(k)$, 在 Python 环境中雅可比矩阵 $Y(k)$ 可以通过反向传播算法求得, 再采取梯度下降的方法, 求得控制器在 k 采样时刻的一个控制时域的最优控制矩阵 $U(k)$:

$$U(k) = U(k) - L_r \cdot Y(k) \quad (21)$$

式中: L_r 为梯度下降的学习率。

3.3 仿真研究

根据文献[24-25]建立以给水流量、给煤流量、汽轮机阀位、一次风量、一次风温为输入的中间点过热微分方程模型, 待定参数由运行数据闭环辨识得到。根据辨识所得模型在 Simulink 中搭建过热微分方程仿真模型, 在 Python 环境下设计 MPC 控制器, 二者使用串口通信, 获得 DDICNN-MPC 控制器结构如图 5 所示。

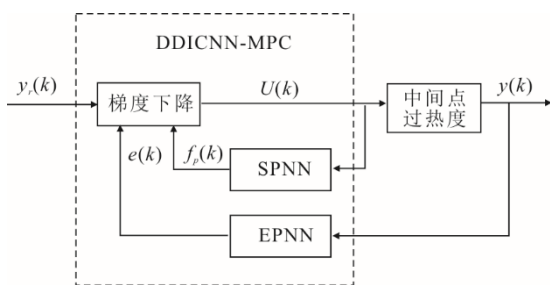


图 5 DDICNN-MPC 控制器
Fig.5 The DDICNN-MPC controller

基于 MLR、BPNN、ICNN 3 种子模型搭建 3 种双深度模型预测控制器, 分别简称为 DDMLR-MPC、DDBPNN-MPC、DDICNN-MPC。控制时间 $t \leq 0$ s 为中间点过热初始状态, 仿真时间设置为 8 400 s, 控制器控制过热度分别在 4 个阶段跟踪 30、40、15、25 °C, 设置梯度下降学习率 $L_r=1$, 梯度下降迭代次数为 100, 仿真比较 3 种控制器的控制效果, 中间点过热度 (被控量 $y(k)$) 控制变化曲线如图 6 所示, 给水流量、给煤量、汽轮机阀位、一次

风量、一次风温 5 个控制量 $u(k)$ 变化曲线如图 7、图 8 所示。

当中间点过热控制在 $\pm 2\%$ 的误差允许范围内可以看作系统稳定, 分别计算不同控制器 4 个阶段控制曲线的平均调节时间、稳态误差和平均绝对误差 δ_{MAE} 见表 2。


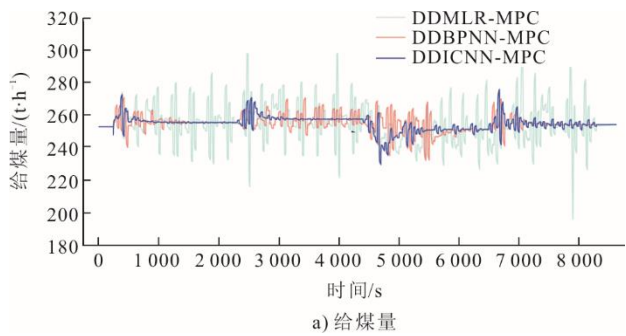




图 6 中间点过热度 (被控量) 变化曲线
Fig.6 Change curves of intermediate point overheat (controlled amount)



a) 给煤量



b) 给水流量



c) 调节阀开度

图 7 给煤量、给水量、调节阀开度 (控制量) 变化曲线
Fig.7 Change curves of coal feed, water feed and turbine switch opening (control amount)

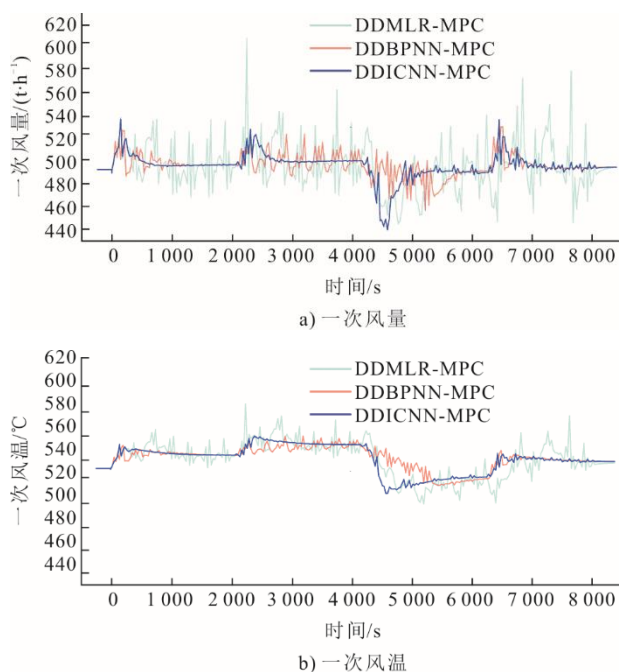


图8 一次风量、一次风温（控制量）变化曲线
Fig.8 Change curves primary air volume, primary air temperature (control amount)

表2 控制器性能指标
Tab.2 Controller performance indexes

控制器	平均调节时间/s	稳态误差/%	平均绝对误差/°C
DDBPNN-MPC	1 215	0.37	3.37
DDICNN-MPC	518	0.35	1.54

由图6、图7、图8及表2对比3种控制器控制效果可以看出：DDMLR-MPC的控制误差较大，难以跟踪中间点温度到达设定值；DDICNN-MPC、DDBPNN-MPC都能控制中间点过热度至稳定，DDBPNN-MPC平均调节时间为1 215 s、稳态误差为0.35%、平均绝对误差为3.37 °C；DDICNN-MPC的平均调节时间为518 s、稳态误差为0.37%、平均绝对误差为1.54 °C，相比于DDBPNN-MPC，DDICNN-MPC能更快更平稳调节中间点过热度到达设定值，且稳态误差更小，控制跟踪效果更好。

4 结 论

本文针对超临界锅炉中间点过热度预测控制问题，提出了一种基于双深度输入凸神经网络多模型的中间点过热度预测控制方法，得到如下结论。

1) 利用多模型方法构建中间点过热度SPNN和EPNN，对10个不同预测步长分别采用ICNN子模型，其预测效果优于BPNN、MLR，具有较好的精度和非线性拟合能力。

2) 基于双深度输入凸神经网络设计了DDICNN-MPC控制器，利用ICNN凸性质，验证了采用梯度下降法作为滚动优化算法的合理性。

3) 通过仿真研究，DDICNN-MPC相比于DDBPNN-MPC、DDMLR-MPC能更迅速、更平稳调节中间点过热度到达设定值，且稳态误差更小，控制跟踪效果更好。

[参考文献]

- [1] 马汀山, 王妍, 吕凯, 等. “双碳”目标下火电机组耦合储能的灵活性改造技术研究进展[J]. 中国电机工程学报, 2022, 42(增刊1): 136-148.
MA Tingshan, WANG Yan, LYU Kai, et al. Research progress on flexibility transformation technology of coupled energy storage for thermal power units under the “dual-carbon” goal[J]. Proceedings of CSEE, 2022, 42(Suppl.1): 136-148.
- [2] 牟春华, 居文平, 黄嘉骊, 等. 火电机组灵活性运行技术综述与展望[J]. 热力发电, 2018, 47(5): 7-13.
MU Chunhua, JU Wenping, HUANG Jiasi, et al. Review and prospect of technologies of enhancing the flexibility of thermal power units[J]. Thermal Power Generation, 2018, 47(5): 7-13.
- [3] 林俐, 田欣雨. 基于火电机组分级深度调峰的电力系统经济调度及效益分析[J]. 电网技术, 2017, 41(7): 2255-2263.
LIN Li, TIAN Xinyu. Analysis of deep peak regulation and its benefit of thermal units in power system with large scale wind power integrated[J]. Power System Technology, 2017, 41(7): 2255-2263.
- [4] 张学延, 何国安, 曾立飞, 等. “双碳”目标下火电机组故障及应对措施综述[J]. 热力发电, 2022, 51(12): 10-17.
ZHANG Xueyan, HE Guoan, ZENG Lifei, et al. Overview of thermal power units' faults and the countermeasures under the target of “carbon neutrality and carbon peaking”[J]. Thermal Power Generation, 2022, 51(12): 10-17.
- [5] 谷俊杰, 王鹏, 白智中, 等. 超超临界机组一次调频动作中间点过热度动态特性研究[J]. 中国电机工程学报, 2017, 37(12): 3525-3534.
GU Junjie, WANG Peng, BAI Zhizhong, et al. Study on superheat degree dynamic response of ultra supercritical unit's intermediate point caused by primary frequency regulation[J]. Proceedings of the CSEE, 2017, 37(12): 3525-3534.
- [6] FAN H, SU Z G, WANG P H, et al. A dynamic nonlinear model for a wide-load range operation of ultra-supercritical once-through boiler-turbine units[J]. Energy, 2021, 226: 120425.
- [7] FAN H, ZHANG Y F, SU Z G, et al. A dynamic mathematical model of an ultra-supercritical coal fired once-through boiler-turbine unit[J]. Applied Energy, 2017, 189: 654-666.
- [8] 刘萌, 王印松, 牟文彪, 等. 基于多策略分区勘探粒子群算法的主蒸汽温度优化控制[J]. 热力发电, 2021, 50(7): 23-30.
LIU Meng, WANG Yinsong, MOU Wenbiao, et al. Optimization control of main steam temperature system based on multi strategy partition exploration particle

- swarm optimization algorithm[J]. Thermal Power Generation, 2021, 50(5): 23-30.
- [9] 李炳楠, 朱峰, 燕志伟, 等. 超临界火电机组协调系统建模及模型预测控制算法研究[J]. 热能动力工程, 2020, 35(2): 117-125.
LI Bingnan, ZHU Feng, YAN Zhiwei, et al. Research on modeling and model predictive control algorithm for supercritical thermal power unit coordination system[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(2): 117-125.
- [10] 马增辉, 徐慧仪. 基于间隙度量的主汽温多模型 Smith 预估控制[J]. 热能动力工程, 2020, 35(9): 148-153.
MA Zenghui, XU Huiyi. Multiple model smith predictor control of main steam temperature based on gap metric[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(9): 148-153.
- [11] WANG G L, YAN W W, CHEN S H, et al. Multi-model predictive control of ultra-supercritical coal-fired power unit[J]. Chinese Journal of Chemical Engineering, 2014, 22: 782-787.
- [12] 郭嘉曦, 刘长良, 刘帅, 等. 基于数字孪生模型的主汽温预测控制策略[J/OL]. 华北电力大学学报: 1-9. (2022-11-22)[2023-05-10] <https://kns.cnki.net/kcms/detail/13.1212.tm.20221121.1021.002.html>.
GUO Jiayi, LIU Changliang, LIU Shuai, et al. Main steam temperature predictive control strategy based on digital twin[J/OL]. Journal of North China Electric Power University: 1-9. (2022-11-22)[2023-05-10] <https://kns.cnki.net/kcms/detail/13.1212.tm.20221121.1021.002.html>.
- [13] AMOS B, XU L, KOLTER J Z. Input convex neural networks[C]. Proceedings of the 34th International Conference on Machine Learning, 2017: 146-155.
- [14] 刘友波, 王天翔, 邱高, 等. 嵌入输入凸神经网络的静态电压稳定控制替代建模方法及其解析算法[J]. 电力自动化设备, 2023, 43(2): 151-159.
LIU Youbo, WANG Tianxiang, QIU Gao, et al. Surrogate modeling method and its analytical algorithm for static voltage stability control embedded with input convex neural network[J]. Electric Power Automation Equipment, 2023, 43(2): 151-159.
- [15] YANG S, BEQUETTE B W. Optimization-based control using input convex neural networks[J]. Computers & Chemical Engineering, 2021, 144: 107143-107151.
- [16] BÜNNING F, SCHALBETTER A, ABOUDONIA A, et al. Input convex neural networks for building MPC, Proc[J]. Proceedings of Machine Learning Research, 2021, 144: 251-262.
- [17] ZHU H Y, TAN P, HE Z Q, et al. Nonlinear model predictive control of USC boiler-turbine power units in flexible operations via input convex neural network[J]. Energy, 2022, 255: 124486.
- [18] FANG C, GU Y H, ZHANG W Z, et al. Convex formulation of overparameterized deep neural networks[J]. IEEE Transactions on Information Theory, 2022, 68(8), 5340-5352.
- [19] CHEN Y, SHI Y, ZHANG B. Data-driven optimal voltage regulation using input convex neural networks[J]. Electric Power System, 2020, 189: 106741.
- [20] ŁAWRYŃCZUK M. Input convex neural networks in nonlinear predictive control: a multi-model approach[J]. Neurocomputing, 2022, 513: 273-293.
- [21] 谷俊杰, 秦达飞, 曹晓威, 等. 超临界锅炉中间点温度增益切换控制方法[J]. 中国电机工程学报, 2014, 34(14): 2274-2280.
GU Junjie, QIN Dafei, CAO Xiaowei, et al. A control method based on gain-switching for intermediate point temperature of supercritical pressure boiler[J]. Proceedings of the CSEE, 2014, 34(14): 2274-2280.
- [22] 陈伟华, 姜兆迪. 基于输入凸神经网络的 IPT 系统输出电压预测控制[J]. 控制工程, 2022, 29(11): 2010-2017.
CHEN Weihua, JIANG Zhaodi. Predictive control for output voltage of IPT system based on input convex neural network[J]. Control Engineering of China, 2022, 29(11): 2010-2017.
- [23] BOYD S, VANDENBERGHE L. Convex optimization[M]. Cambridge University Press, 2004: 260.
- [24] 郭磊. 基于金属蓄热动态的直流炉控制模型研究[D]. 北京: 华北电力大学, 2016: 1.
GUO Lei. Research on control model of once-through boilers based on dynamic heat storage[D]. Beijing: North China Electric Power University, 2016: 1.
- [25] 曾德良, 高珊, 胡勇. MPS 型中速磨煤机建模与仿真[J]. 动力工程学报, 2015, 35(1): 55-61.
ZENG Deliang, GAO Shan, HU Yong. Modeling and simulation of MPS medium speed coal mills[J]. Journal of Chinese Society of Power Engineering, 2015, 35(1): 55-61.

(责任编辑 邓玲惠)