



控制与决策

CONTROL AND DECISION



数据中心制冷系统非线性模型预测控制

魏东, 韩少然, 冉义兵, 李白玉, 石艳彩, 肖志铭, 赵若辰

引用本文:

魏东, 韩少然, 冉义兵, 李白玉, 石艳彩, 肖志铭, 赵若辰. 数据中心制冷系统非线性模型预测控制[J]. 控制与决策, 2024, 39(4): 1240–1250.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0467>

您可能感兴趣的其他文章

Articles you may be interested in

基于高阶滑模速度控制器的异步电机模型预测转矩控制

A model predictive torque control for induction motor based on high order sliding mode speed controller
控制与决策. 2021, 36(4): 953–958 <https://doi.org/10.13195/j.kzyjc.2019.0650>

基于高阶滑模速度控制器的异步电机模型预测转矩控制

A model predictive torque control for induction motor based on high order sliding mode speed controller
控制与决策. 2021, 36(4): 953–958 <https://doi.org/10.13195/j.kzyjc.2019.0650>

基于T-S模糊模型的多时滞非线性网络切换控制系统非脆弱 H_∞ 控制

Non-fragile H_∞ control for multi-delay nonlinear network switching control system based on T-S model
控制与决策. 2021, 36(5): 1087–1094 <https://doi.org/10.13195/j.kzyjc.2019.1098>

基于神经动态优化的非线性系统近似最优跟踪控制

Approximate optimal tracking control for nonlinear systems based on neurodynamic optimization
控制与决策. 2021, 36(1): 97–104 <https://doi.org/10.13195/j.kzyjc.2020.0056>

参数未知的离散系统Q-学习优化状态估计与控制

Q-learning optimal state estimation and control for discrete systems with unknown parameters
控制与决策. 2020, 35(12): 2889–2897 <https://doi.org/10.13195/j.kzyjc.2019.0180>

数据中心制冷系统非线性模型预测控制

魏东^{1,2†}, 韩少然³, 冉义兵⁴, 李白玉⁵, 石艳彩⁶, 肖志铭¹, 赵若辰¹

(1. 北京建筑大学电气与信息工程学院, 北京 100044; 2. 建筑大数据智能处理方法研究北京市重点实验室, 北京 100044; 3. 中冶京诚工程技术有限公司, 北京 100176; 4. 西门子(中国)有限公司, 北京 100020; 5. 北京市市政工程设计研究总院有限公司, 北京 100082; 6. 山东合创安华智能科技有限公司, 济南 250013)

摘要: 数据中心制冷系统具有非线性、强耦合和大滞后特性, 目前常用的 PID 方法无法实现系统整体能效提升, 而现有非线性优化算法计算量大, 不易工程实现. 鉴于此, 提出一种数据中心制冷系统模型预测控制策略, 上层优化层设计预测控制器, 其目标为在满足制冷要求的前提下降低系统能耗, 优化层采用神经网络作为反馈控制器, 将系统整体优化目标函数作为神经网络控制器优化性能指标, 结合变分法与随机梯度下降法, 通过滚动优化求取下层各回路被控变量最优设定值, 算法占用存储区适中、计算量小; 下层现场控制层通过实时控制使各回路被控变量跟踪最优设定值, 可以在不破坏原有现场控制系统的情况下实现性能优化. 构建 Trnsys-Matlab 联合仿真平台, 针对系统夏季、过渡季和冬季的控制策略进行仿真实验. 结果表明, 所提出控制策略能够在满足数据中心安全运行的前提下, 实现系统整体能效提升, 且具有良好的鲁棒性.

关键词: 模型预测控制; 非线性控制; 数据中心

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0467

引用格式: 魏东, 韩少然, 冉义兵, 等. 数据中心制冷系统非线性模型预测控制[J]. 控制与决策, 2024, 39(4): 1240-1250.

Nonlinear model predictive control for data center cooling systems

WEI Dong^{1,2†}, HAN Shao-ran³, RAN Yi-bing⁴, LI Bai-yu⁵, SHI Yan-cai⁶, XIAO Zhi-ming¹, ZHAO Ruo-chen¹

(1. School of Electrical and Information Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China; 2. Beijing Key Laboratory of Intelligent Processing for Building Big Data, Beijing 100044, China; 3. MCC Capital Engineering & Research Co., Ltd., Beijing 100176, China; 4. Siemens China Co., Ltd, Beijing 100020, China; 5. Beijing General Municipal Engineering Design & Research Institute Co., Ltd., Beijing 100082, China; 6. Shandong Hechuang Anhua Intelligent Technology Co., Ltd., Jinan 250013, China)

Abstract: Data center cooling system has nonlinear, strong coupling and large hysteresis characteristics. The commonly used PID method cannot achieve overall system energy efficiency improvement, and the existing nonlinear system optimization algorithms are computationally intensive and not easy to implement. This paper proposes a model predictive control strategy for the data center cooling system. The upper optimization layer designs a predictive control strategy to reduce energy consumption on the premise of meeting the cooling load of the IT servers. A neural network is used as the feedback controller, and the optimization cost function of the system is used as the performance index of the neural network controller, and combining the variational method and stochastic gradient descent method to perform online receding horizon optimization to obtain the optimal set values of the controlled variables for each loop in the lower layer. The optimization algorithm occupies moderate storage space and small computation. The lower field control layer makes the controlled variables track the optimal set value through real-time control, which can realize optimization without destroying the original field control system. A Trnsys-Matlab simulation platform is constructed and simulation experiments are conducted for summer, transition season and winter conditions. Experimental results show that the proposed control strategy can achieve energy efficiency improvement with good robustness while meeting the premise of safe operation of the data center.

Keywords: model predictive control; non-linear system; data center

收稿日期: 2022-03-23; 录用日期: 2022-12-20.

基金项目: 北京市属高校高水平创新团队建设计划项目(IDHT20190506); 住房和城乡建设部科学技术项目(研究开发项目)(2019-K-120); 北京建筑大学高级主讲教师培育计划项目(GJZJ20220803).

责任编辑: 王燕舞.

†通讯作者. E-mail: weidong@bucea.edu.cn.

0 引言

数据中心需要全年供冷,其制冷系统能耗约占数据中心总能耗的50%^[1].数据中心制冷系统组成复杂,其中水泵、风阀、风机等执行器具有非线性,现有非线性优化算法由于计算量大、占用存储空间多,不易工程实现,导致目前该系统多采用手动或局部PID控制,不仅无法取得良好的控制效果,且难以实现系统节能.PUE(power usage effectiveness)是数据中心能效评价标准,定义为数据中心总功率和IT设备功率之比.目前,谷歌数据中心制冷系统采用先进控制策略,结合利用自然冷源,PUE最低能够达1.1左右,而我国数据中心平均PUE大于2.2^[2],因此通过控制策略提升数据中心制冷系统能效具有重要意义.

模型预测控制可有效处理复杂约束下的优化控制问题^[3],若将满足制冷要求的同时降低PUE值作为优化目标函数,则可以实现系统能效提升.文献[4]以满足IT设备温度要求和降低冷水机组功率作为优化目标,采用序列二次规划法(sequential quadratic programming, SQP)实现预测滚动优化.文献[3, 5]提出了一种双时间尺度数据中心预测控制策略,以满足IT设备温度要求并提升送风温度作为优化目标,采用SQP算法实现预测控制.文献[6]以IT设备温度、能耗和控制惩罚项构建系统优化目标,采用内点法(interior-point algorithm)寻优,通过控制风机转速实现模块化数据中心分区域制冷.上述研究虽然在一定程度上能够实现系统节能运行,但局限于风机、冷水机组等局部设备控制,并不能提升制冷系统整体能效.此外,由于数据中心以安全为第一要求,目前数据中心制冷系统预测控制策略成果较少,大部分研究集中在建筑制冷站系统节能优化控制.文献[7]在energyplus环境下搭建仿真平台,采用动态规划法实现系统节能优化.文献[8]应用机理建模法建立了光伏蓄冰空调系统非线性预测模型,采用动态规划法提升系统能效.

模型预测控制核心是滚动优化,非线性优化求解很难取得解析解,上述研究多采用SQP或动态规划算法进行寻优,但此类算法对计算量和存储空间均有较高要求,导致现有成果大多处于仿真阶段.为解决非线性系统优化求解困难的问题,文献[9]利用神经网络逼近动态规划最优反馈解,但该方法本质上是一种最优控制问题求解方法,并不适合受时变和不确定因素影响的被控过程.

鉴于此,本文提出一种数据中心预测控制策略,控制目标为满足制冷要求的前提下尽可能提升系统

能效.对文献[9]方法进行改进,设计神经网络模型预测控制器,将系统整体优化目标函数作为神经网络控制器优化性能指标,并将变分法与随机梯度下降法结合,对系统进行多步预测滚动优化.算法计算量小,占用存储空间少,易于工程实现.

1 系统描述

1.1 数据中心制冷系统组成及原理

数据中心制冷系统结构如图1所示.夏季工况下,冷冻水经冷水机组中的制冷剂降温后,通过末端空气处理机组与机房回风进行热交换,然后风机将低温风送至地板出风口;冷却水与冷水机组的高温制冷剂实现热交换,通过冷却塔将热量散发至室外,如此循环实现制冷功能.冬季和室外气温较低的过渡季,制冷系统不开启冷水机组,利用室外冷空气作为冷源.此时,冷却水经过冷却塔与室外冷空气进行热交换,然后低温冷却水通过板式换热器与冷冻水回路中的部分或全部冷冻水回水换热,逐渐减少甚至停止机械制冷,从而实现自然冷却^[10].

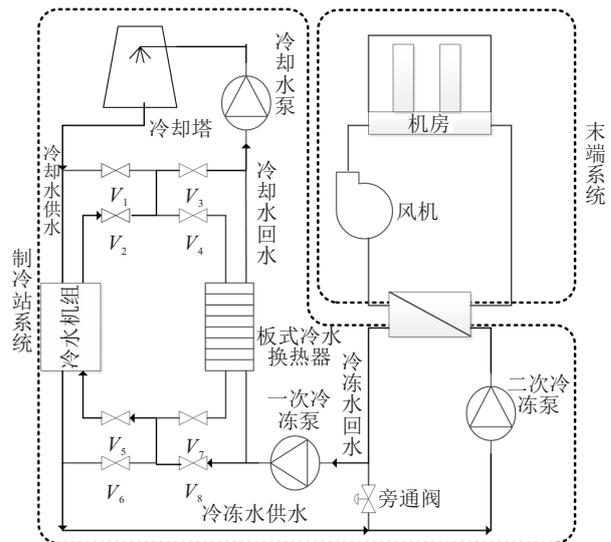


图1 数据中心制冷系统组成及原理

本文依据文献[11]所提出的工况切换方案,根据室外湿球温度,对北京地区全年常用冷却塔供冷时间^[12]进行划分,将3624~5832小时设为夏季工况,8016~14160小时设为冬季工况,其余为过渡季工况.

1.2 制冷系统能效

数据中心总功率包含制冷系统、IT设备、电力分配损失及楼宇自控系统(照明、安防、消防等)的功率.本文主要研究制冷系统控制策略,因此将能耗评价标准简化为 $PUE_{cooling}$,有

$$PUE_{cooling} = \frac{P_{cooling} + P_{IT}}{P_{IT}}. \quad (1)$$

其中: P_{cooling} 表示制冷系统功率, 为冷水机组、冷却塔、水泵和末端风机功率之和; P_{IT} 表示IT设备功率.

冷水机组制备的冷量为

$$Q_{\text{ch}} = c \cdot F_{\text{CHW}} \cdot (T_{\text{CHW}_r} - T_{\text{CHW}}). \quad (2)$$

其中: Q_{ch} 为冷水机组制备冷量, 单位 kW; c 为水比热容, 单位 $J/(kg \cdot K)$; F_{CHW} 为冷冻水流量, 单位 kg/s; T_{CHW} 为冷冻水供水温度, 单位 $^{\circ}\text{C}$; T_{CHW_r} 为冷冻水回水温度, 单位 $^{\circ}\text{C}$.

冷水机组的运行能效比定义为所制备的冷量与冷水机组运行功率之比, 有

$$\text{COP} = Q_{\text{ch}}/P_{\text{ch}}, \quad (3)$$

其中 P_{ch} 为冷水机组的运行总功率, 单位 kW.

冷却塔运行功率可表示为

$$P_{\text{tower}} = (f_t/f_0)^3 \cdot P_{\text{tower,rated}}. \quad (4)$$

其中: P_{tower} 为冷却塔风机的运行功率; $P_{\text{tower,rated}}$ 为风机的额定功率; f_t 为风机的运行频率; f_0 为风机的额定频率, 一般为 50 Hz.

水泵运行功率计算方式为

$$P_{\text{pump}} = \frac{\rho \cdot g \cdot V \cdot H}{3.6 \times 10^6 \cdot \eta_p \cdot \eta_m \cdot \eta_{\text{VFD}}}. \quad (5)$$

其中: P_{pump} 为水泵功率; ρ 和 V 分别为流体密度和体积流量; g 为重力加速度; H 为扬程; η_p 、 η_m 和 η_{VFD} 分别为水泵、电机和变频器的效率.

2 数据中心制冷系统预测控制

2.1 优化目标函数

数据中心制冷系统通过调节送风温度供冷, 因此设计优化目标函数

$$J = \frac{1}{2} \sum_{k=t_1}^{t_1+M-1} (\alpha(\text{PUE}_{\text{cooling_set}}[k] - \text{PUE}_{\text{cooling}}[k])^2 + \beta(T_{a_set}[k] - T_a[k])^2). \quad (6)$$

其中: k 为当前时刻, 预测时域起始时间为 t_1 , 预测时域为 M ; $\text{PUE}_{\text{cooling_set}}[k]$ 为能效指标设定值, $\text{PUE}_{\text{cooling}}[k]$ 为能效指标实际值; $T_{a_set}[k]$ 为送风温度设定值, $T_a[k]$ 为送风温度实际值.

2.2 控制系统结构

控制系统结构如图2所示, 图中 TDL (time delay line) 表示时延线.

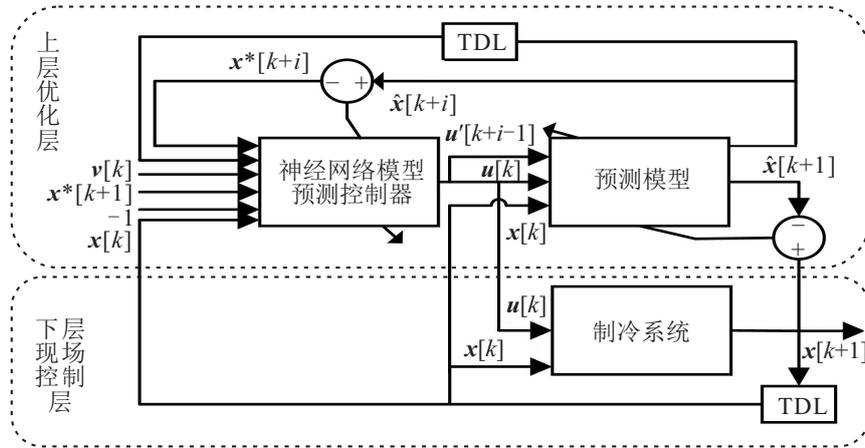


图2 控制系统结构

图2中上层优化层由神经网络预测控制器及制冷系统预测模型构成, 负责求解制冷系统各回路被控变量最优设定值 $u^*[k]$, 包括冷冻水和冷却水供水温度及流量, 以及机房地板送风与顶棚回风温差; 下层现场控制层分别调节冷水机组、冷冻水泵转速、冷却塔风机转速、冷却水泵转速和末端机组冷冻水阀开度, 使被控变量跟上优化层得出的设定值. 图2中: $x[k]$ 为状态变量, 即 $\text{PUE}_{\text{cooling}}$ 和送风温度 T_a ; $v[k]$ 为干扰量, 包括室外湿球温度和IT设备负荷; $x^*[k+1]$ 为下一时刻状态变量期望值; $\hat{x}[k+1]$ 为预测模型输出; -1 的作用是将阈值当作权值处理.

2.3 预测控制滚动优化算法描述

多输入多输出非线性系统数学模型可描述为

$$\begin{aligned} x[k+1] &= f(x[k], u[k]), \\ x[0] &= x_0 \sim P(x_0). \end{aligned} \quad (7)$$

其中: $x[k] \in R^n$, $u[k] \in R^m$; $P(x_0)$ 为与初始状态 x_0 相关的概率分布; x_0 受到机房负荷、气象参数等的影响, 具有不确定性.

神经网络控制器可表示为

$$u[k] = g(x^*[k+1], x[k], W), \quad (8)$$

其中 W 为权值和阈值矩阵.

系统优化目标函数可表示为

$$J = \varphi_{t_1+M}(\mathbf{x}[t_1 + M], t_1 + M) + \sum_{k=t_1}^{t_1+M-1} L(\mathbf{x}[k], \mathbf{u}[k], k). \quad (9)$$

其中: $\varphi_{t_1+M}(\mathbf{x}[t_1 + M], t_1 + M)$ 为末值性能指标; $L(\mathbf{x}[k], \mathbf{u}[k], k)$ 为滚动优化过程中的积分性能指标.

构造哈密顿函数

$$H(\mathbf{x}, \mathbf{x}^*, \mathbf{u}, \mathbf{W}, \lambda, \gamma, k) = L(\mathbf{x}[k + 1], \mathbf{u}[k], k) + \lambda^T[k + 1]f(k) + \gamma^T[k]g(k), \quad (10)$$

其中 $f(k)$ 、 $g(k)$ 分别为式(7)、(8)等号右侧函数.

引入拉格朗日乘子, 构造增广泛函

$$J_a = \Phi_{t_1+m}(\mathbf{x}[t_1 + M], t_1 + M) - \lambda^T[t_1 + M]\mathbf{x}[t_1 + M] + \lambda^T[t_1]\mathbf{x}[t_1 + M] + \sum_{k=t_1}^{t_1+M-1} (H_k - \lambda^T[k]\mathbf{x}[k] - \gamma^T[k]\mathbf{u}[k]). \quad (11)$$

对式(11)求取一次变分, 令 $\delta J_a = 0$, 求取泛函极小值, 得到增广泛函取极值的必要条件

$$\lambda[t_1 + M] = \frac{\partial \Phi_{t_1+M}(\mathbf{x}[t_1 + M], t_1 + M)}{\partial \mathbf{x}[t_1 + M]}, \quad (12)$$

$$\lambda[k] = \frac{\partial H_k}{\partial \mathbf{x}[k]}, \quad (13)$$

$$\gamma[k] = \frac{\partial H_k}{\partial \mathbf{u}[k]}, \quad (14)$$

$$\sum_{k=t_1}^{t_1+M-1} \frac{\partial H[k]}{\partial \mathbf{W}} = 0, \quad (15)$$

其中 $k = t_1, t_1 + 1, \dots, t_1 + M - 1$.

式(12)为横截条件, 式(13)和(14)为哈密顿伴随方程, 式(15)为极值条件. 根据式(15), 利用随机梯度下降法更新神经网络控制器权值、阈值, 有

$$\Delta \mathbf{W} = -\mu \sum_{k=t_1}^{t_1+M-1} \frac{\partial g(k, \mathbf{W})}{\partial \mathbf{W}} q[k], \quad (16)$$

$$\mathbf{W} = \mathbf{W} + \Delta \mathbf{W}, \quad (17)$$

其中 μ 为学习率. 在神经网络控制器收敛后, 其输出 $\mathbf{u}^*[k]$ 使系统优化目标函数达到极小.

2.4 神经网络模型预测控制器设计

神经网络控制器的输入包括状态变量 $\mathbf{x}[k]$ 、干扰量 $\mathbf{v}[k]$ 和状态变量设定值 $\mathbf{x}^*[k + 1]$; 输出为现场各控制回路被控变量设定值. 由于板式换热器本身并不可控, 夏季与过渡季工况下控制器变量相同. 夏季、过渡季工况下控制器的输入变量为: 1) 状态变量: 能效指标 $PUE_{cooling}$ 和送风温度 T_a ; 2) 干扰量: 湿球温度 T_{WB} 和负荷 Q ; 3) 状态变量设定值: 能效指标设定值 $PUE_{cooling_set}$ 和送风温度设定值 T_{a_set} ; 4) 与阈值有关的 -1. 夏季、过渡季工况下控制器的输出变量为: 1) 冷却水供水温度 T_{CW} ; 2) 冷冻水供水温度 T_{CHW} ; 3) 送回风温差 T_{DIF} ; 4) 冷却水流量 F_{CW} ; 5) 冷冻水流量 F_{CHW} . 冬季工况下, 冷水机组完全关闭, 仅靠冷却塔联合板式换热器供冷, 因此控制器输出可减少冷却水泵流量这一变量.

不同工况下神经网络预测控制器结构如图3和图4所示.

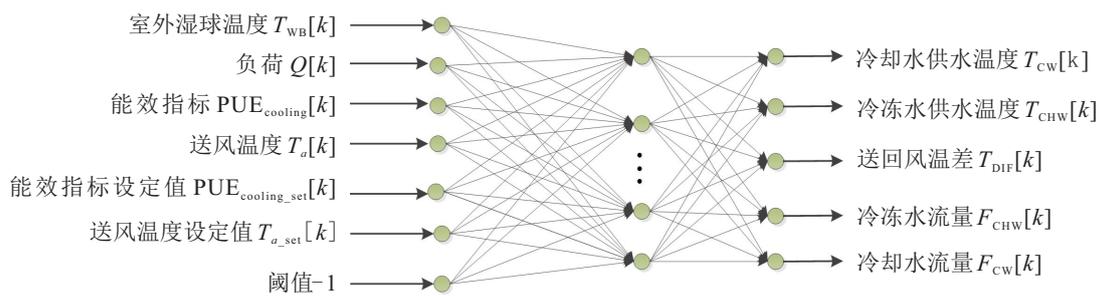


图3 夏季和过渡季工况下神经网络预测控制器结构

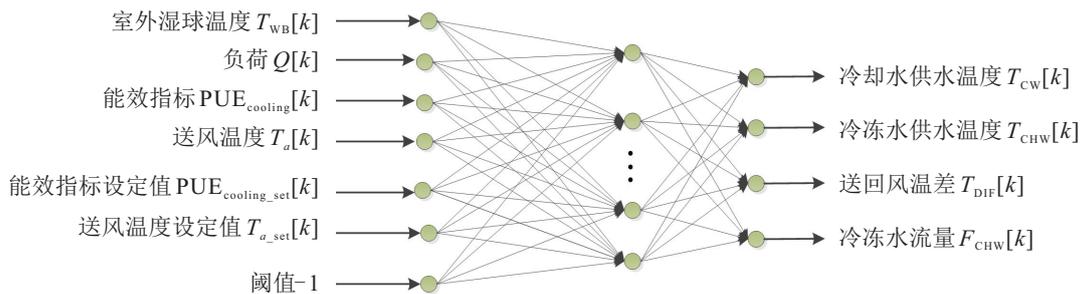


图4 冬季工况下神经网络预测控制器结构

3 实验研究

3.1 TRNSYS-MATLAB联合仿真平台设计与开发

由于实际系统运行状态通常保持不变,很难获取到覆盖系统整体动态特性的运行数据,本文基于Trnsys和Matlab开发数据中心制冷系统实时控制仿真平台.

3.1.1 数据中心制冷系统设备概况

本文研究对象为北京市通州区某数据中心制冷系统,设备参数如表1所示.

表1 数据中心制冷系统设备参数

设备	参数
离心式冷水机组	制冷量2700kW,输入功率420kW
冷冻水泵	功率30kW,流量450m ³ /h,扬程25m
冷却水泵	功率30kW,流量450m ³ /h,扬程25m
冷却塔	冷水量27885m ³ /hr
板式换热器	换热量1800kW

3.1.2 联合仿真平台开发

仿真平台由制冷系统仿真模型、预测模型及神经网络模型预测控制算法组成.应用TRNSYS Version17^[13]构建制冷系统3种工况下的仿真模型,TRNSYS模块选型如表2所示.图2中的预测模型和神经网络模型预测控制器在Matlab中实现.

3.2 预测模型建模及性能分析

3.2.1 预测模型结构及参数

数据中心制冷系统属于复杂非线性系统,传统

表2 建立模型所用变量

TRNSYS 模块	设备名称	TRNSYS 模块	设备名称
Type 51	冷却塔模块	Type 52	盘管
Type 666	冷水机组模块	Type 926	送风机
Type 740	冷却水泵	Type 759	数据中心机房
Type 740	冷冻水泵	Type 11	三通分水、集水器
Type 109	气象天气模块	Type 649	多通分水、集水器
Type 5	板式换热器		

机理建模方法较难实现,本文在TRNSYS制冷系统物理模型基础上,采用数据驱动方法构建预测模型.鉴于三层前馈神经网络能够以任意精度逼近非线性过程^[14],采用三层前馈神经网络建模.

预测模型输出应包括优化目标函数(6)中的状态变量PUE_{cooling}值和送风温度 T_a ;输入包括控制器输出量,即各现场回路被控变量设定值,以及干扰因素.此外还需考虑历史时间序列变量的影响.

综上,夏季、过渡季工况下预测模型的输入包括 k 时刻变量:1)冷却水供水温度;2)冷冻水供水温度;3)送风温度;4)送回风温差;5)冷却水泵流量;6)冷冻水流量;7)湿球温度;8)能效指标;9)负荷.

夏季、过渡季工况下预测模型输出为 $k+1$ 时刻的PUE_{cooling}和送风温度 T_a .冬季工况下制冷系统运行在完全自然冷却模式,冷水机组不参与制冷,因此预测模型的输入变量减少冷却水流量.

夏季及过渡季工况、冬季工况预测模型的神经网络结构分别如图5和图6所示.

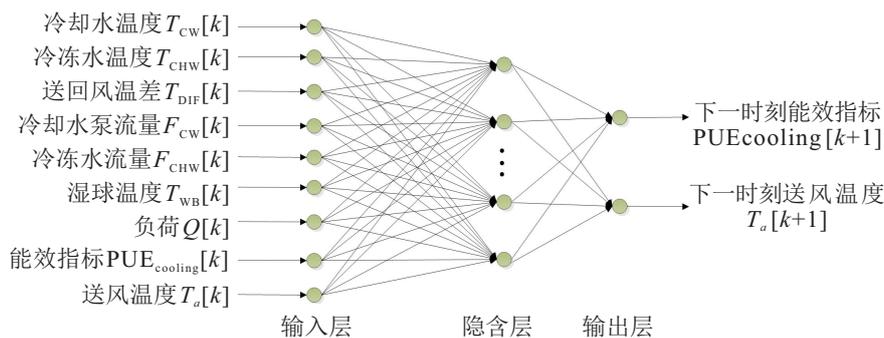


图5 夏季及过渡季工况神经网络预测模型结构

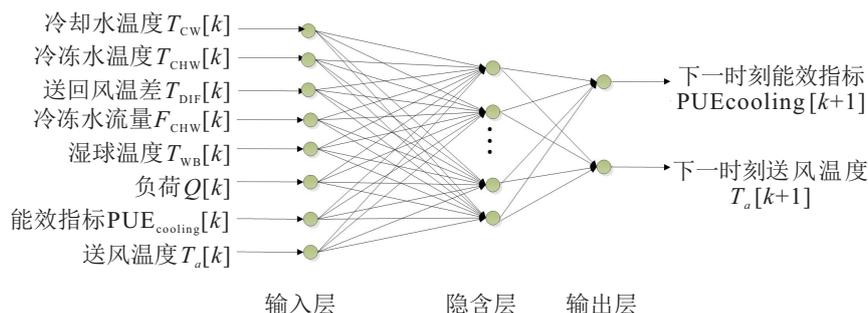


图6 冬季工况神经网络预测模型结构

由于神经网络模型的不可解释性,一般采用经验法设置网络参数^[15],本文通过如下经验公式:

$$m = \sqrt{n+l} + \alpha, \quad (18)$$

和试凑法获取隐层节点数.其中: n 为输入层节点数; l 为输出层节点数; m 为隐层节点数; α 代表1~10之间的常数.以夏季工况为例,利用式(18)求得隐层节点数范围为[4, 13],通过试凑实验,确定隐层节点数为13.

贝叶斯正则化通过在目标函数中加入约束项,能够在保证训练精度的前提下,使网络规模远小于训练样本集的大小,从而防止过拟合^[16].因此本文采取贝叶斯正则化方法对预测模型进行训练,并采用Nguyen-Widrow算法生成初始权值和阈值^[17].此外,实验综合考虑模型训练时间与均方根误差两方面因素,通过实验确定模型训练学习率为0.02.

3.2.2 数据采集与预处理

3种工况下的建模数据通过联合仿真平台的TYPE25e模块采集.为保证数据覆盖系统整个动态范围,实验引入所研究对象实际IT设备负荷(如图7)以及北京市当年室外湿球温度作为扰动.

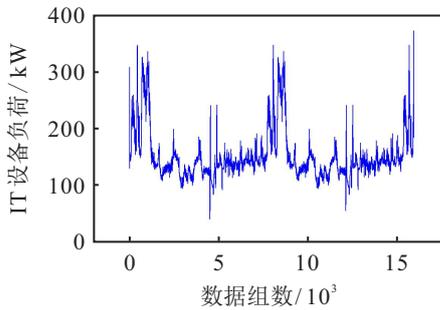


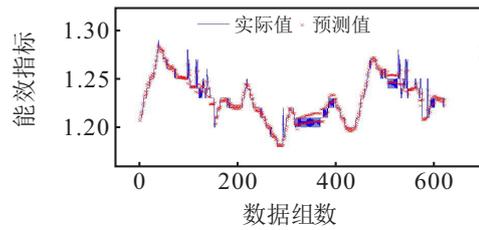
图7 IT设备负荷

采集TRNSYS仿真系统整个自然年的运行数据,仿真步长5 min,采集8 786组数据,将其按照70%、30%划分为训练集和测试集.训练前后采用线性变换法进行数据归一化处理和反归一化处理^[18].

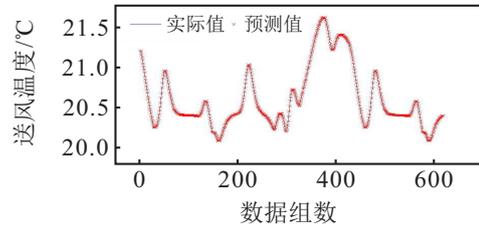
3.2.3 模型性能分析

以夏季工况为例,图8为模型性能曲线.可以看出: $PUE_{cooling}$ 误差波动范围为 $(-1.5 \times 10^{-3}, 1.5 \times 10^{-3})$,经计算得出其平均绝对误差为 0.187×10^{-3} ,平均相对误差为0.16%;送风温度误差波动范围为 $(-0.8 \times 10^{-3}, 0.8 \times 10^{-3})$,计算可得其平均绝对误差为 0.194×10^{-3} ,平均相对误差为0.13%.

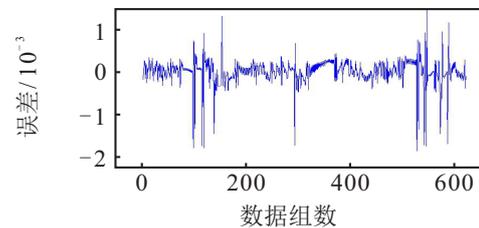
上述模型测试结果表明,本文所构建的神经网络预测模型能够准确描述数据中心制冷系统输入输出之间的复杂非线性关系,具有工程实用价值.



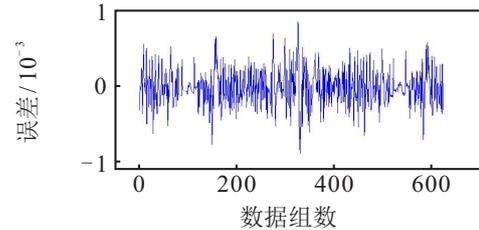
(a) $PUE_{cooling}$ 曲线



(b) 送风温度曲线



(c) $PUE_{cooling}$ 误差曲线



(d) 送风温度误差曲线

图8 预测模型性能

3.3 控制策略实验研究

在联合仿真平台上分别进行夏季、过渡季及冬季工况下的预测控制策略实验.

3.3.1 神经网络预测控制器在线寻优流程

仿真实验根据所提出的预测控制算法对神经网络控制器进行在线寻优,以求得各现场控制回路被控变量的最优设定值.在线寻优步骤如下.

step 1: 神经网络控制器初始化.文献[19]指出,当学习率较小时(< 0.1),梯度下降法能够保证前馈神经网络误差函数的单调性,本文通过实验将学习率 μ 设置为0.05.同时,首先采用Nguyen-Widrow算法生成神经网络控制器初始权值和阈值,然后进行大量实验,选取实验结果为收敛的神经网络权值与阈值作为初始值,进一步保证算法的收敛性.控制周期为5 min,预测时域 M 为6步.

step 2: 将系统反馈值 $\mathbf{x}[t_1]$ 、期望值 $\mathbf{x}^*[t_1+1]$ 和干扰量 $\mathbf{v}[t_1]$ 输入到神经网络控制器获取控制量 $\mathbf{u}[t_1]$.

step 3: 将 $\mathbf{u}[t_1]$ 和 $\mathbf{x}[t_1]$ 输入给预测模型可以得到状态变量预测值 $\hat{\mathbf{x}}[t_1 + 1]$.

step 4: 保持神经网络控制器权值 \mathbf{W}_{ji} 不变, 将 $\hat{\mathbf{x}}[t_1 + 1]$ 、 -1 和 $\mathbf{x}^*[t_1 + 2]$ 作为控制器输入, 得到控制量预测值 $\hat{\mathbf{u}}[k + 1]$. 循环上述操作, 直至得到控制量预测值 $\hat{\mathbf{u}}[k + M - 1]$ 和状态变量预测值 $\hat{\mathbf{x}}[k + M]$.

step 5: 利用式 (13) 和 (14) 计算得出拉格朗日乘子向量 $\lambda[k]$ 和 $\gamma[k]$.

step 6: 利用 step 5 计算出的 $\gamma[k]$, 通过式 (16) 和 (17) 对控制器的权值和阈值进行梯度下降修正.

step 7: 重复 step 4 ~ step 6, 直至 $\Delta \mathbf{W}$ 为零, 计算得到系统最优控制量 $\mathbf{u}^*[t_1]$, 并将其输出给制冷系统.

step 8: 令 $t_1 = t_1 + 1$, 循环 step 2 ~ step 7, 求出每一时刻的最优控制输出 \mathbf{u}^* .

对于上述预测控制算法, 假设存在 p 个控制量, q 个状态变量, n_w 个控制器的连接权值, 寻优需进行 $(2p(p+q)+n_w(q+2))M$ 步计算, 占用约 $(p+q)M+n_w$ 个存储单元; 而动态规划法计算量与系统维数为指

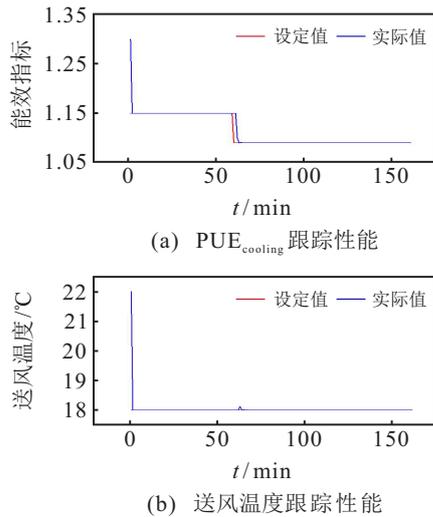


图9 夏季工况系统控制性能

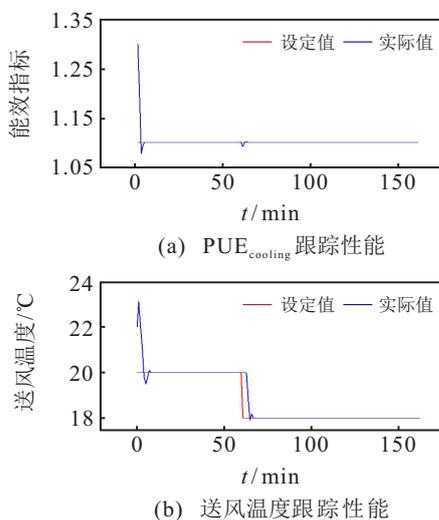
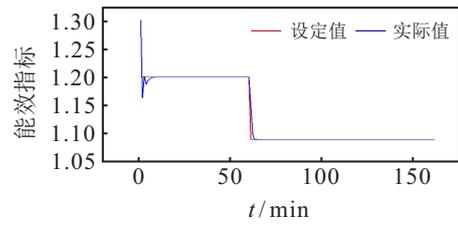
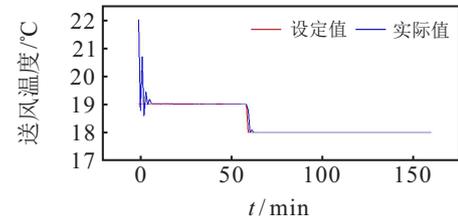


图10 过渡季工况系统控制性能



(a) PUE_{cooling} 跟踪性能



(b) 送风温度跟踪性能

图11 冬季工况系统控制性能

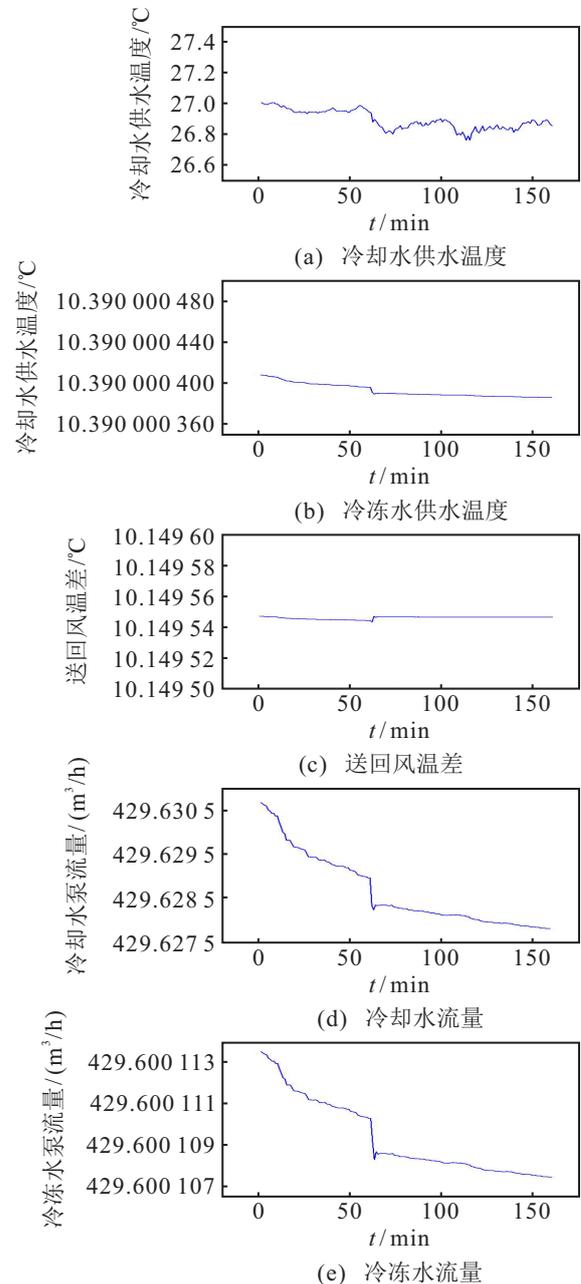


图12 夏季工况控制系统各变量运行曲线

数关系, SQP算法时间复杂度为 $O(n^3)$, 空间复杂度为 $O(n^2)$. 因此, 所提出优化算法具有计算量小与存储空间适中的优势.

3.3.2 控制策略实验结果分析

送风温度设定为《数据中心设计规范》(GB50174-2017)中机房温度推荐操作环境的下限值 18°C , $\text{PUE}_{\text{cooling}}$ 设定为1.1. 扰动量取值与3.2.2节相同. 仿真实验运行时间为160 min, 并在系统运行至第60 min时分别改变 $\text{PUE}_{\text{cooling}}$ 或送风温度设定值. 图9~图14分别为3种工况下系统状态变量或控制量的运行曲线.

由上述系统运行曲线可知, 所提出预测控制策略能够满足实时性需求, 且控制精度较高.

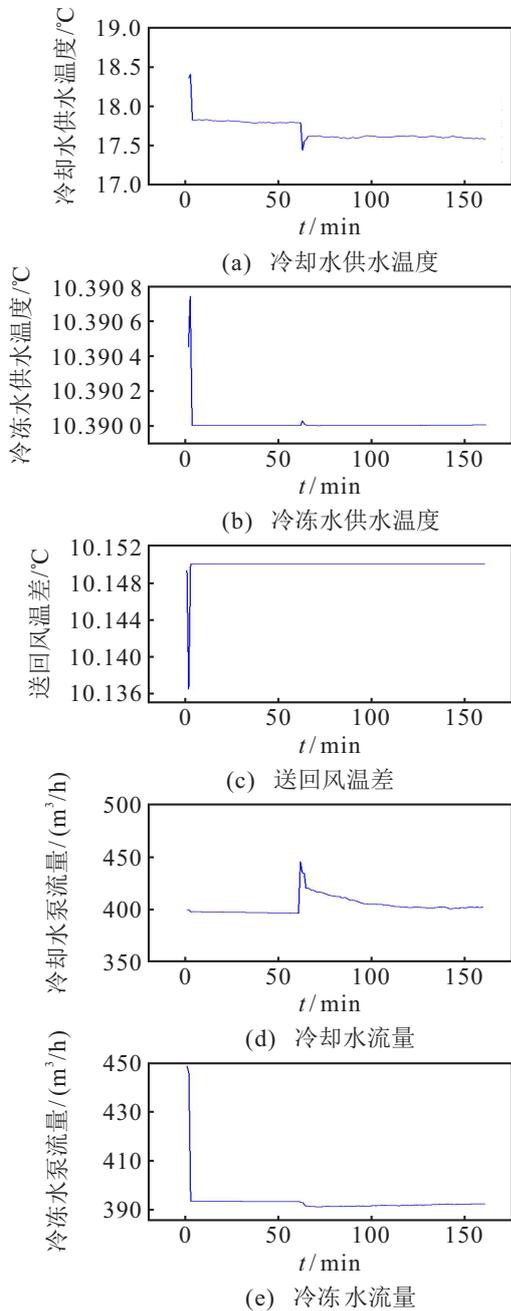


图13 过渡季工况控制系统各变量运行曲线

3.3.3 与动态规划算法对比实验

为进一步验证系统性能, 设计夏季工况条件下与动态规划法的对比实验, 动态规划法采用与本文控制策略相同的优化目标函数、约束条件及干扰量. 采用两项评价指标, 即调节时间 T_r 和稳态误差 E_y 定量描述实验结果, 有

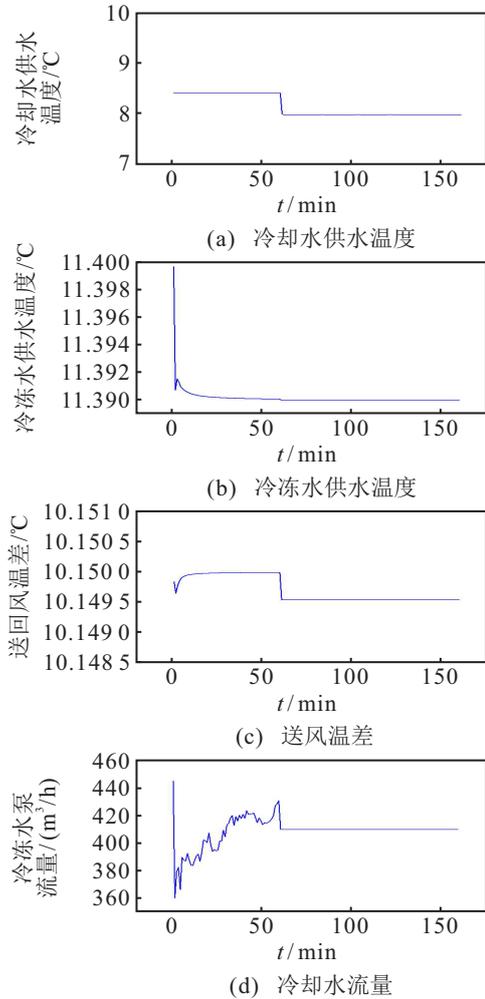


图14 冬季工况控制系统各变量运行曲线

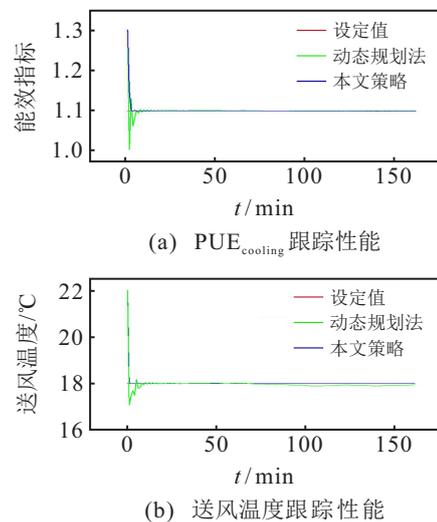


图15 本文策略与动态规划法控制性能对比

$$T_r = k - T_0,$$

$$\forall k \in M, |x(k) - x^*(k)| \leq 0.05 \times x^*(k); \quad (19)$$

$$E_y = \frac{1}{M - T_r} \sum_{k=T_r}^M |x(k) - x^*(k)|. \quad (20)$$

其中: T_0 为设定值改变的初始时刻, $x(k)$ 为 k 时刻实际值, $x^*(k)$ 为 k 时刻设定值. $PUE_{cooling}$ 及送风温度曲线如图 15 所示. 控制性能对比如表 3 所示. 算法执行优化计算时所占内存见表 4.

表3 本文策略与动态规划法控制性能对比

控制策略	送风温度		$PUE_{cooling}$	
	T_r / min	E_y	T_r / min	E_y
本文策略	3 min	0.8658×10^{-4}	7	3.2297×10^{-4}
动态规划法	3 min	6.2475×10^{-2}	12	1.93968×10^{-3}

表4 控制策略所占存储空间情况

控制策略	所占峰值内存/千兆
本文策略	796
动态规划法	5944

由上述图、表可知, 所提出的预测控制策略与动态规划法相比, 精度更高, 计算时间缩短, 同时所占峰值内存减少了 86.6%.

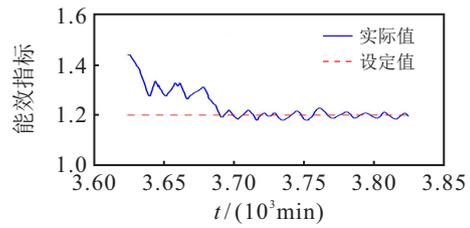
3.3.4 与PID控制对比实验

为验证所提出方法的节能效果, 设计夏季工况下与PID控制的对比实验. 仿真运行时间为200h; 两种控制方案中, 送风温度设定值为 18°C , 预测控制策略的 $PUE_{cooling}$ 设定值为 1.2. 因为PID只能实现单回路控制, 无法实现系统整体能效提升, 所以无 $PUE_{cooling}$ 设定值. 将控制系统分为末端送风温度控制(回路1)、冷冻水供回水温差控制(回路2)、冷却塔出水温度控制(回路3), 3个回路均采用PI控制. 回路1通过调节冷冻水阀开度, 使机房送风温度达到设定值 18°C ; 回路2通过调节冷冻水泵转速, 使冷冻水供回水温差达到设定值 10°C ; 回路3通过调节冷却塔风机转速, 使冷却塔出水温度比室外湿球温度高 5°C . PI参数采用Ziegler-Nichols工程整定法进行整定, 如表5所示.

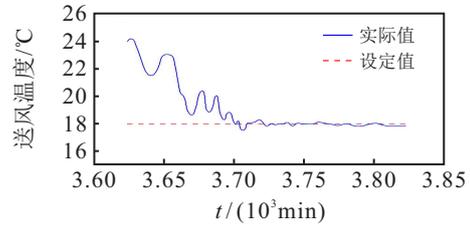
表5 PI参数整定值

参数	末端送风	冷冻水供回水	冷却塔出水
	温度控制	温差控制	温度控制
比例增益 K_P	3.6	3.2	0.91
积分时间常数 T_I / s	0.175	0.153	0.038

图 16~图 19 分别为两种控制方案下状态变量或控制量变化情况, 性能对比如表 6 所示.



(a) $PUE_{cooling}$ 变化情况



(b) 送风温度变化情况

图 16 预测控制系统性能

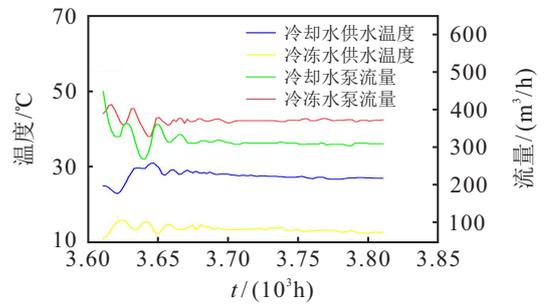
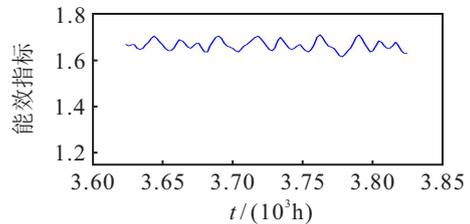
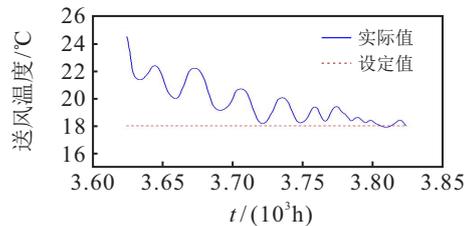


图 17 预测控制系统控制量变化情况



(a) $PUE_{cooling}$ 变化情况



(b) 送风温度变化情况

图 18 PID控制系统性能

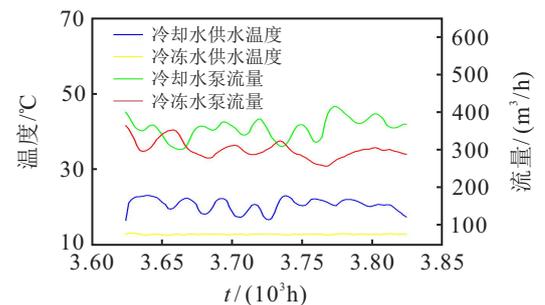


图 19 PID控制系统控制量变化情况

表6 夏季工况下本文控制策略性能

控制策略	送风温度 设定值/°C	PUE _{cooling} 设定值	送风温度	
			T_r	E_y
预测控制	18	1.2	42.4	0.646 08
PID控制	18	—	92.24	0.721 42

由上述图、表可知,PI控制时PUE_{cooling}值始终在1.675上下波动,送风温度虽呈收敛趋势,但收敛时间较长,波动较大. 预测控制策略与PI控制相比,在满

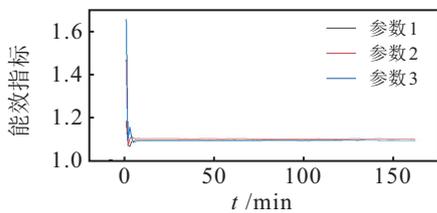
足制冷安全要求的前提下总能耗节省约28.35%,系统快速性指标 T_r 缩短约54%,系统误差指标 E_y 降低约10.5%.

3.3.5 不同初始值对控制效果影响

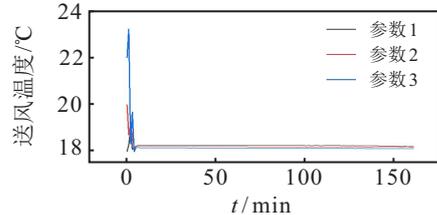
为证明所提出策略的稳定性和鲁棒性,选取3组不同的状态量、控制量初始值进行对比实验,具体参数如表7所示. 不同初始值参数下PUE_{cooling}和送风温度变化情况如图20所示.

表7 初始值参数

组别	冷冻水供水温度 (°C)	冷却水供水温度 (°C)	送回风温差 (°C)	冷冻水流量 (m ³ /h)	冷却水流量 (m ³ /h)	室外湿球温度 (°C)	负荷 (kW)	PUE _{cooling}	送风温度 (°C)
1	10	17	8	180	180	0	100	1.2	18
2	15	20	10	250	250	15	200	1.5	20
3	18	25	12	450	450	25	300	1.7	22



(a) PUE_{cooling} 变化情况



(b) 送风温度变化情况

图20 不同初始值时预测控制系统性能

由图20可知,相对于初值固定的变分法,本文所提出策略具有良好的鲁棒性.

4 结论

数据中心制冷系统具有非线性、强耦合和大滞后特性,传统PID控制参数整定困难,且无法实现系统整体能效提升,而现有非线性优化算法计算量大,不易工程实现. 为此,本文提出一种基于神经网络的数据中心制冷系统预测控制策略,上层优化层设计了神经网络预测控制算法,控制目标为在满足机房制冷要求的前提下降低系统PUE_{cooling}值,采用神经网络作为反馈控制器,将系统整体优化目标函数作为神经网络控制器优化性能指标,结合变分法与随机梯度下降法,进行在线滚动优化,得到下层现场控制层最优设定值. 下层现场控制层对制冷系统进行实时控制,可以在不破坏原有现场控制系统的情况下实现系统性能优化.

本文针对北京市通州区某数据中心搭建了夏季、冬季及过渡季3种工况下的Trnsys-Matlab联合仿真平台. 仿真实验结果表明,所提出控制策略能够在满足数据中心安全运行的前提下,实现系统整体能效提升,且能够克服变量初始值不确定性及室外干扰因素的影响,验证了所提出控制策略的稳定性和鲁棒性. 基于神经网络的预测控制滚动优化算法与动态规划算法相比占用存储空间适中,计算量小,易于工程实现,且与PID控制算法相比,夏季总能耗节省约28.35%.

参考文献(References)

- [1] Fang Q, Gong Q, Wang J, et al. Optimization based resource and cooling management for a high performance computing data center[J]. ISA Transactions, 2019, 90: 202-212.
- [2] 王子星, 雷乐, 李楠, 等. 数据中心空气冷却器性能改进的数值计算[J]. 工程热物理学报, 2021, 42(12): 3249-3253.
(Wang Z X, Lei L, Li N, et al. Heat transfer performance improvement of air-cooling unit in data center by numerical simulation[J]. Journal of Engineering Thermophysics, 2021, 42(12): 3249-3253.)
- [3] Martínez-García F, Badawy G, Kheradmandi M, et al. Adaptive predictive control of a data center cooling unit[J]. Control Engineering Practice, 2021, 107: 104674.
- [4] Ogawa M, Endo H, Fukuda H, et al. Cooling control restraining effects due to ICT equipment utilization of disturbance based on model predictive control for modular data center[C]. IEEE Conference on Control Applications. Juan Les Antibes, 2014: 183-190.
- [5] Fang Q, Wang J, Gong Q, et al. Thermal-aware energy management of an HPC data center via two-time-scale control[J]. IEEE Transactions on Industrial Informatics,

- 2017, 13(5): 2260-2269.
- [6] Mirhoseininejad S, Badawy G, Down D G. A data-driven, multi-setpoint model predictive thermal control system for data centers[J]. *Journal of Network and Systems Management*, 2021, 29(1): 1-22.
- [7] Pombeiro H, Machado M J, Silva C. Dynamic programming and genetic algorithms to control an HVAC system: Maximizing thermal comfort and minimizing g cost with PV production and storage[J]. *Sustainable Cities and Society*, 2017, 34: 228-238.
- [8] 赵柏扬, 张雪芬, 李勇, 等. 基于动态规划的光伏蓄冰空调预测控制[J]. *制冷学报*, 2020, 41(4): 8-15. (Zhao B Y, Zhang X F, Li Y, et al. Predictive control of photovoltaic ice storage air-conditioning system based on dynamic programming[J]. *Journal of Refrigeration*, 2020, 41(4): 8-15.)
- [9] Seong C Y, Widrow B. Neural dynamic optimization for control systems. II. Theory[J]. *IEEE Transactions on Systems, Man, and Cybernetics — Part B: Cybernetics*, 2001, 31(4): 490-501.
- [10] Han Z, Sun X, Wei H, et al. Energy saving analysis of evaporative cooling composite air conditioning system for data centers[J]. *Applied Thermal Engineering*, 2021, 186: 116506.
- [11] Li J, Li Z. Model-based optimization of free cooling switchover temperature and cooling tower approach temperature for data center cooling system with water-side economizer[J]. *Energy and Buildings*, 2020, 227: 110407.
- [12] 北京市建筑设计研究院. 北京地区冷却塔供冷系统设计指南[M]. 北京, 中国: 中国计划出版社, 2011. (Beijing Institute of Architectural Design. Beijing cooling tower cooling system design guide[M]. Beijing: China Plan Press, 2011.)
- [13] 王梦雪, 赵浩然, 田航, 等. 典型综合能源系统仿真与规划平台综述[J]. *电网技术*, 2020, 44(12): 4702-4712. (Wang M X, Zhao H R, Tian H, et al. Review of typical simulation and planning platforms for integrated energy system[J]. *Power System Technology*, 2020, 44(12): 4702-4712.)
- [14] Patan K, Patan M. Neural-network-based iterative learning control of nonlinear systems[J]. *ISA Transactions*, 2020, 98: 445-453.
- [15] 江泽涛, 秦嘉奇, 张少钦. 参数池化卷积神经网络图像分类方法[J]. *电子学报*, 2020, 48(9): 1729-1734. (Jiang Z T, Qin J Q, Zhang S Q. Parameterized pooling convolution neural network for image classification[J]. *Acta Electronica Sinica*, 2020, 48(9): 1729-1734.)
- [16] Ramchoun H, Ettaouil M. Hamiltonian Monte Carlo based on evidence framework for Bayesian learning to neural network[J]. *Soft Computing*, 2019, 23(13): 4815-4825.
- [17] Narkhede M V, Bartakke P P, Sutaone M S. A review on weight initialization strategies for neural networks[J]. *Artificial Intelligence Review*, 2022, 55(1): 291-322.
- [18] 吴诗辉, 张发, 李正欣, 等. 基于神经网络的仿真优化算法设计[J]. *系统工程与电子技术*, 2019, 41(6): 1324-1335. (Wu S H, Zhang F, Li Z X, et al. Design of algorithm for neural network based optimization via simulation[J]. *Systems Engineering and Electronics*, 2019, 41(6): 1324-1335.)
- [19] Shao H, Wu W, Li F, et al. Convergence of batch gradient algorithm for feedforward neural network training[J]. *Journal Information Computer Science*, 2007, 4: 251-255.

作者简介

魏东(1968—),女,教授,博士,从事神经网络非线性优化与控制、预测控制、建筑设备节能控制等研究, E-mail: weidong@bucea.edu.cn;

韩少然(1996—),男,硕士,从事建筑设备节能控制的研究, E-mail: hanson2108@163.com;

冉义兵(1988—),男,硕士,从事工业人工智能的研究, E-mail: ryibing2009@163.com;

李白玉(1989—),女,硕士,从事建筑设备节能控制的研究, E-mail: libaiyu@bmedi.cn;

石艳彩(1989—),女,硕士,从事建筑节能与安全监控理论与工程的研究, E-mail: 947511220@qq.com;

肖志铭(1997—),男,硕士生,从事建筑设备节能控制的研究, E-mail: 840060751@qq.com;

赵若辰(1998—),男,硕士生,从事复杂系统建模与控制的研究, E-mail: zhaoruochen001@163.com.