

控制与决策

Control and Decision

地铁站台空调系统非线性预测控制策略

魏东, 肖志铭, 安硕, 熊亚选

引用本文:

魏东, 肖志铭, 安硕, 熊亚选. 地铁站台空调系统非线性预测控制策略[J]. *控制与决策*, 2024, 39(2): 509–518.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1071>

您可能感兴趣的其他文章

Articles you may be interested in

基于DDPG的冷源系统节能优化控制策略

Energy-saving optimization control strategy of cold source system based on DDPG algorithm

控制与决策. 2021, 36(12): 2955–2963 <https://doi.org/10.13195/j.kzyjc.2020.0734>

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>

一类非线性大系统分散自适应预设性能有限时间跟踪控制

Decentralized adaptive prescribed performance finite-time tracking control for a class of large-scale nonlinear systems

控制与决策. 2020, 35(12): 3045–3052 <https://doi.org/10.13195/j.kzyjc.2019.0623>

地铁站台空调系统非线性预测控制策略

魏东^{1,2}, 肖志铭¹, 安硕³, 熊亚选^{4†}

- 北京建筑大学 电气与信息工程学院, 北京 100044;
- 建筑大数据智能处理方法研究北京市重点实验室, 北京 100044;
- 青岛市人防建筑设计研究院有限公司, 山东 青岛 266100;
- 北京建筑大学 环境与能源工程学院, 北京 100044)

摘要: 地铁站台空调系统回路众多且具有强耦合和非线性特性, PID 控制方法参数整定困难, 无法兼顾乘客舒适性和能效最优, 由于系统建模困难, 非线性优化算法计算量大, 智能控制方法难以实现工程应用. 对此, 提出一种地铁站台空调系统预测控制策略. 首先, 根据热湿负荷平衡和能量守恒定律建立地铁站台热动态特性预测模型; 然后, 将满足乘客舒适性并节省能耗作为系统优化目标, 使用神经网络作为优化反馈控制器, 将系统优化目标函数作为控制器优化性能指标, 结合变分法和随机梯度下降法, 对神经网络控制器的权值和阈值进行在线滚动优化, 算法计算量小, 占用存储空间适中. 仿真实验结果表明, 所提出的预测控制策略与传统 PID 控制方法相比, 在满足乘客舒适性要求的前提下, 系统响应时间可缩短约 39.6%, 末端风机能耗降低约 73.39%.

关键词: 地铁空调系统; 模型预测控制; 机理建模; 非线性优化算法; 神经网络; 建筑节能

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1071

引用格式: 魏东, 肖志铭, 安硕, 等. 地铁站台空调系统非线性预测控制策略[J]. 控制与决策, 2024, 39(2): 509-518.

Nonlinear predictive control for subway station air conditioning systems

WEI Dong^{1,2}, XIAO Zhi-ming¹, AN Shuo³, XIONG Ya-xuan^{4†}

- School of Electrical and Information Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China;
- Beijing Key Laboratory of Intelligent Processing for Building Big Data, Beijing 100044, China;
- Qingdao City Civil Air Defense Construction Design and Research Institute Co., Ltd, Qingdao 266100, China;
- School of Environmental and Energy Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044)

Abstract: There are many loops in the subway station air-conditioning system, and it has strong coupling and nonlinear characteristics, resulting in difficulties to adjust the parameters of the PID controller. And it is impossible for PID to consider both passenger comfort and energy saving. In addition, due to the difficulty of system modeling and the huge computational effort of nonlinear optimization algorithms, it is difficult to realize the engineering application of intelligent control methods. Therefore, a model predictive control strategy is established for the subway platform air conditioning system to improve passengers comfort and achieve energy efficiency. Firstly, based on the heat and humidity load balance and the law of energy conservation, a prediction model for the thermal dynamic characteristics of the subway platform is developed. And then, an artificial neural network (ANN)-based predictive controller is designed, in which the weights and thresholds of the ANN controller are optimized online using the Lagrange-variational-based gradient descent training algorithm, to minimize the system cost function with small computational and storage needs. Simulation results show that the proposed predictive control strategy can shorten the system response time by 39.6% and reduce the energy consumption of the end fan by 73.39% compared with the PID control on the premise of meeting passenger comfort requirements.

Keywords: subway air conditioning system; model predictive control; mechanism modeling; nonlinear optimization algorithm; neural networks; building energy efficiency

收稿日期: 2022-06-18; 录用日期: 2022-10-10.

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: 关新平.

†通讯作者. E-mail: xiongyaxuan@bucea.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

0 引言

近年来,我国地铁轨道交通作为城市现代化的必要产物发展迅速,其能耗问题也愈发引人关注. 2021年,我国城轨交通总能耗213.1亿kW·h,同比增长23.6%^[1],其中,空调系统的能耗约占地铁车站总能耗的30%~40%^[2]. 由于地铁站台空调系统包括冷水机组、水泵和送风机等众多设备,且具有大滞后、非线性、耦合和时变等复杂特性,造成整个系统难以调控且建模困难. 目前,地铁空调系统大多采用PID控制进行送风量调节^[3],系统的非线性特性导致PID参数整定困难,仅在系统动态范围变化不大、扰动较小时才能取得较好的控制效果,并且PID只能实现局部回路控制,难以实现系统整体节能优化^[4]. 模型预测控制(model predictive control, MPC)能够克服干扰等不确定性因素的影响,且能够处理耦合、约束和滞后等问题,被视为解决地铁站台空调系统控制问题的有效方法,目前,已有学者将模型预测控制应用于建筑空调系统. 李卓阳等^[5]建立了由热量瞬态能量平衡方程组成的建筑制冷/制热能耗动态预测模型,并基于该动态模型提出了考虑建筑围护结构热动态特性的模型预测控制方法,用来最小化建筑能耗,同时保证用户的舒适度水平,实验验证了该方法在不同能效等级和不同建筑保温性能条件下的有效性. 陈炯德等^[6]建立了非线性自回归网络模型,用于预测VAV(variable air volume)系统的受控参数,并用粒子群优化算法(PSO)作为优化器实现系统预测控制. 实验结果表明,与基于PI控制器的定静压方法相比,MPC可以在满足室温控制精度的前提下实现风机节能控制. Lv等^[7]提出一种基于热电模拟自适应建筑模型的预测控制系统,该研究使用集总RC(热阻-热容)网络建立铁路车站动态模型,并根据系统采集的数据对建筑模型进行校正. 与PID控制和模型不具备自适应能力的预测控制相比,该研究能有效改善室内的热舒适性并降低能耗. Izawa等^[8]提出一种成本-舒适性粒子群优化预测控制策略,该方法建立了详细的非线性建筑模型,并直接考虑了用户对成本节约和热舒适性的偏好.

尽管目前已有许多学者研究了暖通空调系统模型预测控制策略,但是在实际工程中对模型预测控制的应用仍有大量技术问题亟待解决^[9]. 其一,建立精确的空调系统动态模型较为困难. 目前,针对空调系统的建模方法主要包括RC网络法建模、统计回归法建模、神经网络建模、支持向量机建模等,然而上述建模方法需要大量的输入输出数据,例如神经网络建模

需要覆盖空调系统整个动态范围的运行数据,这在实际工程中难以获得. 其二,模型预测控制需要多次求解有限时域的优化问题,而地铁站台空调系统具有非线性,为优化求解带来了困难. 变分法和动态规划法均可用于求解非线性优化问题,然而变分法本质上属于开环控制方法;动态规划可以实现反馈优化,但当状态量和控制量的维数较多时,求解哈密顿方程会发生“维数灾”问题^[10].

针对上述问题,本文提出一种地铁站台空调系统神经网络预测控制策略. 为了精确描述系统动态特性,并减少对数据的依赖,首先从热湿平衡的角度构建站台内温湿度变化与热湿负荷的数学关系,构建地铁站台热动态特性预测模型;然后利用能量守恒原理建立空气处理机组的动态模型. 在此基础上,为解决非线性优化求解难题,本文提出一种基于神经网络的预测控制滚动优化算法,采用多层前馈神经网络作为优化反馈控制器,将系统优化目标函数,即满足乘客舒适性的同时降低系统能耗,作为神经网络控制器的优化性能指标,将变分法与随机梯度下降法相结合,对神经网络控制器的权值和阈值进行在线滚动优化. 算法吸取了变分法计算量小、占用存储空间少的优点,并利用神经网络的自学习和自适应能力实现非线性系统反馈优化求解.

将本文所提出的预测控制策略用于武汉某地铁站空调系统的全局优化,实验结果表明,与PID控制相比,本文所提出的预测控制策略具有响应速度快、抗干扰能力强的优点,且能实现系统节能.

1 系统描述

1.1 研究对象

地铁站台空调系统是地铁环控系统的一部分,由大系统、小系统和水系统构成^[11]. 大系统为站台公共区的通风空调系统,主要负责公共区域的温度、湿度、CO₂浓度的调控;小系统为车站设备管理用房通风空调系统,为工作人员提供舒适的工作环境和适宜的设备运行条件;水系统用于为站台空气处理机组提供冷源. 由于小系统节能空间较小,本文选择大系统和水系统作为研究对象.

1.2 地铁站台空调系统运行原理

地铁站台空调系统由空气处理机组和制冷站组成,其结构如图1所示. 空气处理机组对送入站台的空气进行热湿处理,其主要设备包含末端风机、盘管表冷器和冷冻水阀;制冷站为地铁站台提供冷量,其主要设备包含冷冻水泵、冷水机组、冷却水泵、冷却塔等. 在空调系统末端混风进入空气处理机组后,在

盘管表冷器处与冷冻水进行热交换,使送风温度降至设定值,随后送入站台进行降温;冷冻水经过冷冻水泵加压送入末端空气处理机组盘管,与空气进行热交换后水温升高,然后被送回冷水机组;在冷水机组蒸发器侧,冷冻水通过制冷剂在蒸发器中的汽化吸热进行降温,再次被送入冷冻水管循环.热量随着制冷剂循环和冷却水循环,依次经过压缩机、冷凝器、冷却水泵和冷却塔后送入外界.

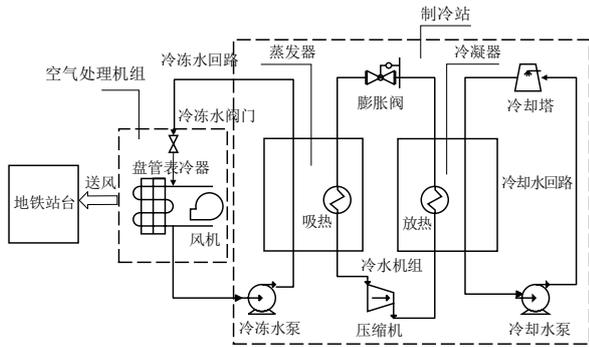


图1 地铁站台空调系统示意

由以上分析可以看出,影响送风温度的参数是冷冻水流量和冷冻水的送回水温差.本文研究的空调系统采用定冷冻水温差的方式运行,对送风温度调节主要依靠冷冻水流量的变化.另一方面,根据站台负荷进行送风量的调节,可以保证站台温湿度满足乘客的舒适性要求并维持环境系统稳定.故本文选择送风量和冷冻水流量作为预测控制的控制量.

2 地铁站台空调系统预测控制

2.1 优化目标

预测控制目标是在满足舒适性要求的前提下,尽可能降低水泵和风机的能耗,因此,本文将系统的优化性能指标定义为

$$J = \frac{1}{2}r_1 \sum_{k=t_1}^N \{(T_{in}[k] - T_{inset}[k])^2 + (T_s[k] - T_{sset}[k])^2 + (w_{in}[k] - w_{inset}[k])^2\} + \frac{1}{2}r_2 f_a^2[k] + \frac{1}{2}r_3 f_w^2[k]. \quad (1)$$

其中: $T_{in}[k]$ 、 $T_s[k]$ 、 $w_{in}[k]$ 为系统当前时刻的状态量, $T_{inset}[k]$ 、 $T_{sset}[k]$ 、 $w_{inset}[k]$ 为当前时刻系统状态量所设定的期望值, $f_a[k]$ 、 $f_w[k]$ 为系统的控制变量(送风量和冷冻水流量), r_1 、 r_2 、 r_3 为各影响变量在优化性能指标中所占的比重.

2.2 系统建模

模型预测控制的基础是构建被控对象预测模型.

2.2.1 空气处理机组预测模型构建

空气处理机组的结构如图2所示.

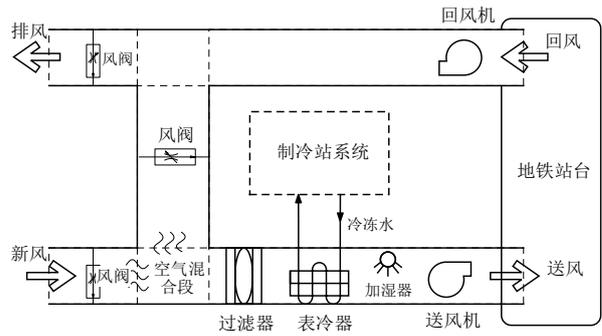


图2 空调末端空气处理机组运行方式

本文作以下假设: 1) 气流均匀; 2) 管道无漏气现象; 3) 冷冻水与送风空气在表冷器内进行完全热交换, 忽略热阻; 4) 地铁站台内温湿度分布均匀.

空气处理机组的冷却装置应满足能量守恒定律, 即

$$Q_1 + Q_2 + Q_3 = Q_4 + Q_5. \quad (2)$$

送风空气在送风管道单位时间内的温度变化所引起的冷量变化表示为

$$Q_1 = V_c \rho_a C_a \frac{dT_s}{dt}. \quad (3)$$

其中: V_c 为空气处理机组的总容积 (m^3), ρ_a 为空气密度 (kg/m^3), C_a 为送风温度下的空气比热容 ($J/(kg \cdot ^\circ C)$), $\frac{dT_s}{dt}$ 为单位时间内送风温度的变化量.

冷冻水与送风空气进行热交换所损失的冷量为

$$Q_2 = f_w \rho_w C_w \Delta T_c. \quad (4)$$

其中: f_w 为单位时间冷冻水流量 (m^3/s), ρ_w 为水的密度 (kg/m^3), C_w 为水的比热容 ($J/(kg \cdot ^\circ C)$), T_c 为冷冻水的送回水温差 ($^\circ C$). 本文研究定温差变流量的控制方式, 设定供回水温度分别为 $7^\circ C$ 和 $12^\circ C$, 温差为 $5^\circ C$.

根据经验, 新风和回风的混合比例为 $0.25:0.75$, 故送风空气含湿量变化所引起的冷量变化表示为

$$Q_3 = f_a \rho_a h_g (0.25w_{out} + 0.75w_{in} - w_s). \quad (5)$$

其中: f_a 为单位时间的送风量 (m^3/s), h_g 为水的潜热 (kJ/kg), w_{out} 为新风含湿量 (g/kg (干空气)), w_{in} 为回风含湿量 (g/kg (干空气)), w_s 为送风含湿量 (g/kg (干空气)).

新风和回风在空气处理机组中经处理后达到送风温度设定值时所需要的总冷量可用以下两式表示:

$$Q_4 = f_a \rho_a C_a (T_{in} - T_s), \quad (6)$$

$$Q_5 = 0.25 f_a \rho_a C_a (T_{out} - T_{in}). \quad (7)$$

其中: T_{in} 为空调回风温度 ($^\circ C$), T_{out} 为室外空气温度 ($^\circ C$).

综上所述,空气处理机组的动态数学模型为

$$\begin{aligned} & f_a \rho_a h_g (0.25 w_{\text{out}} + 0.75 w_{\text{in}} - w_s) + \\ & f_w \rho_w C_w \Delta T_c + V_c \rho_a C_a \frac{dT_s}{dt} = \\ & f_a \rho_a C_a (T_{\text{in}} - T_s) + 0.25 f_a \rho_a C_a (T_{\text{out}} - T_{\text{in}}). \end{aligned} \quad (8)$$

2.2.2 地铁站台环境预测模型构建

单位时间内,站台负荷变化等于空调送、排风引起的负荷变化与站内热源所导致的负荷变化之和,即

$$V_{\text{in}} \rho_a C_a \frac{dT_{\text{in}}}{dt} = f_a \rho_a C_a (T_s - T_{\text{in}}) + Q_{\text{in}}; \quad (9)$$

单位时间内,站台含湿量变化等于空调送、排风引起的湿量变化与站内散湿源引起的湿量变化之和,即

$$\rho_a V_{\text{in}} \frac{dw_{\text{in}}}{dt} = f_a \rho_a (w_s - w_{\text{in}}) + M_{\text{in}}. \quad (10)$$

其中: Q_{in} 为地铁站台冷负荷 (kW), M_{in} 为地铁站台湿负荷 (kg/s), V_{in} 为地铁站台空间的体积 (m^3).

为使模型的数学描述公式更简洁,作以下定义:

$$\begin{aligned} \alpha_1 &= \frac{1}{V_c}, \alpha_2 = \frac{1}{V_{\text{in}}}; \\ \beta_1 &= \frac{\rho_w c_w \Delta T_c}{c_a \rho_a V_c}, \beta_2 = \frac{1}{\rho_a V_{\text{in}}}; \\ \gamma_1 &= \frac{h_g}{c_a V_c}, \gamma_2 = \frac{1}{\rho_a V_{\text{in}} C_a}. \end{aligned} \quad (11)$$

定义控制量、状态量和干扰量如下:

$$\begin{aligned} u_1 &= f_a, u_2 = f_w; \\ x_1 &= T_s, x_2 = T_{\text{in}}, x_3 = w_{\text{in}}; \\ v_1 &= Q_{\text{in}}, v_2 = T_{\text{out}}, v_3 = w_s, \\ v_4 &= M_{\text{in}}, v_5 = W_{\text{out}}. \end{aligned} \quad (12)$$

经整理可得地铁站台空调系统预测模型为

$$\begin{aligned} \dot{x}_1 &= \alpha_1 u_1 (x_2 - x_1) + 0.25 \alpha_1 u_1 (v_2 - x_2) - \\ & \beta_1 u_2 - \gamma_1 u_1 (0.25 v_5 + 0.75 x_3 - v_3), \\ \dot{x}_2 &= \alpha_2 u_1 (x_1 - x_2) + \gamma_2 v_1, \\ \dot{x}_3 &= \alpha_2 u_1 (v_3 - x_3) + \beta_2 v_4. \end{aligned} \quad (13)$$

2.2.3 预测模型离散化

本文采用一阶后向差分代替状态方程中的微分,即

$$\frac{dx(t)}{dt} = \frac{\{x(kT) - x[(k-1)T]\}}{T}. \quad (14)$$

由式(9)~(14)可得地铁空调系统离散化模型为

$$\begin{aligned} x_1[k+1] &= T\{\alpha_1 u_1[k](x_2[k] - x_1[k]) + \\ & 0.25 \alpha_1 u_1[k](v_2[k] - x_2[k]) - \\ & \beta_1 u_2[k] - \gamma_1 u_1[k](0.25 v_5[k] + \\ & 0.75 x_3[k] - v_3[k])\} + x_1[k], \end{aligned}$$

$$\begin{aligned} x_2[k+1] &= \\ & T\{\alpha_2 u_1[k](x_1[k] - x_2[k]) + \gamma_2 v_1[k]\} + x_2[k], \\ x_3[k+1] &= \\ & T\{\alpha_2 u_1[k](v_3[k] - x_3[k]) + \beta_2 v_4[k]\} + x_3[k]. \end{aligned} \quad (15)$$

2.3 神经网络负荷预测模型

空调系统逐时负荷的准确预测是保证地铁站台温度控制效果的前提之一^[12]. 目前,针对空调负荷预测的方法主要有时间序列法、回归分析法、支持向量机预测法、神经网络预测法等^[13]. 综合分析以上预测方法,神经网络预测法在拟合非线性特性、提高预测精度等方面更具优势,且无需考虑繁杂的建模步骤,因此,本文选用BP神经网络进行负荷预测.

在实际运行工况中,影响地铁站台空调负荷的因素众多,包括站台内外环境、客流量、列车产热量、隧道换热、站内照明设备和机械设备散热,以及建筑围护结构本身产生的影响等. 对于已建设完成的地铁站,建筑围护结构的参数在地铁运营期间变化不大,且常开照明设备形成的负荷基本稳定,因此在模型输入中不考虑这两类变量. 此外,地铁口与室外环境相接,各环境参数受室外条件的影响明显,故将此类数据作为模型输入. 另一方面,地铁车站空调负荷具有明显的时间规律,故本文将带有时间特征的历史负荷数据作为模型输入. 本文仅考虑配置全屏蔽门系统的地铁车站空调系统,因此,可以忽略隧道换热和列车产生热量对负荷的影响.

综上所述,本文选定如下输入参数: 1) 室外温度; 2) 室外湿度; 3) 同一天前一时刻负荷; 4) 前一天同一时刻负荷; 5) 一周前同一时刻负荷. 神经网络的输出参数确定为地铁站台下一时刻的负荷.

现已证明三层神经网络能够逼近任意一个非线性过程^[14], 故本文采用三层神经网络进行负荷预测. 根据工程实践可知,神经网络模型的隐含层神经元个数会直接影响预测的精确性. 目前尚没有一种明确的方法能确定隐含层的个数,实践中,可基于下式,采用试凑法^[15]选择误差最小的神经元个数:

$$m = \sqrt{n+l} + \alpha. \quad (16)$$

其中: n 为输入层神经元个数, l 为输出层神经元个数, m 为隐含层神经元个数, α 是范围1~10的常数.

本文构建由5个输入层神经元、11个隐含层神经元和1个输出层神经元组成的神经网络负荷预测模型. 基础的BP神经网络存在收敛速度慢、易陷入局部极值和易过拟合等缺点^[16]. 为改进其缺点,人们提出了动量法、变尺度法、变步长法、Levenberg-

Marquardt (L-M) 算法^[17]和贝叶斯正规化算法^[18]等. 针对含有几百个权值的中小型神经网络, 贝叶斯正规化方法可有效提高神经网络的泛化能力^[19], 因此, 本文选择贝叶斯正规化方法对负荷预测模型进行训练.

2.4 神经网络非线性预测控制

2.4.1 神经网络预测控制滚动优化算法

要实现模型预测控制, 还需要研究易于工程实现的滚动优化算法.

地铁站台空调系统为多输入多输出非线性系统, 在预测控制过程中, 其一般表现形式为

$$x[k+1] = f(x[k], u[k], k), \quad x[0] = x_0. \quad (17)$$

其中: $x[k]$ 为 k 时刻 n 维的状态变量, $x[k] = [x_1(k), x_2(k), \dots, x_n(k)]$; $u[k]$ 为 k 时刻 r 维的控制变量, $u[k] = [u_1(k), u_2(k), \dots, u_r(k)]$; k 为控制系统的当前时刻, 其取值为 $0, 1, \dots, n$; x_0 为初始状态时系统的状态量.

本文设定神经网络控制器的基本表达式为

$$u[k] = g(x[k], x^*[k+1], W). \quad (18)$$

其中: $x^*[k+1]$ 为状态量的期望值; W 为神经网络控制器的权值矩阵; $u[k]$ 为神经网络控制器的输出值, 即寻优控制量. 本文建立单隐含层的神经网络控制器进行动态寻优, 其输入参数为 $x[k]$ 、 $x^*[k+1]$ 和阈值对应的 -1 , 输出参数为 $u[k]$.

系统的优化目标函数如下:

$$J = \phi_{t_1+M}(x[t_1+M], t_1+M) + \sum_{k=t_1}^{t_1+M-1} L(x[k+1], u[k], k). \quad (19)$$

其中: M 为预测时域, t_1 为预测控制的初始时刻, $\phi_{t_1+M}(x[t_1+M], t_1+M)$ 为末值性能指标, $L(x[k+1], u[k], k)$ 为预测过程中的性能指标.

本文以变分法为基础, 结合系统的状态方程以及优化性能指标构造哈密顿函数, 可将有约束条件的最优性能指标求解转化为无约束条件的求解, 其哈密顿函数为

$$H(x, x^*, u, W, \lambda, \gamma, k) = L(x[k+1], u[k], k) + \lambda^T[k+1]f(k) + \gamma^T[k]g(k, W). \quad (20)$$

其中: λ, γ 为拉格朗日乘子向量, $f(\cdot)$ 为预测模型的状态方程, $g(\cdot)$ 为神经网络控制器的状态方程.

通过引入拉格朗日乘子和哈密顿函数, 可以得出包含约束的增广性能指标函数为

$$J = \phi_{t_1+M}(x[t_1+M], t_1+M) +$$

$$\sum_{k=t_1}^{t_1+M-1} \{L(x[k+1], u[k], k) + \lambda^T[k+1](f(k) - x[k+1]) + \gamma^T[k](g(k, W) - u[k])\}. \quad (21)$$

将哈密顿函数代入增广泛函中, 可得

$$J = \phi_{t_1+M}(x[t_1+M], t_1+M) - \lambda^T[t_1+M]x[t_1+M] + \lambda^T[t_1]x[t_1] + \sum_{k=t_1}^{t_1+M-1} \{H(k) - \lambda^T[k]x[k] - \gamma^T[k]u[k]\}. \quad (22)$$

对优化性能指标求变分, 可得

$$\delta J = \left\{ \frac{\partial \phi_{t_1+M}(x[t_1+M], t_1+M)}{\partial x(t_1+M)} - \lambda[t_1+M] \right\}^T \partial x[t_1+M] + \lambda^T[0] \partial x(0) + \sum_{k=t_1}^{t_1+M-1} \left\{ \left(\frac{\partial H(k)}{\partial x[k]} - \lambda[k] \right)^T \partial x[k] + \left(\frac{\partial H(k)}{\partial u[k]} - \gamma[k] \right)^T \partial u[k] + \frac{\partial H(k)}{\partial W} \partial W \right\}. \quad (23)$$

要使目标函数的变分在任意的控制量和状态量的情况下均为零, 需满足以下条件:

$$\lambda^T[k] = \frac{\partial H(k)}{\partial x[k]}, \quad (24)$$

$$\gamma^T[k] = \frac{\partial H(k)}{\partial u[k]}, \quad (25)$$

$$\lambda^T[t_1+M] = \frac{\partial \phi_{t_1+M}(x[t_1+M], t_1+M)}{\partial x[t_1+M]}, \quad (26)$$

$$\sum_{k=t_1}^{t_1+M-1} \frac{\partial H}{\partial W} = 0. \quad (27)$$

其中: 式(24)和(25)是哈密顿正则方程, 式(26)是系统边界条件, 式(27)是系统优化条件.

在满足式(24)~(27)的基础上, 本文基于随机梯度下降法更新神经网络控制器的权值和阈值, 有

$$\Delta W = -\mu \sum_{k=t_1}^{t_1+M-1} \frac{\partial g(k, W)}{\partial W} \gamma^T[k], \quad W = W + \Delta W, \quad (28)$$

其中 μ 为学习率. 在神经网络控制器收敛后, 泛函(22)的变分 $\delta J = 0$, 即此刻系统优化目标函数最小.

2.4.2 预测控制方案

图3为地铁站台空调预测控制系统框图, 该系统由地铁站台空调系统(被控对象)、被控对象预测模型、神经网络控制器和负荷预测模型组成. 首先, 被

控对象预测模型从 k 时刻起利用当前时刻的状态量 $x[k]$ 和控制量 $u[k]$ 预测未来时刻的状态量 $\hat{x}[k+i]$;其次,利用负荷预测模型预测下一时刻的地铁站台负荷值 $Q[k+1]$;然后,将神经网络控制器作为系统的优化反馈控制器,将负荷预测值 $Q[k+1]$ 、未来状态量期望值 $x^*[k+i]$ 、被控对象反馈的状态量 $x[k]$ 、状态量预测

值 $\hat{x}[k+i]$ 和系统的扰动量 $v[k]$ 作为控制器输入,采用上述神经网络预测控制算法在有限预测时域内对控制量进行滚动优化,输出量即为最优控制量序列;最后,将最优控制量作用于地铁站台空调系统,获得真实状态量 $x[k+1]$,并与状态量预测值 $\hat{x}[k+i]$ 作比较,由此获得预测误差并对预测模型进行反馈校正。

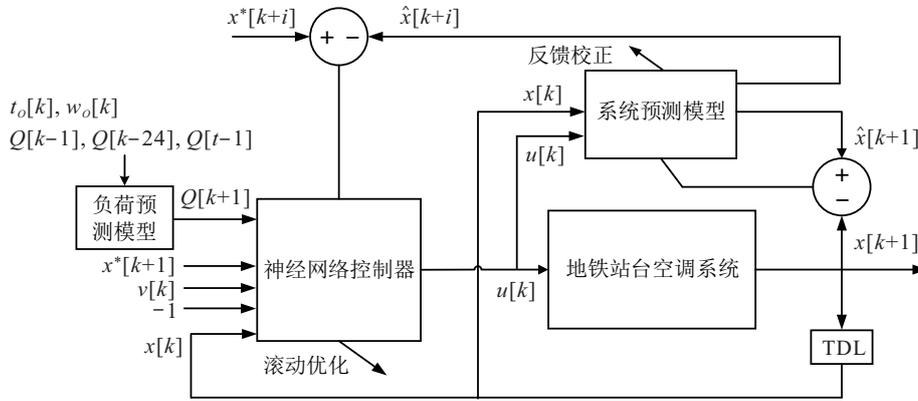


图3 系统神经网络预测控制结构

本文将系统状态量的初始值设为:送风温度 21°C ,站台温度 31°C ;系统状态量的期望值设为:送风温度 18°C ,站台温度 26°C 。

利用神经网络控制器进行预测控制的步骤如下:

step 1: 初始化神经网络控制器的各项参数. 对初始状态量 $x[0]$ 、初始权值 W 进行设定,确定状态量的期望值 $x^*[k+i]$ 和控制周期 P 以及预测时域 M ,选定控制器的学习率 μ (本文选择0.025)。

step 2: 将状态量 $x[k]$ 、状态量期望值 $x^*[k+1]$ 、扰动变量 $v[k]$ 和 -1 一同输入神经网络控制器中进行计算,得出当前时刻的控制量 $u[k]$ 。

step 3: 将控制量 $u[k]$ 、当前时刻的状态量 $x[k]$ 和扰动变量 $v[k]$ 输入到系统的预测模型中,得到下一时刻状态量的预测值 $\hat{x}[k+1]$ 。

step 4: 计算并获得一个预测时域内各时刻的控制量和状态量. 在同一个预测时域内保持神经网络控制器的权值 W 不变,将上一步获得的 $\hat{x}[k+1]$ 、下一时刻状态量期望值 $x^*[k+2]$ 、当前时刻的扰动量 $v[k+1]$ 和阈值对应的 -1 再次输入到神经网络控制器中,获得控制量 $u[k+1]$;再将 $u[k+1]$ 、 $x[k+1]$ 、 $v[k+1]$ 输入预测模型中,得到新的预测状态量 $\hat{x}[k+2]$ 。通过step 4的不断重复,直至一个预测时域完成。

step 5: 根据2.4.1节推导出的正则方程(24)和(25),从后向前计算拉格朗日乘子向量 $\lambda[k]$ 和 $\gamma[k]$ 。

step 6: 根据上述计算出的拉格朗日乘子 $\gamma[k]$,通过式(28),基于随机梯度下降法对神经网络控制器权

值(含阈值)进行修正。

step 7: 重复step 4~step 6,对权值进行一个预测时域内的修正,直至 $\Delta W = 0$ 。

step 8: 进入下一采样周期,再次循环step 2~step 7,得到各个时刻的控制量最优解以及整个系统状态变化的轨迹。

假设共有 p 个状态量、 q 个控制量、 n_w 个预测控制器的权值,于是在上述整个寻优过程中一共要进行 $2q(p+q) + n_w(p+2)M$ 步运算,占用 $(p+q)M + 2n_w$ 个存储单元. 由此可得,本文所提出的滚动优化算法计算量和占用的储存单元数与 q 、 p 、 n_w 呈线性关系,而动态规划算法运行计算量所需要的储存单元数与 q 、 p 、 n_w 呈指数关系,因此,本文提出的神经网络预测控制滚动优化算法计算量小,占用存储空间少。

3 实验研究

本文针对武汉某地铁站空调系统的实测数据进行控制策略仿真实验。

3.1 神经网络负荷预测模型训练

3.1.1 数据采集及预处理

本文选取武汉某地铁站2018年和2019年空调季的实测数据进行训练,采样周期为5 min,共采集28 582条数据,这些数据是由该地铁站空调系统监控管理平台提供. 本文将前27 570个数据作为训练集,后1 012个数据作为测试集。

为消除实测数据中的噪声,本文采用中位值平均滤波法对原始数据进行处理^[20]。另外,由于神经网络

的输入输出变量代表的含义不同,其单位和量级差别很大,导致神经网络模型训练时间过长,甚至出现无法收敛的情况,本文采用线性函数转换方法^[21]对滤波后的数据进行归一化和反归一化处理。

3.1.2 负荷预测性能分析

图4是模型的测试结果. 由图4可知,预测负荷能够较好地跟踪实际负荷的变化,相对误差为4.23%。

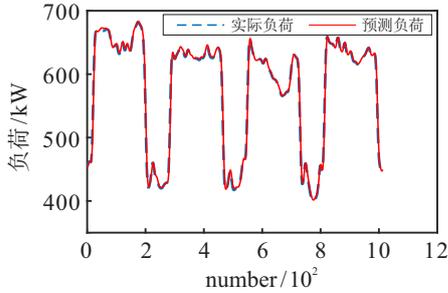


图4 预测负荷与实际负荷对比

3.2 神经网络控制器预训练

由于神经网络预测控制的效果对控制器的初始权值敏感,有必要对神经网络控制器进行预训练,以获得合适范围内的初始权值。

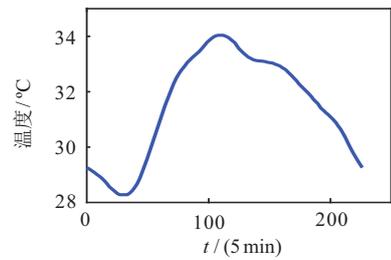
本文选取武汉某地铁站2019年7月的实测运行数据进行预训练,采样周期为5 min. 样本数据被分为2个不同的数据集,用于神经网络控制器的预训练和测试,占比分别为80%和20%。最后,将训练好的神经网络权值作为下一步控制器滚动优化的初始权值。

3.3 实验结果分析

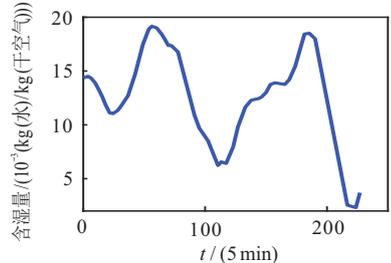
预测控制实验按照2.4.2所述步骤进行. 在实际的地铁运营中站台内的干扰因素较多,为模拟系统干扰,本文将实测的干扰变量(图5)编入程序中。

本文通过设定优化性能指标中的权重系数来分析不同参数对结果的影响,权重占比越大,对所控制的性能指标要求越严格. 这里采用 $r_1:r_2:r_3$ 为0.2:0.4:0.4(以下简称权重1)和0.6:0.2:0.2(以下简称权重2)进行仿真实验结果分析. 图6和图7为在不同权重下的送风量、冷冻水流量变化曲线。

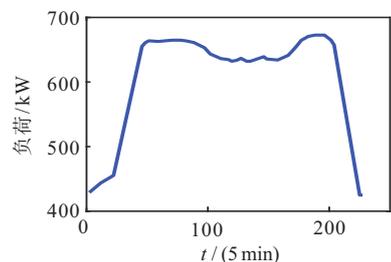
由图6可知,在两种权重目标函数下,权重1的送风量变化更快,随后两者在系统状态量达到设定值后均趋于平稳,但仍不断调节以保证站台内的温湿度稳定在设定值上. 由图7可知,由于目标函数分配权重的不同,导致冷冻水流量的初始变化出现差异,但总体趋势相同. 运行前期较大的冷冻水流量使送风温度快速达到设定值,在系统各项状态量达到设定值后冷冻水流量变化逐渐趋于平缓,但仍处于动态变化以克服干扰因素对地铁站台环境的影响。



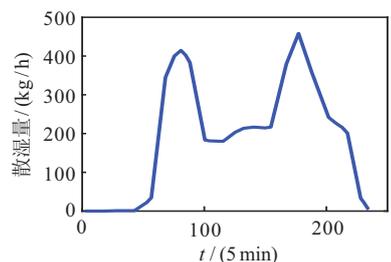
(a) 实测室外温度变化曲线



(b) 实测室外含湿度变化曲线



(c) 站台负荷变化曲线



(d) 站台乘客散湿量变化曲线

图5 干扰变量曲线

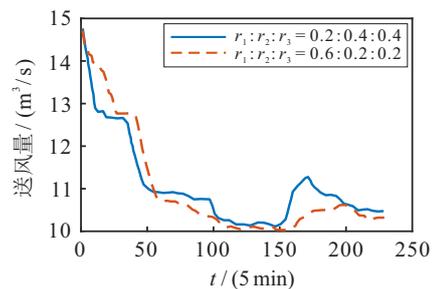


图6 不同权重比例系数下送风量的变化曲线

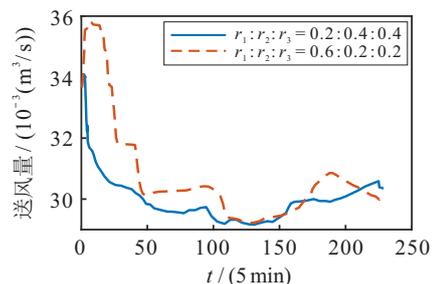


图7 不同权重比例系数下冷冻水流量的变化曲线

图8和图9为不同权重下的系统状态量的变化曲线. 由图8和图9可知,在不同权重的预测控制下,即使存在众多持续干扰,系统均能保持稳定. 综上分

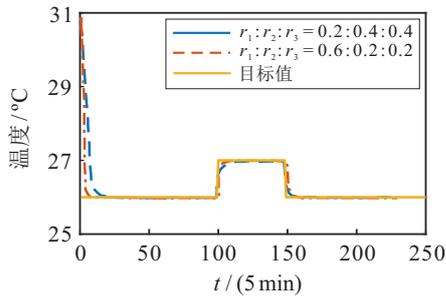


图8 不同权重比例系数下站台温度变化曲线

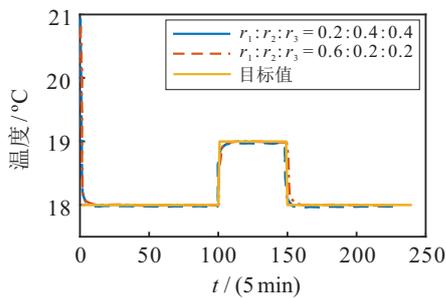


图9 不同权重比例系数下送风温度变化曲线

析,神经网络预测控制方法具有较强的抗干扰能力,当系统设定值发生变化时,状态量能快速跟踪设定值的变化. 本文认为,在两种权重系数的控制方式下,均能使地铁站台环境在较短时间内达到设定值时,可以优先考虑更节能的控制方式.

3.4 神经网络预测控制与PID控制对比实验

为了进行对比分析,本文利用同样的数学模型进行PID控制的仿真实验. 由于PID控制只能实现单回路控制,这里将空调系统分为冷冻水流量-送风温度以及送风量-站台温度两个回路. 本文分别采用神经网络算法^[22]和PSO算法^[23]对PID参数进行整定,整定后的PID控制参数如表1所示.

图10和图11为PID控制与神经网络预测控制效果对比. 可以看出:在仿真实验期间,神经网络预测控制响应时间短且基本无超调;而PID控制方法虽然也能跟踪目标值的变动,但响应时间长且系统振荡明显. 因此,神经网络预测控制方法的抗干扰能力更强,在不同干扰下仍能保持系统的稳定,提高了站台环境的舒适性,而PID控制则使系统在干扰下产生了不同程度的波动.

表1 PID控制参数

送风温度	冷冻水流量-送风温度模型	站台温度	送风量-站台温度模型
18°C	PSO: $K_p = 0.0057, K_i = 0.0038, K_d = 0.000218$	26°C	PSO: $K_p = 3.1447, K_i = 1.8808, K_d = 0.000152$
	神经网络: $K_p = 0.0036, K_i = 0.0091, K_d = 0.000127$		神经网络: $K_p = 4.3215, K_i = 1.2533, K_d = 0.000359$
19°C	PSO: $K_p = 0.0039, K_i = 0.0028, K_d = 0.000145$	27°C	PSO: $K_p = 0.0145, K_i = 6.9211, K_d = 0.000853$
	神经网络: $K_p = 0.0021, K_i = 0.0063, K_d = 0.000093$		神经网络: $K_p = 0.0493, K_i = 4.8921, K_d = 0.001359$

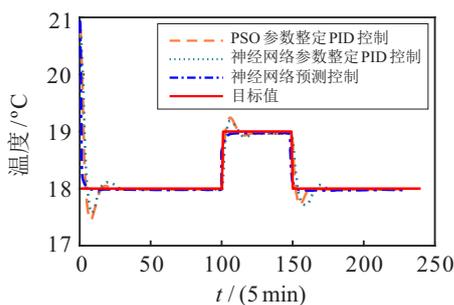


图10 不同控制下送风温度变化曲线

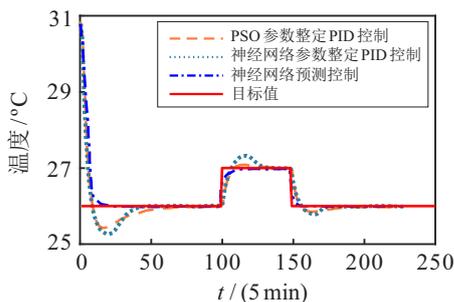


图11 不同控制下站台温度变化曲线

图12显示了不同控制方法下冷冻水流量的变化. 与PID控制相比,在神经网络预测控制下的冷冻水流量普遍更小. 由于水阀开度与冷冻水流量呈正相关,在神经网络预测控制下的水阀开度更小,较小的水阀开度可有效减少制冷站端水泵的能耗.

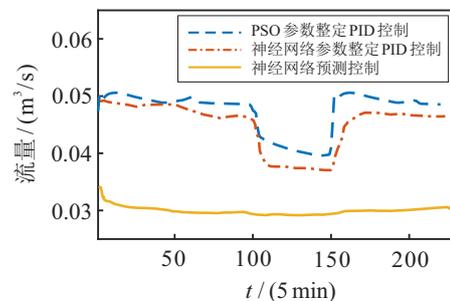


图12 不同控制下冷冻水流量变化曲线

图13给出了不同控制方法下送风量的变化曲线,由该图可知,神经网络预测控制的送风量始终小于PID控制的送风量. 风机消耗功率与送风量的关系可由风机相似定律得出,即

$$\frac{P_{\text{fan_PID}}}{P_{\text{fan_MPC}}} = \left| \frac{f_{a_PID}}{f_{a_MPC}} \right|^3. \quad (29)$$

其中: $P_{\text{fan_PID}}$ 为PID控制下的风机消耗功率(kW), $P_{\text{fan_MPC}}$ 为神经网络预测控制下的风机消耗功率(kW), f_{a_PID} 为PID控制下的送风量(m^3/s), f_{a_MPC} 为神经网络预测控制下的送风量(m^3/s).

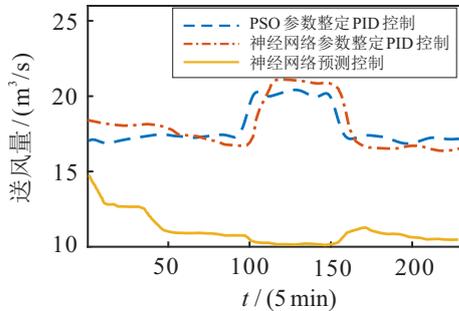


图13 不同控制下送风量变化曲线

神经网络预测控制节省的风机能耗为

$$\Delta P = P_{\text{fan_PID}} - P_{\text{fan_MPC}} = P_{\text{fan_PID}} \left(1 - \left| \frac{f_{a_MPC}}{f_{a_PID}} \right|^3 \right). \quad (30)$$

由式(30)可知,当PID控制下送风量平均值为 $17.91 \text{ m}^3/\text{s}$ 和神经网络预测控制下送风量平均值为 $11.52 \text{ m}^3/\text{s}$ 时,神经网络预测控制与PID控制相比,末端风机能耗可节省73.39%。

4 结论

地铁站台空调系统因强耦合、大时滞、多干扰等复杂特性,导致PID控制难以取得良好的效果,无法兼顾乘客舒适性和系统能耗最优。而由于系统复杂且具有非线性,建模困难,非线性优化算法对计算量和存储空间有较高的要求,导致目前缺少智能控制算法在实际地铁站台空调系统中的应用。为此,本文提出了一种地铁站台空调系统预测控制策略。首先,根据热湿负荷平衡和能量守恒定律建立了地铁站台热动态特性预测模型;其次,用神经网络作为优化反馈控制器,将系统优化目标函数,即满足乘客舒适性的同时降低系统能耗,作为神经网络控制器的优化性能指标,采用变分法和随机梯度下降法相结合的算法,对神经网络控制器的权值和阈值进行在线滚动优化,解决了动态规划算法易造成“维数灾”的问题,并克服了传统变分法无法实现反馈优化而易受干扰影响的情况;最后,通过对地铁站台空调系统的仿真实验结果表明,本文所提出的预测控制策略在外界干扰下,能够使系统状态量在短时间内达到目标值,与PID控制相比,系统响应时间减少约39.6%,末端风机能耗降低约71.1%,且具有更好的动态和稳态性

能。本文下一步将研究优化目标函数权重自适应调节方法,以进一步提高控制系统的自适应能力和鲁棒性。

参考文献(References)

- [1] 中国城市轨道交通协会. 城市轨道交通2021年度统计和分析报告[J]. 城市轨道交通, 2022(4): 35-37. (China Association of Metros. Urban rail transit 2021 annual statistics and analysis report[J]. China Metro, 2022(4): 35-37.)
- [2] Yin H, Yang C Y, Yi L Z, et al. Ventilation and air conditioning system of deep-buried subway station in sub-tropical climates: Energy-saving strategies[J]. Applied Thermal Engineering, 2020, 178: 115555.
- [3] Maddalena E T, Lian Y Z, Jones C N. Data-driven methods for building control—A review and promising future directions[J]. Control Engineering Practice, 2020, 95: 104211.
- [4] 魏东, 焦焕炎, 冯浩东. 基于负荷预测的冷冻站系统非线性预测控制[J]. 控制理论与应用, 2021, 38(10): 1619-1630. (Wei D, Jiao H Y, Feng H D. Nonlinear predictive control of refrigeration system based on load forecasting[J]. Control Theory & Applications, 2021, 38(10): 1619-1630.)
- [5] 李卓阳, 靳小龙, 贾宏杰, 等. 考虑建筑物热动态特性的暖通空调模型预测控制方法[J]. 中国电机工程学报, 2020, 40(12): 3928-3940. (Li Z Y, Jin X L, Jia H J, et al. Model predictive control method for the HVAC system of buildings considering the thermal dynamic characteristics of the envelope[J]. Proceedings of the CSEE, 2020, 40(12): 3928-3940.)
- [6] 陈炳德, 王子轩, 姚晔, 等. 变风量空调系统用非线性模型预测控制方法研究[J]. 制冷学报, 2019, 40(6): 62-69. (Chen J D, Wang Z X, Yao Y, et al. Nonlinear model predictive control for a variable air volume air-conditioning system[J]. Journal of Refrigeration, 2019, 40(6): 62-69.)
- [7] Lv R X, Yuan Z Y, Lei B, et al. Model predictive control with adaptive building model for heating using the hybrid air-conditioning system in a railway station[J]. Energies, 2021, 14(7): 1996.
- [8] Izawa A, Fripp M. Multi-objective control of air conditioning improves cost, comfort and system energy balance[J]. Energies, 2018, 11(9): 2373.
- [9] Afram A, Janabi-Sharifi F. Theory and applications of HVAC control systems—A review of model predictive control (MPC)[J]. Building and Environment, 2014, 72:

- 343-355.
- [10] Song B. Neural network model based control of nonlinear flexible link systems[D]. West Lafayette: Purdue University, 1999.
- [11] Yu Y Z, You S J, Zhang H, et al. A review on available energy saving strategies for heating, ventilation and air conditioning in underground metro stations[J]. Renewable and Sustainable Energy Reviews, 2021, 141: 110788.
- [12] Su X, Huang Y X, Wang L, et al. Operating optimization of air-conditioning water system in a subway station using data mining and dynamic system models[J]. Journal of Building Engineering, 2021, 44: 103379.
- [13] Wang L, Lee E W M, Yuen R K K. Novel dynamic forecasting model for building cooling loads combining an artificial neural network and an ensemble approach[J]. Applied Energy, 2018, 228: 1740-1753.
- [14] Kawashima M. Artificial neural network backpropagation model with three-phase annealing developed for the building energy predictor shootout[R]. Atlanta: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., 1994.
- [15] Islam M J, Senadeera W, Brooks P, et al. An artificial neural network (ANN) model for predicting biodiesel kinetic viscosity as a function of temperature and chemical compositions[C]. The 20th International Congress on Modelling and Simulation. Brisbane, 2013: 1561-1567.
- [16] Afram A, Janabi-Sharifi F, Fung A S, et al. Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system[J]. Energy and Buildings, 2017, 141: 96-113.
- [17] Ng B C, Darus I Z M, Jamaluddin H, et al. Application of adaptive neural predictive control for an automotive air conditioning system[J]. Applied Thermal Engineering, 2014, 73(1): 1244-1254.
- [18] Huang H, Chen L, Hu E. A neural network-based multi-zone modelling approach for predictive control system design in commercial buildings[J]. Energy and Buildings, 2015, 97: 86-97.
- [19] Saini L M. Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks[J]. Electric Power Systems Research, 2008, 78(7): 1302-1310.
- [20] 郑涛, 石秀华, 许晖. 数字滤波新方法尝试与验证[J]. 测控技术, 2004, 23(4): 19-20.
(Zheng T, Shi X H, Xu H. New method and its feasibility analysis to digital filtering[J]. Measurement & Control Technology, 2004, 23(4): 19-20.)
- [21] Govindugari D R, McGoveran D O. Method and architecture for data transformation, normalization, profiling, cleansing and validation[P]. US: 20040083199. 2004-04-29.
- [22] 胡黄水, 赵思远, 刘清雪, 等. 基于动量因子优化学习率的BP神经网络PID参数整定算法[J]. 吉林大学学报: 理学版, 2020, 58(6): 1415-1420.
(Hu H S, Zhao S Y, Liu Q X, et al. BP neural network PID parameter tuning algorithm based on momentum factor optimized learning rate[J]. Journal of Jilin University: Science Edition, 2020, 58(6): 1415-1420.)
- [23] 王唯一, 张明泉, 杨帆, 等. 基于粒子群算法的PID调速系统的研究[J]. 控制工程, 2015, 22(6): 1082-1086.
(Wang W Y, Zhang M Q, Yang F, et al. Study of PID speed controller based on particle swarm optimization[J]. Control Engineering of China, 2015, 22(6): 1082-1086.)

作者简介

魏东(1968—),女,教授,博士,从事预测控制、建筑设备节能控制等研究, E-mail: weidong@bucea.edu.cn;

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;

安硕(1995—),女,硕士生,从事建筑节能与安全监控的研究, E-mail: 2945508213@qq.com;

熊亚选(1977—),男,教授,博士,从事暖通空调系统节能优化、绿色智能建筑等研究, E-mail: xiongyaxuan@bucea.edu.cn.