

## 基于负荷预测的冷冻站系统非线性预测控制

魏东<sup>1,2†</sup>, 焦焕炎<sup>1</sup>, 冯浩东<sup>1</sup>

(1. 北京建筑大学 电气与信息工程学院, 北京 100044; 2. 北京市建筑大数据智能处理重点实验室, 北京 100044)

**摘要:** 我国建筑能耗约占社会总能耗的30%, 其中集中式暖通空调系统能耗约占一半以上. 为提高节能效率, 本文提出基于负荷预测的空调冷冻站系统神经网络预测控制策略. 本文采用神经网络作为优化反馈控制器, 将满足负荷需求和系统能效比需求作为优化目标, 将变分法和随机梯度下降法相结合, 对神经网络权值进行滚动优化, 既能解决传统变分法由开环控制引发的对随机干扰和不确定性敏感的问题, 又可避免基于动态规划的非线性优化算法的“维数灾”问题. 本文以北京某国企科研楼的空调系统为研究对象, 实验结果表明, 本文所提出的神经网络预测控制策略与PID控制算法相比, 系统总能耗节省约8.57%, 并且在控制过程中能够克服各种变化和不确定性因素的影响, 具有更好的动态和稳态性能, 且该算法占用存储空间适中、计算量小, 易于工程实现.

**关键词:** 模型预测控制; 神经网络; 负荷预测; 空调冷冻站系统; 建筑节能

**引用格式:** 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. 控制理论与应用, 2021, 38(10): 1619 – 1630

DOI: 10.7641/CTA.2021.00651

## Nonlinear predictive control of refrigeration system based on load forecasting

WEI Dong<sup>1,2†</sup>, JIAO Huan-yan<sup>1</sup>, FENG Hao-dong<sup>1</sup>

(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)

**Abstract:** Building energy consumption accounts for about 30% of the total social energy consumption in China, among which the energy consumption of heating, ventilation and air-conditioning systems accounts for more than half. In this paper, a neural network model predictive control strategy based on load forecasting is proposed for an air-conditioning refrigeration system to improve its energy efficiency. The neural network is used as the optimal feedback controller, and the load demand and energy efficiency ratio demand of the system are taken as the optimization objectives. By combining the variational method with the stochastic gradient descent method, the weights of the neural network are optimized, which can not only solve the problem of sensitivity to random disturbances and uncertainties caused by the open-loop control of the traditional variational method, but also avoid the “dimension disaster” problem of the traditional nonlinear optimization algorithm based on dynamic programming. In this paper, the air-conditioning system of a research building in Beijing is taken as the research object. The experimental results show that, compared with PID control algorithm, the proposed neural network predictive control strategy, which has better dynamic and steady-state performance, can save about 8.57% of the total energy consumption of the system and overcome the influence of various changes and uncertainties in the control process. Moreover, the algorithm occupies moderate storage space and has small amount of calculation, which is easy to be implemented in engineering.

**Key words:** model predictive control; neural networks; load forecasting; air-conditioning refrigeration systems; building energy efficiency

**Citation:** WEI Dong, JIAO Huanyan, FENG Haodong. Nonlinear predictive control of refrigeration system based on load forecasting. *Control Theory & Applications*, 2021, 38(10): 1619 – 1630

收稿日期: 2020-09-26; 录用日期: 2021-02-16.

†通信作者. E-mail: weidong@bucea.edu.cn; Tel.: +86 13621335206.

本文责任编辑: 施阳.

北京市属高校高水平创新团队建设计划项目(IDHT20190506), 北京市教委科技计划重点项目(KZ201810016019)资助.

Supported by the High Level Innovation Team Construction Project of Beijing Municipal Universities (IDHT20190506) and the Key Science and Technology Plan Project of Beijing Municipal Education Commission of China (KZ201810016019).

## 1 引言

近年来,建筑物能源消耗处于不断上升的趋势.在中国,建筑能耗约占社会总能耗的30%<sup>[1]</sup>.集中式暖通空调(HVAC)系统是建筑物重要的组成部分之一,其能耗约占建筑能耗总量的40%~50%<sup>[2-3]</sup>.由于空调冷冻站系统拥有众多设备,包括冷水机组、水泵和冷却塔等,使得系统结构复杂,具有非线性、大滞后以及时变等复杂特性,且冷冻水回路和冷却水回路间存在耦合关系,造成传统PID控制方法设计和调试困难,因此系统控制效果不佳.本文通过调研发现,由于参数整定困难,造成PID控制在空调系统负荷变化时极易产生振荡,所以目前90%以上的集中式空调系统采用手动控制,造成能源的大量浪费.即使采用自动控制的系统,也没有把冷冻站系统看成一个整体,只针对局部设备进行控制,通常达不到理想的节能效果.已有研究表明,智能控制方法具有自适应、自学习和自协调能力,可以对复杂系统进行全局控制,提升空调系统的性能和节能效果.其中,模型预测控制(MPC)被视为一种有效的方法,它可以解决耦合和约束问题,并基于建筑动态特性,在保证人员较高舒适度的前提下,得到一组最优控制规律,从而最大限度地降低系统能耗<sup>[4]</sup>.Hovgaard等人<sup>[5]</sup>提出了一种适用于商用多区域制冷系统的模型预测控制策略,该方法通过采用快速凸二次规划求解器进行迭代,具有较高的实时运行速度.Picard等人<sup>[6]</sup>系统地研究了建筑物获得最佳控制性能所需的控制器模型复杂度,并将建筑模型线性化,得到线性时不变状态空间模型,然后用模型预测控制策略来提升系统的性能.Huang<sup>[7]</sup>利用MPC控制变风量空调系统中的区域温度和风阀位置.与PI控制器相比,基于模型预测控制的送风量控制器具有更好的瞬态响应性能,并且在风管压力扰动下具有更强的鲁棒性.为了达到所需的区域温度,Karlsson等人<sup>[8]</sup>使用MPC方法控制地板供暖系统的供水温度.其中,预测控制器利用天气预报和建筑物的死区时间,始终将室温保持在所需的范围内.Yang等人<sup>[9]</sup>提出了一种新的用于室外空气系统的模型预测控制策略.其中,预测模型采用状态空间模型捕捉建筑热力学和热舒适性特性,进行建筑响应预测.随后,作者采用多目标成本函数,在满足预测平均投票率(PMV)和相对湿度的约束条件下,对建筑能耗和热舒适性进行了优化.

尽管目前相关领域学者已经进行了大量的研究工作,工程中对模型预测控制技术的应用仍处于初级阶段.首先,模型预测控制的实现需要一个精确的建筑模型,然而,获得这样一个性能良好的模型是一项困难的任务.其次,在模型预测控制中,需要多次求解相应的优化问题,大多数现有的优化算法对计算量和存储空间都有很高的要求,使得模型预测控制在空调系统控制中的应用不易于工程实现.此外,现有研究成

果大多数是针对冷冻站的局部设备进行控制,而冷冻站系统包含冷水机组、冷冻水回路和冷却水回路,针对局部设备的控制无法实现系统整体上的节能.

为了降低计算和存储问题的复杂性,Seong等<sup>[10]</sup>提出了一种非线性多输入多输出系统的神经网络(ANN)动态优化方法,主要特点是用神经网络逼近动态规划的最优反馈解,从而降低了动态规划等经典方法的计算和存储问题的复杂性.然而,该方法不适用于受时变和不确定因素影响的工业过程.相比之下,模型预测控制采用滚动优化方法,并利用优化过程中测量到的系统信息进行反馈校正,这有助于消除未建模干扰或建模误差,增强了系统的鲁棒性,适用于复杂工业过程.因此,本文针对空调冷冻站系统,提出基于负荷预测的神经网络预测控制策略,将满足负荷需求和系统能效比需求作为优化目标,以达到在满足冷量需求的前提下降低系统整体能耗的目的.目前,空调冷冻站系统控制中主要采用恒压差或者恒温差策略<sup>[11]</sup>,在实际工程中,恒压差和恒温差的控制并没有按照实际负荷需求调节各设备,且无法考虑系统整体节能,不能达到预期的节能效果.本文所提出的基于负荷预测的控制策略使系统主动跟随负荷变化趋势,能够保证系统根据实时需求调节设备参数,在时间、数量方面实现供需匹配,同时由于优化目标函数考虑到系统整体能效最优,能够有效减少能源浪费.另外,针对目前非线性预测控制优化算法计算量大、不易于工程实现的问题,本文采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神经网络控制器在线寻优性能指标,基于变分法与随机梯度下降法对神经网络控制器进行在线滚动优化,从而获得使系统优化目标函数最佳的控制量序列.优化算法充分利用了变分法计算量小、占用存储空间少,以及神经网络能够处理非线性并能实现反馈优化的优势,解决了变分法无法实现反馈优化和动态规划算法的“维数灾”问题,易于工程实现.本文以北京某国企科研楼的空调冷冻站系统为研究对象,基于系统实际运行数据,利用神经网络构建了系统负荷预测模型和空调冷冻站系统能效比预测模型,在此基础上设计了神经网络控制器.仿真实验结果表明,本文所提出的控制策略能够在负荷变化的情况下使系统稳定运行,满足冷量需求,同时与PID控制方法相比节能8.57%,并可有效减少传统PID控制方法所需的调试工作量.

## 2 系统描述

### 2.1 研究对象

集中式空调系统的整体组成如图1所示,主要由空气处理器、冷冻站、风机、风管系统、末端设备等组成.空气处理器的主要设备是过滤器和盘管表冷器,混风(新风与部分回风)进入空气处理器后在过滤器处

进行过滤处理, 在盘管表冷器处进行热、湿处理; 冷冻站根据室内负荷为空调系统提供所需的冷量; 风机的功能是为空调系统提供空气循环动力; 风管系统的功能是对空调系统的空气进行输送和散布; 各末端区域根据自身的需求来调整末端设备, 以使各区域温度达到设定值。

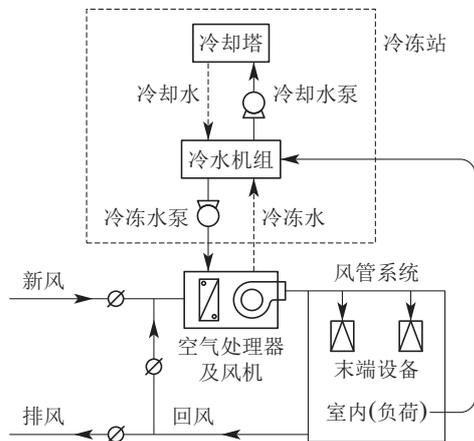


图 1 集中式空调系统组成

Fig. 1 Composition of a central air-conditioning system

本文主要以空调冷冻站系统为研究对象, 如图2所示, 该系统主要包括冷水机组、冷冻水回路和冷却水回路。

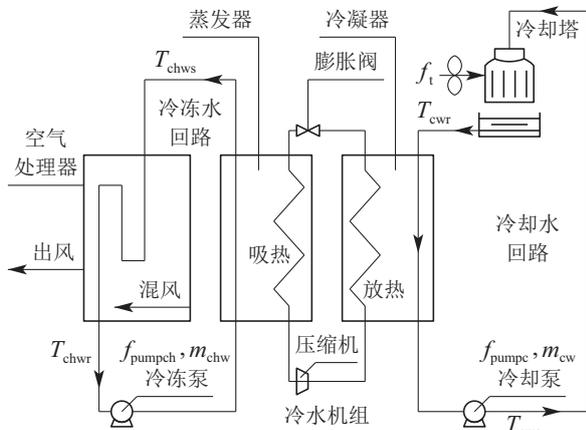


图 2 冷冻站系统图

Fig. 2 Diagram of an air-conditioning refrigeration system

冷水机组是系统的核心部件, 在空调系统中, 冷水机组负责制备冷量, 主要由蒸发器、压缩机、冷凝器和膨胀阀4部分组成。当系统处于制冷阶段时, 制冷剂在这四大部件中周期循环。首先, 液态制冷剂在蒸发器内吸收冷冻水回水的热量, 变成气态, 再经过压缩机, 被压缩成高温高压的气体。然后, 该气体流经冷凝器放出热量, 使其温度降低, 变成液体, 放出的热量被冷却水带到冷却塔排出。最后, 高压液态制冷剂在系统的推动下流经膨胀阀, 降压后再次流向蒸发器进入下一个循环。

冷冻水回路由冷冻泵及冷冻水管道组成。循环过程中, 冷冻水首先在蒸发器处与制冷剂进行热交换, 降温后由冷冻泵加压送入冷冻水管道, 然后流到空气处理器, 与混风进行热交换。降温后的冷风由风机吹向空调末端, 经末端设备进入室内, 达到降温的目的。同时, 冷冻水因吸收混风热量而温度升高。最后, 升温后的冷冻水再与冷水机组进行热交换。

冷却水回路主要由冷却泵、冷却水管道和冷却塔组成。系统运行过程中, 冷却水在冷凝器处吸收制冷剂释放的热量, 从而温度升高。然后, 冷却泵将升温后的冷却水压入冷却塔, 使之与外界环境进行热交换。最后, 降温后的冷却水又回到冷水机组处进入下一次循环。该建筑冷冻站系统的各设备信息如表1所示。

表 1 冷冻站系统设备信息

Table 1 Equipment information of the refrigeration system

名称	设备参数	数量
离心式冷水机组	制冷量1458 kW, 功率334 kW	2
离心式冷冻水泵	功率18.5 kW, 流量316 m <sup>3</sup> /h, 扬程38 m	2
离心式冷却水泵	功率15 kW, 流量353 m <sup>3</sup> /h, 扬程32 m	2
方形冷却塔	风量11500 m <sup>3</sup> /h, 功率5.5 kW	2

## 2.2 系统能效分析

### 2.2.1 冷水机组

冷水机组是空调冷冻站系统的主要设备之一, 其能耗约占系统总能耗的一半。冷水机组负责制备冷量, 空调末端区域负责消耗冷量, 冷水机组制备的冷量通常表示为

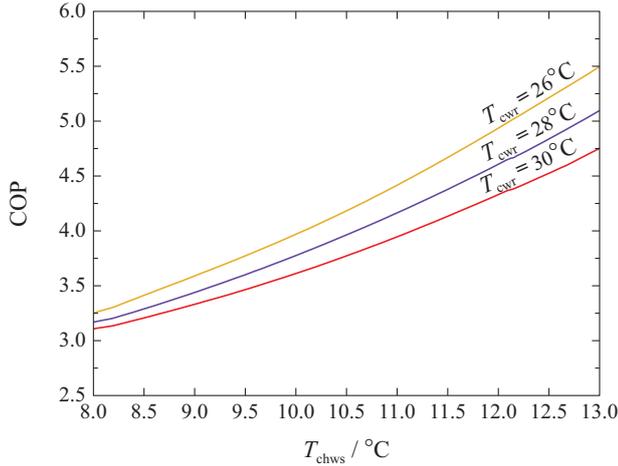
$$Q_{ch} = c \cdot m_{chw} \cdot (T_{chwr} - T_{chws}), \quad (1)$$

其中:  $Q_{ch}$ 表示冷水机组制备的冷量, 单位kW;  $c$ 表示水的比热容, 单位kJ/(kg·K);  $m_{chw}$ 表示冷冻水流量, 单位kg/s;  $T_{chws}$ 表示冷冻水供水温度, 单位°C;  $T_{chwr}$ 表示冷冻水回水温度, 单位°C。

同时, 冷水机组的运行能效比可表示为

$$COP = Q_{ch}/P_{chiller}, \quad (2)$$

其中: COP表示冷水机组的运行能效比, 无量纲;  $P_{chiller}$ 表示冷水机组的运行功率, 单位kW。能效比COP可以被用来衡量冷水机组的能效。影响COP的因素主要有冷冻水供水温度 $T_{chws}$ 、冷却水回水温度 $T_{cwr}$ (可以通过改变冷却塔风机运行频率 $f_t$ 来进行控制)、冷冻水流量 $m_{chw}$ (可以通过改变冷冻水泵频率 $f_{pumpch}$ 来进行控制)、制备的冷量 $Q_{ch}$ 及冷水机组台数。冷水机组COP随 $T_{chws}$ ,  $T_{cwr}$ 的变化关系曲线如图3所示<sup>[12]</sup>。

图3 COP- $T_{chws}$ - $T_{cwr}$ 关系曲线Fig. 3 The curve of the relation between COP and  $T_{chws}$ ,  $T_{cwr}$ 

### 2.2.2 水泵

水泵是空调冷冻站系统的重要设备之一,包括冷冻水泵和冷却水泵.在空调系统中,水泵起到动力循环作用,约有15%~20%的能耗来自水泵.水流量大小的改变可以通过调节水泵频率来实现.目前工程应用中,使用较多的是变频水泵,其功率计算公式为

$$P_{pump} = \rho g V H / 3.6 \times 10^6 \cdot \eta, \quad (3)$$

$$\eta = \eta_p \cdot \eta_m \cdot \eta_{VFD}, \quad (4)$$

其中:  $P_{pump}$ 表示水泵的功率,即驱动水泵的电机功率,单位kW;  $\rho$ 为流体的密度,单位 $\text{kg}/\text{m}^3$ ;  $g$ 为重力加速度,单位 $\text{m}/\text{s}^2$ ;  $V$ 表示流体的体积流量,单位 $\text{m}^3/\text{h}$ ;  $H$ 表示水泵的扬程,单位m;  $\eta$ 表示水泵的全效率;  $\eta_p$ 为水泵效率;  $\eta_m$ 为电机效率;  $\eta_{VFD}$ 为变频器效率.

### 2.2.3 冷却塔

在空调系统的总能耗中,大约5%的能耗来自冷却塔.冷却塔风机的运行功率可表示为

$$P_{tower} = \left(\frac{f_t}{f_0}\right)^3 P_{tower, rated}, \quad (5)$$

其中:  $P_{tower}$ 表示风机的运行功率,单位kW;  $P_{tower, rated}$ 表示风机的额定功率,单位kW;  $f_t$ 表示风机的运行频率,单位Hz;  $f_0$ 表示风机的额定频率,一般为50 Hz.

影响冷却塔能效的因素主要有室外空气湿球温度  $T_{wb}$ 、冷却水流量  $m_{cw}$  (可以通过改变冷却水泵频率  $T_{pumpc}$  来进行控制)、冷却水回水温度  $T_{cwr}$  及冷却塔台数.

## 2.3 系统预测控制目标

集中式空调冷冻站系统预测控制目标是使空调冷冻站系统各设备运行在高效状态,在满足大楼冷量需求的前提下,尽可能节约能源,使空调冷冻站系统能效比EER达到设定值.式(6)为空调冷冻站系统能效比EER的计算公式.

$$EER = Q_{ch} / P_{total}, \quad (6)$$

式中:冷水机组制冷量  $Q_{ch}$  可由式(1)求得,  $P_{total}$  表示空调冷冻站系统各设备的运行功率总和,单位kW,计算公式为:

$$P_{total} = P_{chiller} + P_{pumpch} + P_{pumpc} + P_{tower}, \quad (7)$$

其中:冷水机组的运行功率  $P_{chiller}$  可直接测量获得,冷冻水泵运行功率  $P_{pumpch}$ 、冷却水泵的功率  $P_{pumpc}$  和冷却塔运行功率  $P_{tower}$  可分别由式(3)和式(5)求得.

## 3 负荷预测与系统建模

为实现本文所提出的模型预测控制策略,首先需要对负荷和系统能效比进行建模.冷冻站系统设备众多,设备型号、规格多样,以冷水机组为例,其包括离心式、螺杆式和磁悬浮式,且系统的负荷和能效比与设备控制参数之间是非线性关系,使用传统基于机理建模的方法,很难建立系统的模型<sup>[13]</sup>.为此,研究人员提出了多种基于数据驱动的建模方法,如数据挖掘算法(人工神经网络-ANN<sup>[14]</sup>、支持向量机-SVM<sup>[15]</sup>)、统计模型(回归<sup>[16]</sup>等)、几何模型<sup>[17]</sup>,以及随机模型(概率密度函数逼近<sup>[18]</sup>)等.在这些建模方法中,神经网络算法无需繁冗的建模过程,且模型精度较高<sup>[19]</sup>,相比于其他方法,它在非线性系统建模方面更具优势.因此,本文采用神经网络获取系统负荷预测模型和能效比预测模型.

建立神经网络模型需要采集覆盖系统所有动态特性的丰富数据集.适当选择参数或变量可以提高模型的可理解性、可扩展性和准确性<sup>[20]</sup>.因此,需要合理选择建模参数.

### 3.1 模型参数

#### 3.1.1 负荷预测模型参数

准确的负荷预测是空调系统预测控制的前提条件.空调负荷可分为冷负荷和热负荷两种<sup>[21]</sup>.空调负荷的影响因素众多,主要由整个大楼空调区域的内部扰动与外部扰动组成.其中,内部扰动一般指由大楼内部的照明设备、室内人员及其他电气设备等产生的热量;外部扰动主要包括室外空气温湿度、太阳辐射强度、风速、风向等.当建筑物投入使用后,建筑物的空间结构与使用材料等为固定参数,此时影响空调系统负荷的最重要参数是室外气象参数、室内空间的使用以及设备的开启情况.因此,本文选择负荷预测模型的输入参数有以下6个:

- 1) 室外温度  $T_{out}[k]$ ;
- 2) 室外相对湿度  $RH_{out}[k]$ ;
- 3) 太阳辐射强度  $S[k]$ ;
- 4) 室外风速(北向)  $W_{north}[k]$ ;
- 5) 室外风速(东向)  $W_{east}[k]$ ;
- 6) 室内负荷(人员及电气设备)  $Q_{in}[k]$ .

其中  $k$  表示当前时刻,负荷预测模型的输出为下一时刻系统负荷预测值  $Q[k+1]$ .

### 3.1.2 系统模型参数

本文选择冷冻站系统能效比EER预测模型的输入参数有<sup>[13]</sup>:

- 1) 冷冻水供水温度 $T_{chws}[k]$ ;
- 2) 冷却水回水温度 $T_{cwr}[k]$ ;
- 3) 冷冻水泵频率 $f_{pumpch}[k]$  (即冷冻水流量 $m_{chw}$ );
- 4) 冷却水泵频率 $f_{pumpc}[k]$  (即冷却水流量 $m_{cw}$ );
- 5) 回风温度 $T_{in}[k]$ ;
- 6) 室外空气干球温度 $T_{db}[k]$ ;
- 7) 室外空气湿球温度 $T_{wb}[k]$ ;

8) 负荷预测值 $Q[k]$ ;

9) 当前时刻的系统能效比EER $[k]$ .

模型的输出为下一时刻系统能效比EER $[k + 1]$ .

### 3.2 数据采集

本文选取夏季6月至9月的系统实测样本数据进行负荷预测和系统能效比建模, 采样周期为10分钟, 这些数据都是由该国企科研楼的集中式空调监控系统提供. 样本数据被分成3个不同的数据集, 用于对神经网络模型的训练、验证和测试, 数据占比分别为70%, 10%和20%. 部分数据如表2所示.

表 2 部分数据信息  
Table 2 Partial data information

参数个数	1	2	3	4	5	6	7	8	9	10
室外干球温度(°C)	22.2	22.5	26.8	26.6	26.7	26.5	31.6	31.4	32.8	32.4
室外湿球温度(°C)	19	19.2	19.1	18.9	18.9	18.8	22.4	22.1	20.9	20.5
室外相对湿度(%)	74.7	74.1	48.9	49.1	48.5	48.4	46.2	44.8	34.5	34
室内负荷(kW)	1021	1035.7	1120.5	1280	1300.9	1312.4	1380.9	1366.6	1380.9	1370.2
回风温度(°C)	25.9	26	26	26.2	26.4	26.6	27	27	27.1	27.3
冷冻水供水温度(°C)	14.6	14.9	9.6	10.6	12.6	15	12.4	14.5	13	14.1
冷却水回水温度(°C)	26.1	23.5	26.8	27	26.6	25.2	28.2	27.2	27.3	25
冷冻水泵频率(Hz)	37	37.7	35.2	35.7	36.2	36.8	36.4	37	36.9	37.5
冷却水泵频率(Hz)	38.1	30.2	32.3	34.8	35.1	33.6	30.7	31.3	31.1	30.3

### 3.3 数据预处理

为了消除尖峰噪声和随机噪声, 本文对数据进行了滑动平均滤波处理. 滑动平均滤波算法需要先确定滑动窗口的宽度 $N$ , 即连续取 $N$ 个数据看成一个队列, 每次获取一个新数据放入队尾, 并扔掉原来队首的一个数据, 滤波器每次输出的数据总是当前队列中 $N$ 个数据的算术平均值, 本文选取 $N$ 为15.

另一方面, 在神经网络的训练过程中, 由于模型各输入变量的量纲不同, 并且数据值的大小差异非常大, 会使训练速度变慢, 甚至会出现训练最终无法收敛的情况. 因此, 有必要对实测样本数据进行归一化和反归一化处理. 本文在进行处理时, 采用线性函数转换方法<sup>[22]</sup>, 将数据转换成0至1范围内的数值.

### 3.4 ANN结构

本文采用两个三层BP神经网络(一个输入层、一个隐含层和一个输出层)建立负荷预测模型和系统能效比预测模型, 三层神经网络已被证明能以高精度有效逼近任何一个非线性过程<sup>[23]</sup>. 网络隐层神经元数目对预测模型的性能有显著影响, 然而, 现有文献中并没有提出明确的解析函数来预先确定隐层神经元的数量, 一般可通过基于式(8)的试错法<sup>[24]</sup>来计算得到隐层神经元数量.

$$m = \sqrt{n + l} + \alpha, \quad (8)$$

其中:  $n$ 和 $l$ 分别代表输入层和输出层节点数;  $m$ 表示

隐含层节点数;  $\alpha$ 是试凑常数, 取值范围通常是[1, 10].

利用上述公式, 本文计算得出负荷预测模型的隐含层节点数取值范围是[4, 13]. 为了确定隐含层神经元的最佳数量, 必须进行实验试凑比较. 综合考虑网络误差和网络泛化性能, 通过实验测定, 本文发现当隐含层节点数为12时, 网络训练效果最佳, 实验比较结果如表3所示. 同样, 系统能效比预测模型的最优隐层节点数为10.

表 3 不同情况下, BP神经网络模型的均方根误差  
Table 3 The RMSE of the BP model in different cases

隐含层神经元个数	RMSE
8	0.0131
9	0.0147
10	0.0132
11	0.015
12	0.0127
13	0.0145
14	0.0148

神经网络的训练通常采用反向传播(BP)算法<sup>[25]</sup>、Levenberg-Marquardt (LM)算法<sup>[26]</sup>和贝叶斯正则化算法<sup>[27]</sup>. BP算法是最常用的算法, 它使用梯度下降法来寻找极小值. 然而, 它存在局部极小和过拟合问题<sup>[19]</sup>. LM 算法收敛速度最快, 均方误差最小, 但其泛化能力

较弱.对于具有数百个权值的中小型神经网络,贝叶斯正则化算法能够有效提高神经网络的泛化能力,避免过拟合问题<sup>[28]</sup>.因此本文采用贝叶斯正则化算法对神经网络进行训练.

### 3.5 确定初始权值和学习率

神经网络初始权值的范围和学习率对网络的性能和学习速度有一定的影响,太大的初始权值和学习率会导致网络无法收敛,影响建模精度,而太小的初始权值和学习率会浪费计算资源,降低训练速度.因此有必要找到合适的初始权值范围和学习率,使网络获得更好的性能和学习速度.通过实验发现,学习率为0.1,初始权值范围在(-0.1, 0.1)之间时,训练结果的均方误差较小,训练时间较短.因此本文将神经网络初始权值确定为(-0.1, 0.1)之间的随机小数,学习率确定为0.1.

### 3.6 模型性能分析

#### 3.6.1 负荷预测模型

本文利用所构建的负荷预测模型对未来1天的冷负荷进行了预测.

图4和图5是负荷预测模型的测试实验结果,横坐标表示140组测试数据.所得到的测试输出误差曲线如图4所示.由图可以看出,模型测试输出与对应的目标输出之间的误差在-20~36 kW之间,相对误差为1.82%,对于实际工程应用而言,该误差在可接受范围内.

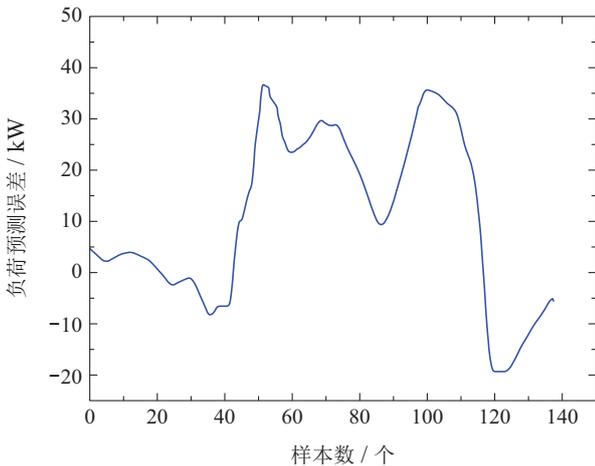


图4 负荷预测误差

Fig. 4 Prediction error of the load

模型测试输出与对应的目标输出之间的比较结果如图5所示.由图可以看出,模型测试输出与对应的目标输出之间的拟合度良好;受到天气因素等时变参数的影响,在空调系统负荷发生改变时,预测模型的值可以较好地跟随目标值.这表明本文所构建的空调系统负荷预测模型可以以较高的精度反映输入-输出样

本数据对中国有的非线性映射关系.

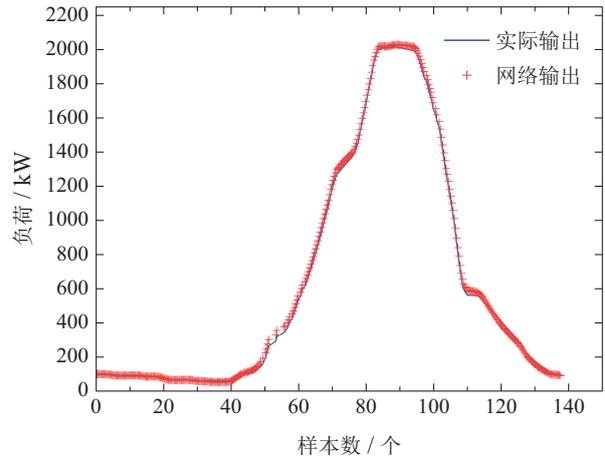


图5 负荷的实际输出和预测输出比较图

Fig. 5 Comparison diagram of actual output and predicted output of the load

由以上结果可以看出,本文所构建的神经网络负荷预测模型具有结构简单的特点,同时能够避免进行繁琐的非稳态传热计算;并且该模型很好地描述了建筑物空调负荷与输入参数之间的复杂非线性关系,具有工程实用价值.

#### 3.6.2 系统能效比模型

图6和图7是利用200组数据(训练集采用700组数据)对冷冻站系统能效比预测模型进行测试的实验结果.所得到的测试误差输出曲线如图6所示.由图可以看出,模型输出与对应的目标输出之间误差值大部分都维持在-0.04~0.04之间,相对误差为1.11%.模型输出与对应的目标输出之间的比较结果如图7所示.可见,模型输出与对应的目标输出之间的拟合度良好,表明所提出的预测模型有效地跟踪了系统的动态过程.

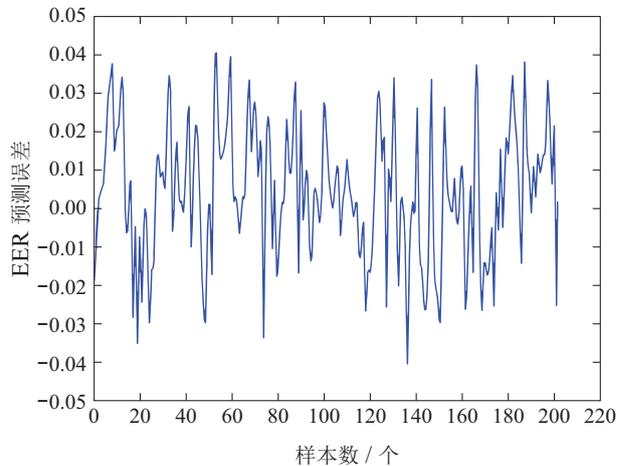


图6 EER预测误差

Fig. 6 Prediction error of EER

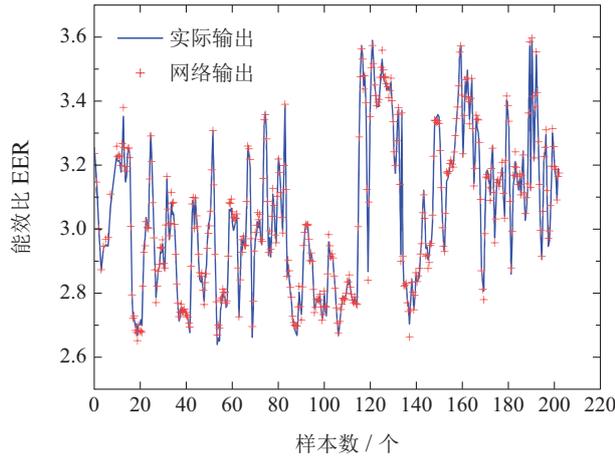


图 7 EER实际输出与网络输出的比较

Fig. 7 Comparison diagram of actual output and predicted output of EER

## 4 神经网络预测控制

### 4.1 算法概述

模型预测控制是处理耦合和约束问题的一种有效方法,人们广泛认为它是继PID控制之后又一代实用的控制技术<sup>[29]</sup>。然而,空调冷冻站系统的非线性特性使得模型预测控制的在线优化难以实现。

动态规划和变分法是解决最优化问题的常用方法,但两者都有一定的局限性。当使用动态规划方法时,存储容量随维度呈指数增长,将会出现“维数灾”问题<sup>[30]</sup>。变分法相对简单,但由于缺乏反馈校正,容易受到干扰和不确定性因素的影响<sup>[31]</sup>。为此,本文提出一种基于神经网络的非线性预测控制策略,采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神经网络控制器优化性能指标,将系统动态模型和神经网络控制器方程作为约束,基于变分法和随机梯度下降法<sup>[32]</sup>相结合的训练算法,对神经网络权值(阈值)进行在线寻优,实现预测控制滚动优化,达到使系统优化目标函数最佳的控制目标。该算法既能够解决传统变分法由开环控制引发的对随机干扰和不确定性敏感的问题,又可避免基于动态规划的非线性优化算法的“维数灾”问题,易于工程实现。

### 4.2 基于ANN的MPC算法

集中式空调系统是多输入多输出非线性系统,假设系统预测模型为

$$\mathbf{x}[k+1] = f(\mathbf{x}[k], \mathbf{u}[k]), \quad (9)$$

其中:  $\mathbf{x}[k]$ 表示状态向量,  $\mathbf{x}[k] = [x_1(k) \ x_2(k) \ x_3(k) \ \cdots \ x_n(k)]$ ,  $n$ 表示状态向量的维数;  $\mathbf{u}[k]$ 表示控制向量,  $\mathbf{u}[k] = [u_1(k) \ u_2(k) \ u_3(k) \ \cdots \ u_m(k)]$ ,  $m$ 表示控制向量的维数;  $k$ 表示采样周期的当前时刻,取值范围是  $(0, 1, 2, \dots)$ ;  $k+1$ 表示 $k$ 的下一时刻。

神经网络控制器方程可以表示为

$$\mathbf{u}[k] = g(\mathbf{x}[k], \mathbf{x}^*[k+1], \mathbf{W}), \quad (10)$$

其中:  $\mathbf{W}$ 表示神经网络的权值系数矩阵(包括阈值);  $\mathbf{x}^*[k+1]$ 表示下一时刻状态变量的期望值。该网络输入层包含  $2n+1$  个神经元,输入变量为  $\mathbf{x}[k]$ ,  $\mathbf{x}^*[k+1]$ , 和  $-1$  (神经元阈值)。输出层包含  $m$  个神经元,输出变量为最优控制量  $\mathbf{u}[k]$ 。

$$J = \varphi_{t_1+M}(\mathbf{x}[t_1+M], t_1+M) + \sum_{k=t_1}^{t_1+M-1} L(\mathbf{x}[k], \mathbf{u}[k], k), \quad (11)$$

式中:  $M$ 表示预测时域,  $t_1$ 表示每个预测时域中的初始时刻,  $\varphi_{t_1+M}(\mathbf{x}[t_1+M], t_1+M)$ 表示末端时刻的性能指标,  $L(\mathbf{x}[k], \mathbf{u}[k], k)$ 表示预测过程中的性能指标。

在预测模型(9)和控制器方程(10)给出的等式约束条件下,优化问题可以表示为最小化性能指标函数(11)。本文所提出的模型预测控制策略使用预测模型(9)预测系统的未来状态。然后,在存在干扰和约束的情况下,控制器生成控制向量(10)以最小化预测时域内的性能指标函数(11)。在每个时刻,测量系统输出  $\mathbf{x}[t_0]$ , 并将其反馈给控制器,用作优化过程中的初始状态向量  $\mathbf{x}[t_1]$ 。通过引入拉格朗日乘子<sup>[33]</sup>和哈密顿函数<sup>[34]</sup>,可以获得包含约束的增广性能指标函数,表示为

$$J_a = \boldsymbol{\lambda}^T[t_1](\mathbf{x}[t_0] - \mathbf{x}[t_1]) + \varphi_{t_1+M}(\mathbf{x}[t_1+M], t_1+M) + \sum_{k=t_1}^{t_1+M-1} \{L(\mathbf{x}[k], \mathbf{u}[k], k) + \boldsymbol{\lambda}^T[k+1](f(k) - \mathbf{x}[k+1]) + \mathbf{q}^T[k](g(k, \mathbf{W}) - \mathbf{u}[k])\}, \quad (12)$$

其中:  $\boldsymbol{\lambda}$ 和 $\mathbf{q}$ 是拉格朗日乘子向量;  $f(k)$ 和 $g(k, \mathbf{W})$ 分别代表等式(9)和式(10)的右侧部分。

哈密顿函数可以表示为

$$H(k) = H(\mathbf{x}, \mathbf{x}^*, \mathbf{u}, \boldsymbol{\lambda}, \mathbf{q}, k, \mathbf{W}) = L(\mathbf{x}[k], \mathbf{u}[k], k) + \boldsymbol{\lambda}^T[k+1]f(k) + \mathbf{q}^T[k]g(k, \mathbf{W}). \quad (13)$$

然后,增广性能指标可以重新表示为

$$J_a = \boldsymbol{\lambda}^T[t_1]\mathbf{x}[t_0] + \varphi_{t_1+M}(\mathbf{x}[t_1+M], t_1+M) - \boldsymbol{\lambda}^T[t_1+M]\mathbf{x}[t_1+M] + \sum_{k=t_1}^{t_1+M-1} \{H(k) - \boldsymbol{\lambda}^T[k]\mathbf{x}[k] - \mathbf{q}^T[k]\mathbf{u}[k]\}. \quad (14)$$

根据状态向量变分 $\delta\mathbf{x}[k]$ 、控制向量变分 $\delta\mathbf{u}[k]$ 和神经网络控制器权值(包括阈值)变分 $\delta\mathbf{W}$ ,对式(14)求取一次变分,得

$$\delta J_a = \left\{ \frac{\partial \varphi_{t_1+M}(\mathbf{x}[t_1+M], t_1+M)}{\partial \mathbf{x}[t_1+M]} - \right.$$

$$\lambda^T[t_1 + M]\delta\mathbf{x}[t_1 + M] + \lambda^T[t_1]\delta\mathbf{x}[t_0] + \sum_{k=t_1}^{t_1+M-1} \left\{ \left( \frac{\partial H(k)}{\partial \mathbf{x}[k]} - \lambda^T[k] \right) \delta\mathbf{x}[k] + \left( \frac{\partial H(k)}{\partial \mathbf{u}[k]} - \mathbf{q}^T[k] \right) \delta\mathbf{u}[k] + \frac{\partial H(k)}{\partial \mathbf{W}} \delta\mathbf{W} \right\}. \quad (15)$$

对于任意的变分向量 $\delta\mathbf{x}[k]$ ,  $\delta\mathbf{u}[k]$ 和 $\delta\mathbf{W}$ , 最小化性能指标 $J_a$ 的必要条件是 $\delta J_a = 0$ . 因为 $\mathbf{x}[t_0]$ 是已知常量, 所以 $\delta\mathbf{x}[t_0] = 0$ .

因此, 式(15)为0的必要条件为

$$\lambda^T[k] = \frac{\partial H(k)}{\partial \mathbf{x}[k]}, \quad (16)$$

$$\mathbf{q}^T[k] = \frac{\partial H(k)}{\partial \mathbf{u}[k]}, \quad (17)$$

$$\lambda^T[t_1 + M] = \frac{\partial \varphi_{t_1+M}(\mathbf{x}[t_1 + M], t_1 + M)}{\partial \mathbf{x}[t_1 + M]}, \quad (18)$$

$$\sum_{k=t_1}^{t_1+M-1} \frac{\partial H(k)}{\partial \mathbf{W}} = 0. \quad (19)$$

式(16)和式(17)称为哈密顿正则(伴随)方程, 其中 $k = t_1, t_1 + 1, \dots, t_1 + M - 1$ . 式(18)和式(19)分别是横截条件和极值条件.

### 4.3 系统控制

图8所示为系统模型预测控制策略的结构图. 图中 $x[k] = \text{EER}[k]$ 表示冷冻站系统能效比;  $\hat{x}[k+i]$  ( $i = 1, 2, 3, \dots$ )表示预测模型输出的系统能效比预测值;  $x^*[k+i]$  ( $i = 1, 2, 3, \dots$ )表示能效比期望值;  $\mathbf{z}[k]$ 表示其它变量(室外干球温度、室外湿球温度、回风温度);  $Q_{\text{act}}[k]$ 表示空调负荷的实际值;  $y[k]$ 表示 $k$ 时刻的冷冻水流量、冷冻水供水温度及冷冻水回水温度.

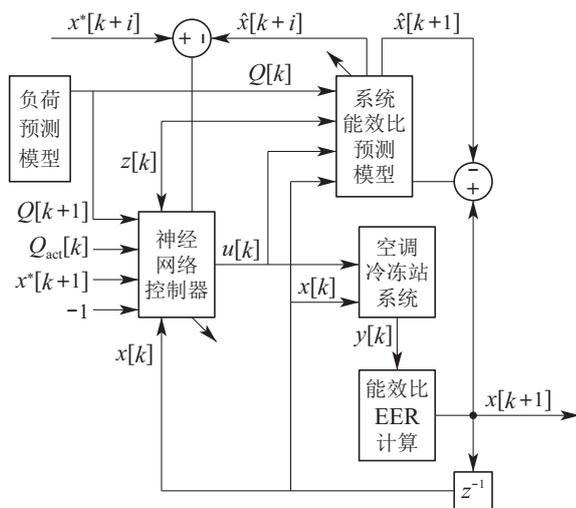


图8 系统MPC策略结构图

Fig. 8 Chart of model predictive control of the system

根据第2.2节的分析可知, 通过提高冷冻水供水温度、降低冷却水回水温度可以提高冷水机组能效; 通过改变水泵的频率, 可以控制冷冻水流量和冷却水流

量. 由于冷水机组内部有厂家设置好的控制器, 且原理复杂、造价昂贵, 不允许直接对其进行控制, 因此控制算法是计算使系统优化性能指标达到最佳时的冷冻水供水温度设定值, 设定值传给冷水机组后, 冷水机组会自动进行控制, 使其出水温度跟上冷冻水的设定值. 故对于空调冷冻站系统需要寻优的运行参数有冷冻水供水温度 $T_{\text{chws}}$ 、冷却水回水温度 $T_{\text{cwr}}$ 、冷冻水泵频率 $f_{\text{pumpch}}$ 和冷却水泵频率 $f_{\text{pumpc}}$ , 即控制向量 $\mathbf{u}[k] = (T_{\text{chws}}[k], T_{\text{cwr}}[k], f_{\text{pumpch}}[k], f_{\text{pumpc}}[k])$ .

此外, 空调系统各设备都受到一定条件的约束, 运行参数的取值有一定的限定范围. 控制变量参数的约束范围如下:

冷冻水供水温度:  $7^\circ\text{C} \leq T_{\text{chws}} \leq 15^\circ\text{C}$ ;

冷却水回水温度:  $20^\circ\text{C} \leq T_{\text{cwr}} \leq 37^\circ\text{C}$ ;

冷冻水泵频率:  $30 \text{ Hz} \leq f_{\text{pumpch}} \leq 50 \text{ Hz}$ ;

冷却水泵频率:  $30 \text{ Hz} \leq f_{\text{pumpc}} \leq 50 \text{ Hz}$ .

系统预测模型即采用第3节中神经网络建立的预测模型. 在 $kT$  ( $T$ 是采样周期)时刻的性能指标可以表示为

$$J(\text{EER})[k] = \frac{1}{2} \sum_{k=t_1}^{t_1+M-1} \{ (\text{EER}[k] - \text{EER}_{\text{set}}[k])^2 + (Q[k] - Q_{\text{act}}[k])^2 \}, \quad (20)$$

其中:  $\text{EER}_{\text{set}}[k]$ 表示 $k$ 时刻能效比设定目标值,  $Q[k]$ 和 $Q_{\text{act}}[k]$ 分别表示 $k$ 时刻负荷的预测值和实际值.

## 5 仿真实验

### 5.1 神经网络控制器设计

本文基于所提出的预测控制策略设计神经网络控制器, 其包含3个网络层. 输入层有7个参数, 包括系统状态EER和影响EER的室外环境变量、负荷值及回风温度, 具体为当前时刻室外干球温度、室外湿球温度、负荷、回风温度、EER值和EER的设定值, 以及与阈值(-1); 输出变量有4个, 分别是当前时刻冷冻水供水温度、冷却水回水温度、冷冻水泵频率及冷却水泵频率. 该神经网络控制器的结构如图9所示.

### 5.2 预测控制优化算法

本文所提出的基于神经网络的预测控制器的在线优化按以下9个步骤进行, 根据需求, 其中控制器的预测时域 $M$ 取6, 即对未来1小时系统的状态进行预测, 根据经验, 学习率 $\mu = 0.1$ .

1) 初始化神经网络控制器, 将神经网络的连接权值 $\mathbf{W}$ 设为较小的随机数(0.01或更小); 确定预测时域 $M$ 和控制器权值更新率 $\mu$  (又称学习率).

2) 根据系统输出反馈值 $\mathbf{x}[t_0]$ 确定预测时域内的状态初值 $\mathbf{x}[t_1]$ .

3) 设当前时刻为  $k = t_1$ , 在预测时域内, 根据控制目标, 设置期望输出  $\mathbf{x}^*[t_1 + 1]$  在各个时刻的值.

4) 将  $\mathbf{x}[t_1]$  和  $\mathbf{x}^*[t_1 + 1]$  等输入变量作用于神经网络控制器, 得到控制量  $\mathbf{u}[t_1]$ . 然后根据负荷预测模型得到当前时刻负荷预测值  $Q[t_1]$ , 再将  $\mathbf{u}[t_1]$ ,  $\mathbf{x}[t_1]$  和  $Q[t_1]$  等作用于预测模型, 得到  $\hat{\mathbf{x}}[t_1 + 1]$ .

5) 将  $\hat{\mathbf{x}}[t_1 + i]$  和  $\mathbf{x}^*[t_1 + i + 1]$  等输入变量作用于神经网络控制器, 得到控制量  $\mathbf{u}[t_1 + i]$ , 其中  $i = 1, 2, \dots, M$ . 然后根据负荷预测模型得到负荷预测值  $Q[t_1 + i]$ , 再将  $\mathbf{u}[t_1 + i]$ ,  $\hat{\mathbf{x}}[t_1 + i]$  和  $Q[t_1 + i]$  等作用于预测模型, 得到  $\hat{\mathbf{x}}[t_1 + i + 1]$ , 并存储计算结果.

6) 重复步骤4)和5), 根据Hamilton正则方程(16)–(17), 从后向前计算拉格朗日乘子向量  $\boldsymbol{\lambda}[k]$  和  $\mathbf{q}[k]$ .

7) 根据计算出的  $\mathbf{q}[k]$ , 采用以下方程, 基于随机梯度下降法修正神经网络控制器的权值.

$$\Delta \mathbf{W} = -\mu \sum_{k=t_1}^{t_1+M-1} \frac{\partial g(k, \mathbf{W})}{\partial \mathbf{W}} \mathbf{q}[k], \quad (21)$$

$$\mathbf{W} = \mathbf{W} + \Delta \mathbf{W}, \quad (22)$$

其中  $\mathbf{W}$  是神经网络控制器的权重矩阵.

8) 重复步骤4)至7), 不断修改神经网络控制器权值, 直至  $\Delta \mathbf{W} = 0$ .

9) 令  $t_1 = t_1 + 1$ , 重复步骤3)至8), 计算出以后各个时刻控制量的值  $\mathbf{u}$ , 直至控制过程结束.

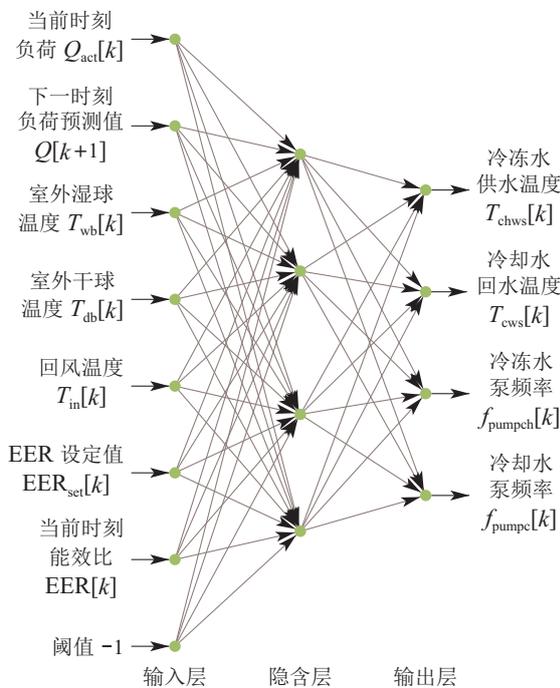


图 9 神经网络控制器结构图

Fig. 9 Structure diagram of the neural network controller

假设在上述寻优过程中, 控制量有  $m$  个, 状态量有  $n$  个, 控制器的连接权值有  $n_w$  个, 则对于图8所示的预测优化控制系统, 在寻优过程中需要进行约  $(2n(n + m) + n_w(m + 2))M$  步迭代运算, 占用  $(n + m)M +$

$2n_w$  个存储单元. 据此可知, 本文所提出的神经网络预测控制算法运行时所占用的存储单元与  $m, n, n_w$  成简单线性关系, 而动态规划算法所需存储单元与控制量、状态量维数成指数关系. 因此, 在对非线性系统进行求解时, 本文提出的神经网络预测控制优化算法计算量小、占用存储空间少. 同时, 该方法通过神经网络控制器实现了系统反馈优化, 能够处理非线性和模型不确定性问题.

### 5.3 性能分析

本文采用上述方案对空调冷冻站系统在MATLAB环境下进行预测控制算法仿真验证. 在验证实验中, 将通过神经网络辨识的空调冷冻站系统能效比模型既作为预测模型使用, 同时也作为被控对象使用. 本文从所采集的数据计算得知系统能效比EER值大多分布在3.2左右, 只有极少数达到3.5, 故将EER期望值设定为3.5, 相关参数的变化过程如图10–14所示. 图10显示系统运行80分钟以后基本达到稳定, 可以将系统能效比值稳定在3.5左右.

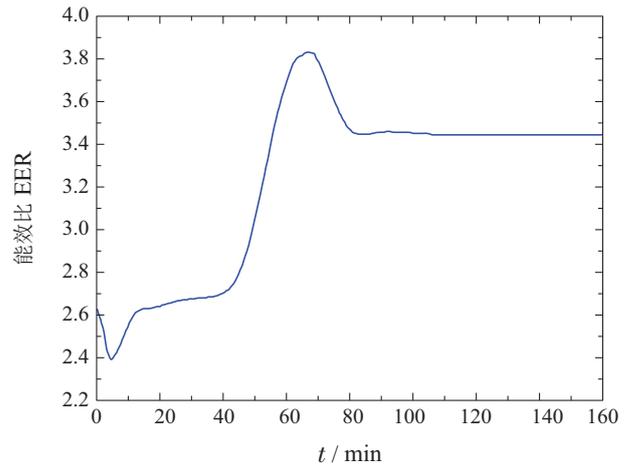


图 10 空调系统能效比EER变化情况

Fig. 10 Changes of EER of the air-conditioning system

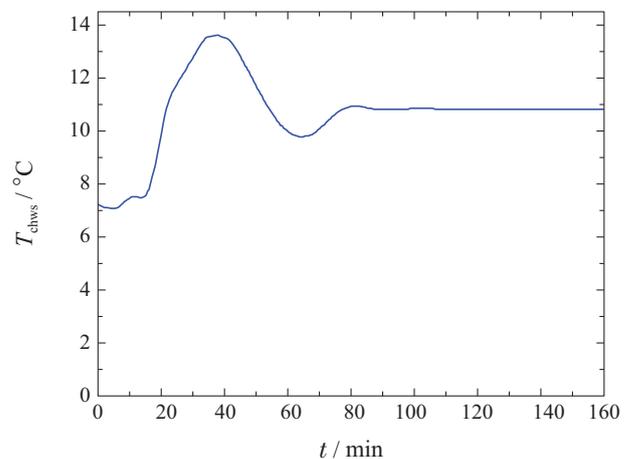


图 11 冷冻水供水温度  $T_{chws}$  变化情况

Fig. 11 Changes of  $T_{chws}$

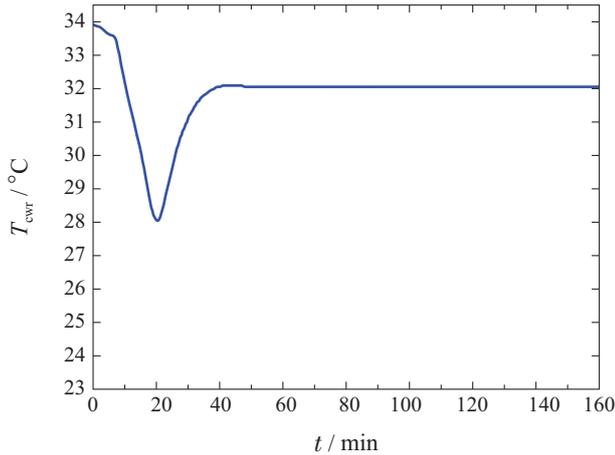
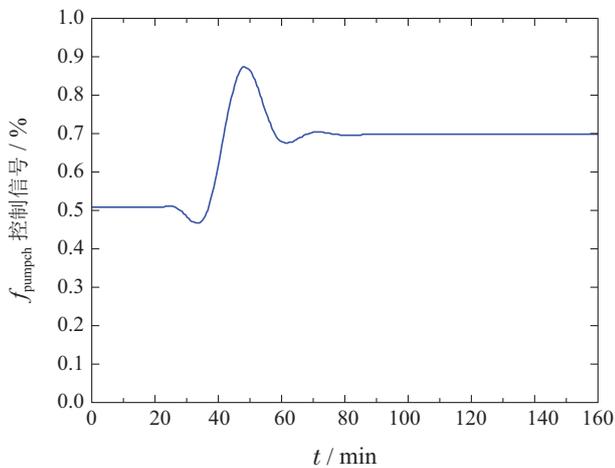
图12 冷却水回水温度 $T_{cwr}$ 变化情况Fig. 12 Changes of  $T_{cwr}$ 

图13 冷冻水泵频率变化情况

Fig. 13 Frequency changes of the chilled water pump

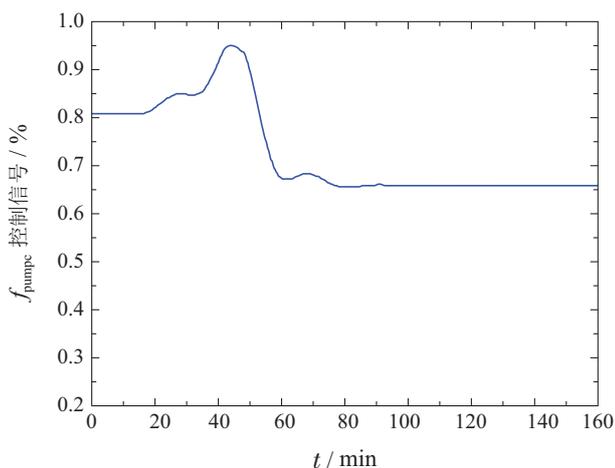


图14 冷却水泵频率变化情况

Fig. 14 Frequency changes of the cooling water pump

图11显示了冷冻水供水温度 $T_{chws}$ 变化情况,图12显示了冷却水回水温度 $T_{cwr}$ 变化情况.由图3可知,冷冻水供水温度的提高,表示冷水机组工作在较高的COP值下, $T_{chws}$ 基本可以稳定在 $11^{\circ}\text{C}$ 左右.而冷却水

回水温度稳定在 $32^{\circ}\text{C}$ 左右,达到了设计出水温度,使冷却塔工作在高能效状态下.

图13、图14显示的是水泵频率控制信号变化情况,该数值与水泵的流量值成正比例关系,可以间接反映水泵的流量变化情况.

由以上结果可以看出,本文所提出的预测控制算法能够很快地将空调系统相关运行参数稳定在最佳值附近,并使系统能效比EER达到预期目标值,控制效果良好.

#### 5.4 预测控制与PID控制性能比较

本文分别采用所提出的基于神经网络的预测控制策略与PID控制策略对空调冷冻站系统进行控制,表4所示为整定后的PID控制增益参数,图15所示为500分钟内两种方法的控制结果比较图.从图中可看出,利用预测控制算法能够使空调冷冻站系统能效比以较快的速度跟踪到期望值.而在只有PID控制时,参数整定需要经过两个制冷季,调试工作量大,且只能对单个设备的参数进行定值控制,无法实现系统整体性能优化;另外,本文研究对象的状态量EER值不是直接被控量,利用PID方法无法对该参数进行控制,也无法将能耗作为性能指标进行优化控制,因此,能效比达不到期望值,无法实现节能.

表4 PID参数

Table 4 PID parameters

控制量PID参数	$K_p$	$K_i$	$K_d$
$T_{chws}$	35	0.2	0.05
$T_{cwr}$	35	0.2	0.05
$f_{pumpch}$	40	0.15	0.05
$f_{pumpc}$	40	0.15	0.05

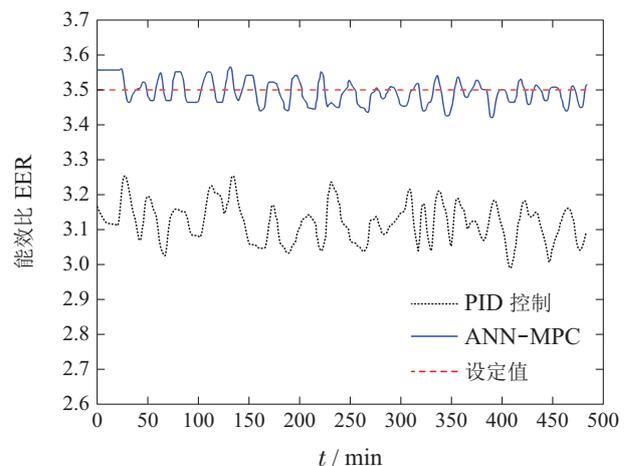


图15 MPC与PID控制的比较

Fig. 15 Comparison between MPC and PID control

根据图15计算得知,采用预测控制算法与采用传统的PID控制方法相比,系统的总能耗节省约8.57%

$((3.5 - 3.2)/3.5 = 0.0857)$ . 可见, 采用本文提出的预测控制算法对空调冷冻站系统进行优化具有较大的节能潜力.

## 6 结论

本文针对集中式空调系统回路间耦合、非线性、大滞后以及时变性等复杂特性, 以实际工程空调冷冻站系统为研究对象, 提出了基于神经网络的预测控制策略. 本文首先分析了冷冻站系统相关运行参数变化对系统运行能效的影响, 以及环境参数、建筑参数与负荷之间的关系, 在此基础上利用BP神经网络构建了空调系统负荷预测模型和能效比预测模型; 然后, 为了减少计算量和存储空间, 解决变分法无法实现反馈优化和基于动态规划的优化算法的“维数灾”问题, 本文采用神经网络作为优化反馈控制器实现预测控制滚动优化, 将变分法与随机梯度下降法相结合, 并以满足系统能效比要求和负荷要求为目标, 设计了空调系统神经网络预测控制器. 仿真实验结果表明, 基于神经网络的预测控制策略在控制过程中能够克服不确定性因素的影响, 在负荷不断变化的情况下使系统稳定在高效比工况下, 且与PID控制算法相比, 总能耗节省约8.57%.

虽然本文所提出的控制策略在用于空调冷冻站系统控制时取得了良好的效果, 但是由于实验条件和时间方面的限制, 还需要在以下几个方面对控制策略做进一步研究:

1) 本文建立了基于神经网络的空调系统负荷预测模型. 模型的输入量没有考虑由于建筑物热容量引起的冷负荷在时间上的延迟, 即气象参数的延迟效应. 因此, 有必要进一步研究室外温湿度以及太阳辐射强度的延迟效应对空调系统负荷的影响;

2) 本文所研究的冷冻站系统为一次泵系统, 未来可以进一步针对二次泵系统或含有蓄能设备的空调系统进行研究, 对于二次泵系统, 需要根据负荷变化调整二次泵的运行参数, 以满足负荷要求, 同时根据冷水机组能效比调整一次泵的运行参数; 对于含有蓄能设备的冷冻站系统, 则需要研究蓄冷设备与冷水机组相配合的控制策略;

3) 本文仅是从冷冻站系统的角度对空调系统节能优化进行了研究, 但是实际工程空调系统还包括末端系统. 因此, 在今后的研究中, 可从空调系统整体的角度来研究在线节能运行优化策略.

## 参考文献:

- [1] ZHANG Xudong, LIU Shasha. Analysis of key points of energy-saving assessment on civil buildings. *Building Energy Efficiency*, 2014, 42(4): 81 – 84.  
(张旭栋, 刘沙沙. 民用建筑项目节能评估要点分析. *建筑节能*, 2014, 42(4): 81 – 84.)
- [2] YANG Zhen. Development and application prospect of cool storage. *Journal of HVAC*, 2010(10): 261 – 263.  
(杨振. 浅谈蓄冷的发展状况及应用前景. *暖通空调*, 2010(10): 261 – 263.)
- [3] CHO J, KIM Y, KOO J, et al. Energy-cost analysis of HVAC system for office buildings: development of a multiple prediction methodology for HVAC system cost estimation. *Energy & Buildings*, 2018, 173: 562 – 576.
- [4] DRGONA J, PICARD D, KVASNICA M, et al. Approximate model predictive building control via machine learning. *Applied Energy*, 2018, 218(MAY15): 199 – 216.
- [5] HOVGAARD T G, BOYD S, LARSEN L F S, et al. Nonconvex model predictive control for commercial refrigeration. *IFAC Proceedings Volumes*, 2013, 86(8): 1349 – 1366.
- [6] PICARD D, DRGONA J, KVASNICA M, et al. Impact of the controller model complexity on model predictive control performance for buildings. *Energy & Buildings*, 2017, 152: 739 – 751.
- [7] HUANG G. Model predictive control of VAV zone thermal systems concerning bi-linearity and gain nonlinearity. *Control Engineering Practice*, 2011, 19(7): 700 – 710.
- [8] KARLSSON H, HAGENTOFT C E. Application of model based predictive control for water-based floor heating in low energy residential buildings. *Building and Environment*, 2010, 46(3): 556 – 569.
- [9] YANG S, WAN M P, NG B F, et al. Experimental study of model predictive control for an air-conditioning system with dedicated outdoor air system. *Applied Energy*, 2019, 257: 113920.
- [10] SEONG C Y, WIDROW B. Neural dynamic optimization for control systems—part II. theory. *IEEE Transactions on Systems, Man, and Cybernetics. Part B*, 2001, 31(4): 502 – 513.
- [11] CAO Hua, ZHANG Jiugen. Energy saving analysis for variable frequency pump of cooling and chilled water in central air conditioning system. *Motor and Control Application*, 2014, 41(4): 62 – 66.  
(曹华, 张九根. 中央空调冷却水、冷冻水系统的变频节能分析. *电机与控制应用*, 2014, 41(4): 62 – 66.)
- [12] HUANG Yangchun. *Study of operation optimization for cold source System of central air-conditioning based on TRNSYS*. Guangzhou: South China University of Technology, 2015.  
(黄扬春. 基于TRNSYS的中央空调冷源系统运行优化研究. 广州: 华南理工大学, 2015.)
- [13] AFRAM A, JANABI-SHARIFI F. Review of modeling methods for HVAC systems. *Applied Thermal Engineering*, 2014, 67(1/2): 507 – 519.
- [14] FAN Jiahua, MA Lei, ZHOU Pan, et al. Modeling and control of piezoelectric actuator based on radial basis function neural network. *Control Theory & Applications*, 2016, 33(7): 856 – 862.  
(范家华, 马磊, 周攀, 等. 基于径向神经网络的压电作动器建模与控制. *控制理论与应用*, 2016, 33(7): 856 – 862.)
- [15] ZHANG Shuning, WANG Fuli, HE Dakuo, et al. Modeling method of online robust least-squares-support-vector regression. *Control Theory & Applications*, 2011, 28(11): 1601 – 1606.  
(张淑宁, 王福利, 何大阔, 等. 在线鲁棒最小二乘支持向量机回归建模. *控制理论与应用*, 2011, 28(11): 1601 – 1606.)
- [16] SAUERBREI W, SCHUMACHER M. A bootstrap resampling procedure for model building: application to the Cox regression model. *Statistics in Medicine*, 2010, 11(16): 2093 – 2109.
- [17] ANWER N, BALLU A, MATHIEU L. The skin model, a comprehensive geometric model for engineering design. *CIRP Annals - Manufacturing Technology*, 2013, 62(1): 143 – 146.
- [18] ZLATANOVIC I, GLIGOREVIC K, IVANOVIC S, et al. Energy-saving estimation model for hypermarket HVAC systems applications. *Energy & Buildings*, 2011, 43(12): 3353 – 3359.

- [19] 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. *Energy & Buildings*, 2017, DOI: 10.1016/j.enbuild.2017.02.012.
- [20] KUSIAK A, XU G, TANG F. Optimization of an HVAC system with a strength multi-objective particle-swarm algorithm. *Energy*, 2011, 36(10): 5935 – 5943.
- [21] YAN Xiulian. *Variable static pressure variable air supply temperature control based on PLS load forecasting in air-conditioning system*. Xi'an University of Architecture and Technology, 2013. (闫秀联. 基于PLS负荷预测的空调变静压变送风温度控制. 西安建筑科技大学, 2013.)
- [22] NISHIDA T. Data transformation and normalization. *Rinsho Byori the Japanese Journal of Clinical Pathology*, 2010, 58(10): 990 – 997.
- [23] JING-WEN H U, AMP F R, UNIVERSITY T V. Predictive modeling of surface skewness and kurtosis based on BP neural network. *Surface Technology*, 2017, 46(2): 235 – 239.
- [24] JAHIRUL M I, 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. *Modsim International Congress on Modelling & Simulation*, 2013: 1561 – 1567.
- [25] RAVA E, CHIRWA E M. Prediction of performance of the moving-bed biofilm pilot reactor using back-propagation artificial neural network (BP-ANN). *Chemical Engineering Transactions*, 2017, 61: 1189 – 1194.
- [26] NG B C, DARUS I Z M, JAMALUDDIN H, et al. Application of adaptive neural predictive control for an automotive air conditioning system. *Applied Thermal Engineering*, 2014, 73(1): 1244 – 1254.
- [27] HUANG H, CHEN L, HU E. A neural network-based multi-zone modelling approach for predictive control system design in commercial buildings. *Energy & Buildings*, 2015, DOI: 10.1016/j.enbuild.2015.03.045.
- [28] SAINI L M. Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks. *Electric Power Systems Research*, 2008, 78(7): 1302 – 1310.
- [29] SEONG C Y, WIDROW B. Neural dynamic optimization for control systems—part I: theory. *IEEE Transactions on Systems Man & Cybernetics Part B*, 2001, 31(4): 490 – 501.
- [30] SUN P, WANG L P, JIANG Z Q, et al. Application of two multi-dimensional dynamic programming algorithms in optimization of cascade reservoirs operation. *Journal of Hydraulic Engineering*, 2014, 45(11): 1327 – 1335.
- [31] ITO K, KUNISCH K. A variational approach to sparsity optimization based on Lagrange multiplier theory. *Inverse Problems*, 2014, 30(1): 15001 – 15023.
- [32] HONG H, TSANGARATOS P, ILIA I, et al. Introducing a novel multi-layer perceptron network based on stochastic gradient descent optimized by a meta-heuristic algorithm for landslide susceptibility mapping. *Science of the Total Environment*, 2020, 742: 140549.
- [33] BHRRAWY A H, EZZ-ELDIEN S S. A new Legendre operational technique for delay fractional optimal control problems. *Calcolo*, 2016, 53(4): 521 – 543.
- [34] AZAD N L, MOZAFFARI A, FATHI A. An optimal learning-based controller derived from Hamiltonian function combined with a cellular searching strategy for automotive coldstart emissions. *International Journal of Machine Learning and Cybernetics*, 2017, 8: 955 – 979.

#### 作者简介:

**魏东** 教授, 博士, 建筑大数据智能处理研究北京市重点实验室副主任, 目前研究方向为建筑节能与安全监控理论与工程, E-mail: weidong@bucea.edu.cn;

**焦焕炎** 硕士研究生, 目前研究方向为建筑节能与安全监控理论与工程, E-mail: jiaohuanyan@foxmail.com;

**冯浩东** 硕士研究生, 目前研究方向为建筑节能与安全监控理论与工程, E-mail: fenghaodong@foxmail.com.