

1-2-2019

## Optimizing Control of Total Heat Supply Based on Machine Learning

Li Qi

*School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China;*

Xingqi Hu

*School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China;*

Jianmin Zhao

*School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China;*

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



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

---

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

---

## Optimizing Control of Total Heat Supply Based on Machine Learning

### Abstract

**Abstract:** The central heating system has complex structure, along with the characteristics of hysteresis, strong coupling and nonlinear. Contraposing the problem that the process is difficult to be identified and controlled by the mechanism modeling, an optimal control method of heat source total heat production based on machine learning is proposed. *The heat source model of central heating system is established by BP neural network and long short-term memory neural network.* Under the premise of meeting the demand of heating quality, with the total energy consumption as the optimization objective, the optimal control sequence of water supply temperature and water flow at heat source is obtained *by the action-dependent dual heuristic programming (ADDHP) algorithm.* The simulation analysis shows that, the established heat source model can effectively identify the heat source production process, and the ADDHP control method can achieve the optimal control of total heat production of heat source.

### Keywords

machine learning, long short-term memory neural network, action-dependent dual heuristic programming, heat source, optimal control

### Recommended Citation

Li Qi, Hu Xingqi, Zhao Jianmin. Optimizing Control of Total Heat Supply Based on Machine Learning[J]. Journal of System Simulation, 2018, 30(3): 1134-1143.

# 基于机器学习的热源总供热量优化控制

李琦, 户杏启, 赵建敏

(内蒙古科技大学信息工程学院, 内蒙古 包头 014010)

**摘要:** 集中供热系统结构复杂, 存在严重的滞后性、强耦合性、非线性, 针对其难以通过机理建模进行辨识和控制的问题, 提出一种基于机器学习的热源总热量生产优化控制方法。分别利用BP(Back Propagation)和长短时记忆神经网络建立集中供热系统的热源模型, 在满足供热质量的前提下, 以供热总能耗为优化目标, 通过执行依赖双启发式动态规划(Action-Dependent Dual Heuristic Programming, ADDHP)算法, 得到热源处供水温度和供水流量的优化控制序列。仿真分析表明, 建立的热源模型能有效辨识热源生产过程, ADDHP控制方法能够实现热源总热量生产的最优控制。

**关键词:** 机器学习; 长短时记忆神经网络; 执行依赖双启发式动态规划; 热源; 优化控制

中图分类号: TP301

文献标识码: A

文章编号: 1004-731X (2018) 03-1134-10

DOI: 10.16182/j.issn1004731x.joss.201803046

## Optimizing Control of Total Heat Supply Based on Machine Learning

Li Qi, Hu Xingqi, Zhao Jianmin

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

**Abstract:** The central heating system has complex structure, along with the characteristics of hysteresis, strong coupling and nonlinear. Contraposing the problem that the process is difficult to be identified and controlled by the mechanism modeling, an optimal control method of heat source total heat production based on machine learning is proposed. The heat source model of central heating system is established by BP neural network and long short-term memory neural network. Under the premise of meeting the demand of heating quality, with the total energy consumption as the optimization objective, the optimal control sequence of water supply temperature and water flow at heat source is obtained by the action-dependent dual heuristic programming (ADDHP) algorithm. The simulation analysis shows that, the established heat source model can effectively identify the heat source production process, and the ADDHP control method can achieve the optimal control of total heat production of heat source.

**Keywords:** machine learning; long short-term memory neural network; action-dependent dual heuristic programming; heat source; optimal control

## 引言

城市集中供热系统具有节能、高效、环保等

优点, 是城市现代化的重要基础设施之一, 但由于我国建筑能耗占社会总能耗的 30%, 单位面积供热能耗是发达国家的倍数, 由于集中供热系统每年都要消耗巨大的燃煤和电能, 因此研究节能高效的集中供热系统优化控制算法, 实现按需供热的控制目标, 已成为国内外科研究的重点<sup>[1]</sup>。

国内外研究学者对集中供热系统的运行调节



收稿日期: 2017-05-16 修回日期: 2017-06-21;  
作者简介: 李琦(1973-), 男, 陕西米脂, 硕士, 教授, 研究方向为复杂工业过程优化控制、嵌入式及物联网应用; 户杏启(1992-), 女, 河北保定, 硕士生, 研究方向为控制算法优化; 赵建敏(1982-), 男, 内蒙古土左旗, 硕士, 研究方向为图像处理、人工智能。

<http://www.china-simulation.com>

• 1134 •

与优化控制进行了大量丰富的研究, Edward O'Dwyer<sup>[2]</sup>提出了一种模型预测控制的方法, 对供暖系统进行建模与扰动估计。魏宇杰<sup>[3]</sup>从节约能耗的角度采用递推最小二乘法建立集中供热系统的仿真模型, 用广义预测控制方法追踪回水温度的设定值, 对集中供热系统进行滚动优化。王源<sup>[4]</sup>提出供热系统管网模型优化控制算法, 并验证了其模型和优化控制算法的可行性。楼海雷<sup>[5]</sup>等对质量并调在热网中的应用进行了描述, 并提出通过水泵的变频调节方式, 实现了质量并调。李丽<sup>[6]</sup>通过热力学分析得到热电联产是较为节能的供热方式, 建立了集中供热系统能耗分析的数学模型, 并对供热系统进行了优化。

集中供热系统的非线性和复杂性使得其模型难以建立, 传统的机理建模难以进行辨识和控制, 建模效果不理想, 而神经网络具有强大的拟合能力, 能挖掘数据中的内在信息, 非常适用于集中供热系统辨识研究。因此本文采用 BP 神经网络和长短时记忆<sup>[7]</sup>(Long Short-Term Memory, LSTM)神经网络分别建立热源处模型, 为接下来的优化控制做准备。

自适应动态规划算法<sup>[8]</sup>(Adaptive Dynamic Programming, ADP)利用离线和在线数据, 采用神经网络逼近动态规划中的性能指标函数和控制策

略, 进而满足最优性原理, 能够有效克服“维数灾难”问题, 具有精度高、收敛快、稳定性好等特点。本文将执行依赖双启发式动规划(Action-Dependent Dual Heuristic Programming, ADDHP)算法应用到集中供热系统热源总热量生产中, 以节能降耗为供热系统的优化目标, 建立以供水温度和供水流量为变量的总能耗数学表达式, 作为控制算法中的效用函数, 采用 ADDHP 算法进行训练, 进而得到热源处供水温度和供水流量的优化控制序列, 实现对热源总供热量的最优跟踪控制。

## 1 基于 ADDHP 的集中供热系统热源优化控制总体方案

### 1.1 集中供热系统的生产工艺

集中供热是将热水或者蒸汽作为热媒, 由一个或多个热源利用热网给城市、镇或区域热用户供应热能的形式。城市集中供热系统由热源、供热管网、热力站及热用户 4 个部分构成。热源产生的热能利用热蒸汽和热水等介质, 沿着一次管网到达各个热力站, 热力站通过热交换器将热能分配给二次管网, 二次管网再将热能传递给热用户。集中供热系统总体结构图如图 1 所示。




图 1 集中供热系统总体结构图

Fig. 1 General structure diagram of central heating system

集中供热系统的运行调节与优化控制主要包括两部分内容,一个是供热系统总热量的生产优化问题,另一个是热源的热量对各热力站的热量分配问题。本文负责解决热源总热量生产的优化控制问题,运行方式采用质量并调的调节方式,保证热源生产的总热量达到热用户的用热需求且实现节能降耗的优化控制目标,具体表现为热源一次侧供水温度和供水流量的设定值优化问题。

### 1.2 执行依赖双启发式动态规划原理

ADP 是由 Werbos 于 1977 年提出,采用非线性函数拟合方法逼近动态规划的性能指标,为解决高维复杂非线性系统的最优控制问题提供了一种切实可行的理论和方法。

ADDHP 是近似动态规划 4 种基本结构中的一种,其主要由 3 部分组成:模型网络、执行网络、评价网络。每一部分均可由神经网络代替,本文中模型网络是通过神经网络建立,执行网络和评价网络通过 RNN 实现,执行网络用来近似最优控制策略,评价网络用来近似最优性能指标函数。

ADDHP 的评价网络以状态量和控制量作为输入,其输出为性能指标函数  $J(k)$  对状态量  $x(k)$  的导数,相比 DHP,控制精度更高。

ADDHP 的结构图如图 2 所示。




图 2 ADDHP 结构图  
Fig. 2 ADDHP structure diagram

图 2 中:  $x(k)$ :  $k$  阶段的状态变量,即  $k$  阶段的回水温度;  $v(k)$ :  $k$  阶段的室外气温;  $u(k)$ :  $k$  阶段的控制变量,即  $k$  阶段的供水温度和供水流量。输出  $k+1$  阶段的回水温度,  $k+1$  阶段的供水温度和供水流量又作为评价网络的输入,得到  $k$  阶段和  $k+1$  阶段的性能指标函数  $J(x(k))$ ,

$J(x(k+1))$ ,  $U(x(k), u(k))$  为  $k$  阶段的效用函数,通过调节两个阶段的性能指标函数与效用函数之间的偏差来实现热源总热量生产的优化控制。

## 2 集中供热系统的热源模型

集中供热系统模型建立的好坏关系到整个系统能否合理的运行调节与优化调度,为保证模型能够满足热源总供热量的优化生产,本文分别采用 BP 和 LSTM 神经网络对集中供热系统热源处进行建模,最后比较建模效果,找到合适的建模方法。

### 2.1 神经网络介绍

#### 2.1.1 BP 神经网络

BP 神经网络是一种多层前馈神经网络,该网络的特点是信号向前传递,误差反向传播。在前向传递中,输入信号从输入层经隐含层逐层处理,直至输出层。每一层的神经元状态只影响下一层神经元状态。如果输出层得不到期望输出,则转入反向传播,根据预测误差调整网络权值和阈值,从而使 BP 神经网络预测输出不断逼近期望输出。BP 神经网络的拓扑结构如图 3 所示。




图 3 BP 神经网络拓扑结构图  
Fig. 3 Topological structure of BP neural network

#### 2.1.2 LSTM 神经网络

在深度学习领域,循环神经网络(Recurrent Neural Network, RNN)具有记忆和储存功能<sup>[9-10]</sup>,传统的神经网络模型没有考虑数据之间的关联性,信息都是从输入层到隐层,隐层到输出层,层与层之间是全连接的,但每层的节点是无连接的,而 RNN 将上一个时刻的隐含层数据作为当前时刻的输入,从而允许时间维度上的信息得以保留。考虑

了前面样本数据对其后面样本数据的影响,对于热网供热这样的时序数据具有很好的拟合能力。RNN 网络结构图如图 4 所示。其中,当前时刻隐层的输入不仅包括当前时刻输入层的输出,还包括上一时刻隐层的输出。




图 4 RNN 网络结构

Fig. 4 RNN network structure

循环神经网络用来处理时间序列数据,隐含层各个节点同时包括对过去时刻序列元素的记忆信息,但如果循环神经网络的输入序列太长,则会导致梯度暴涨或消失,LSTM 能够有效解决此问题。

为保证神经网络建模效果,需要对神经网络的输入参数、隐藏层规模、结构层数、输出参数进行合理的设计。

## 2.2 输入输出变量

对集中供热系统热源处运行工况分析可知<sup>[11-12]</sup>,热源处下一阶段的状态量主要是由当前阶段的状态量与当前阶段的控制量决定的,同时室外气温也会对供热系统热源处的总供热量产生影响,所以将当前时刻的气温、当前时刻热源一次侧供水温度、

当前时刻热源一次侧供水流量、当前时刻热源一次侧回水温度作为模型的输入变量,回水温度作为一个状态变量能够反应实际供热系统的供热质量,将其作为模型的输出变量,建立一个 4 输入 1 输出的神经网络模型。

## 2.3 样本数据

本文所用数据(除气温)来源于包头市某热力公司旗下的包铝电厂,气温是通过 Python 爬取中国天气网获得。由于设备误差造成个别数据不合理,记录错误数据出现的时刻,用前后 10 min 数据的平均值代替。选取该厂热源 2014-11-01~2015-03-15 及 2015-10-20~2016-03-20 共 6 800 组数据,所有数据都以小时为间隔,选取 6 300 组数据作为训练数据集,500 组数据作为测试数据集,样本数据如表 1。

## 2.4 神经网络的结构和参数

### 2.4.1 BP 神经网络建模

集中供热系统热源模型采用 3-8-1 结构,通过大量实验分析得出 BP 神经网络模型参数如表 2 所示,其中隐含层节点数设置为 8;最大训练迭代次数 epochs 设置为 1 000;学习率 lr 设置为 0.1;训练偏差 goal 为 0.004;隐藏层采用双极性 sigmoidal 函数,输出层采用线性 purelin。

BP 神经网络训练流程图如图 5 所示。

表 1 样本数据  
Tab. 1 Sample data

序号	供水温度/°C	供水流量/(t/h)	室外温度/°C	回水温度/°C	下一时刻回水温度/°C
1	67.4	1 941.22	1.9	42.6	42.7
2	63.8	1 935.86	1.6	42.7	42.9
3	60.9	1 938.82	2.3	42.9	43.0
4	60.8	1 935.47	3.0	43.0	43.2
5	61.1	1 936.55	3.7	43.2	43.9
6	54.4	1 921.95	13.1	43.9	43.6
...	...	...	...	...	...
6798	48.6	1 940.62	-0.1	46.2	46.2
6799	48.4	1 941.92	-0.4	46.2	46.3
6800	48.3	1 942.67	0.4	46.3	46.2

表 2 BP 神经网络模型参数设置表

参数	值
输入参数	4
输出参数	1
隐藏层节点个数	8
epochs	1 000
lr	0.1
goal	0.004

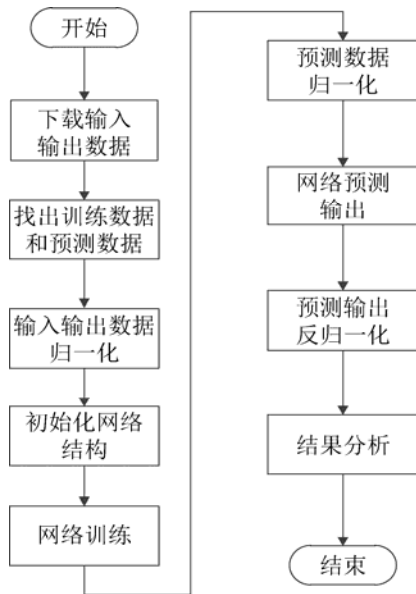


图 5 BP 神经网络训练流程图

Fig. 5 Training flow chart of BP neural network

得到的供热系统热源处回水温度泛化能力测试图如图 6 所示。

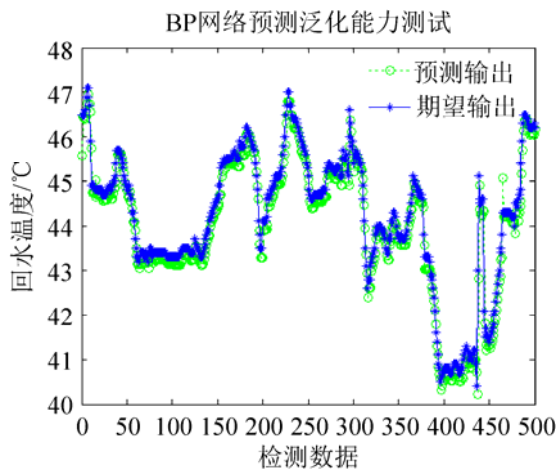


图 6 集中供热系统模型泛化能力测试

Fig. 6 Generalization ability test of district heating system model

### 2.4.2 LSTM 神经网络建模

采用 Google 公司的开源深度学习计算框架 Tensorflow 进行 LSTM 神经网络模型的搭建，编写 Python 程序，搭建热源模型。

LSTM 神经网络建立的模型网络如图 7。




图 7 基于 LSTM 集中供热系统的热源模型

Fig. 7 Heat source model of central heating system based on LSTM

图 7 中： $u_1(k)$ ： $k$  时刻的供水温度； $u_2(k)$ ： $k$  时刻的供水流量； $x(k)$ ： $k$  时刻的回水温度； $v(k)$ ： $k$  时刻的室外气温； $x(k+1)$ ： $k+1$  时刻的回水温度； $W_{in}$ ：模型网络输入层到隐含层的权值； $W_{out}$ ：模型网络隐含层到输出层的权值。

LSTM 神经网络隐藏层单元个数无法通过固定的公式来确定，故采用试凑法，即先从较少的隐含层细胞单元个数进行训练，然后逐渐增加 LSTM 神经网络细胞单元个数，最终设置隐藏层细胞单元个数为 70。同理应用试凑法设置 LSTM 神经网络结构层数为 2。通过大量实验分析得出 LSTM 神经网络模型参数如表 3 所示，其中 rnn\_unit 为隐层细胞单元个数设置为 70；input\_size 为输入数据的维度为 4；num\_layers 为 LSTM 结构的层数为 2；output\_size 为输出数据的维度为 1；learning\_rate 为学习率设置为 0.001；batch\_size 为每一批次训练样例个数设置为 60；time\_step 为时间步设置为 20；epochs 是网络训练最大迭代次数，设为 3 000；激活函数采用 tanh；训练函数采用随机梯度下降法。

LSTM 神经网络训练流程图如图 8 所示。

表 3 LSTM 神经网络模型参数设置表  
Tab. 3 Parameter setting table  
of LSTM neural network model

参数	值	参数	值
rnn_unit	70	batch_size	60
input_size	4	time_step	20
num_layers	2	epochs	3 000
output_size	1	activation	tanh
learning_rate	0.001		

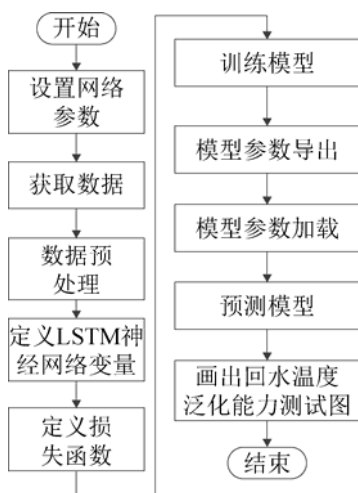


图 8 LSTM 神经网络训练流程图

Fig. 8 Training flow chart of LSTM neural network

集中供热系统热源模型泛化能力如图 9 所示。通过仿真实验结果可以看出, 本文建立的 LSTM 神经网络模型能够较好的反应热网实际生产工况。

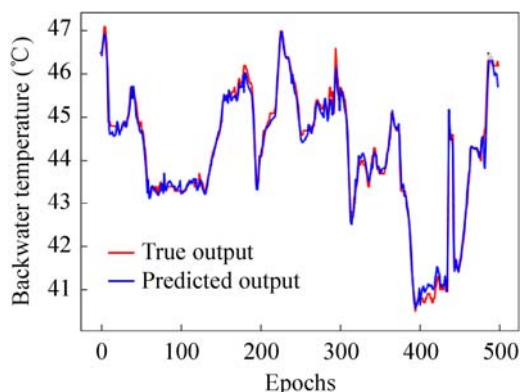


图 9 热源模型泛化能力测试

Fig. 9 Generalization ability test of heat source model

## 2.5 建模结果分析

BP 神经网络模型和 LSTM 神经网络模型预测误差结果如图 10 所示。

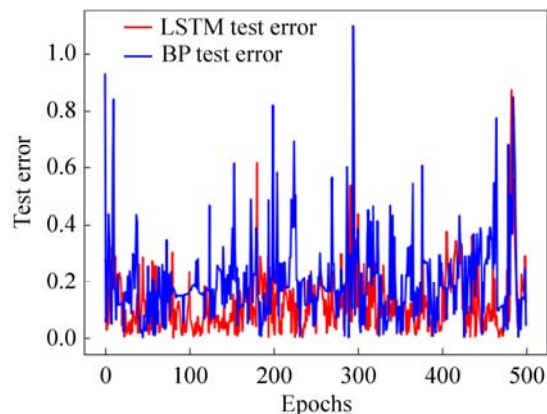


图 10 预测误差对比图

Fig. 10 Contrast chart of prediction error

由图 10 可看出, LSTM 神经网络模型预测误差显然比 BP 神经网络模型预测误差要小, 模型预测精度更高, 满足集中供热系统的要求, 所以采用 LSTM 神经网络对集中供热系统热源处进行建模。

## 3 ADDHP 优化控制器设计

### 3.1 ADDHP 算法训练过程

本文结合 ADDHP<sup>[13-14]</sup>算法优化供热系统热源处回水温度, 模型网络采用 LSTM, 执行网络、评价网络采用 RNN 建立, 所以算法优化训练过程即为神经网络权值更新过程。

ADDHP 算法的训练过程如下:

步骤 1: 确定执行网络及评价网络结构, 设置相关参数。

步骤 2: 通过 LSTM 建立热源模型作为模型网络。

步骤 3: 设置执行网络及评价网络权值, 折扣因子  $\gamma$ 、学习率  $l$ 、效用函数  $U(k)$ 。

步骤 4: 设置系统的初始状态变量  $x(k)$ , 并将其输入到执行网络, 得到当前时刻的控制变量  $u(k)$ 。

步骤 5: 给定系统初始状态, 将当前  $k$  时刻的状态变量  $x(k)$ 、气温  $v(k)$  和控制变量  $u(k)$  输入到模型网络中, 得到  $k+1$  时刻的状态变量  $x(k+1)$ 。

步骤 6: 将  $k+1$  时刻的状态变量  $x(k+1)$  和控制变量  $u(k+1)$  作为评价网络的输入, 评价网络输出为  $\frac{\partial J[x(k+1)]}{\partial x(k+1)}$ 。



步骤 7: 计算出执行网络的误差  $e_a(k) = \frac{\partial J(k)}{\partial u(k)}$

$\frac{\partial U(k)}{\partial u(k)} + \gamma \frac{\partial J(k+1)}{\partial u(k)}$  并更新其权值。

步骤 8: 将  $k$  时刻的状态变量  $x(k)$  和  $k$  时刻的控制变量  $u(k)$  作为评价网络的输入, 计算得到评价网络输出  $\frac{\partial J[x(k)]}{\partial x(k)}$ 。

步骤 9: 计算评价网络的误差  $e_c(k) = \frac{\partial J(k)}{\partial x(k)}$

$\frac{\partial U(k)}{\partial x(k)} - \gamma \frac{\partial J(k+1)}{\partial x(k)}$  并更新其权值。

步骤 10: 一次训练完成后返回步骤 5, 直到达到设定的最大迭代次数, 整个系统训练结束。

### 3.2 性能指标函数的确定

本文以供热能耗最小为优化控制目标<sup>[15]</sup>, 建立当前总能耗最小的目标函数, 利用 ADDHP 优化算法得到相应的供水温度和供水流量的优化控制序列。故性能指标函数为:

$$J[x(k), k] = U[x(k), u(k), k] \quad (1)$$

式中:  $J$  为性能指标函数;  $U$  为效用函数。效用函数  $U$  为热源供热总能耗, 主要包括循环泵的耗电量和燃料煤耗两部分<sup>[16]</sup>。

$$U = U_{\text{电}} + U_{\text{煤}} = P_{\text{泵}} \times J_{\text{电}} + B_h \times J_{\text{煤}} \quad (2)$$

循环水泵的电耗量计算式为:

$$U_{\text{电}} = P_{\text{泵}} \times J_{\text{电}} \quad (3)$$

$$P_{\text{泵}} = \frac{s}{3.6 \times 10^6 \times \eta_1} \times \left( \frac{G_1}{\rho} \right)^3 \quad (4)$$

式中:  $J_{\text{电}}$  为工业用电价格, 元/度;  $s$  为管网阻力特性系数,  $\text{Pa}/(\text{m}^3 \cdot \text{h}^{-1})^2$ ;  $G_1$  为管网流量,  $\text{t/h}$ ;  $\rho$  为泵送水的密度,  $\text{kg}/\text{m}^3$ ;  $\eta_1$  为水泵的效率。

本文选用热电联产作为热源形式, 能耗主要是煤耗, 故热源的每小时燃料消耗量计算公式为:

$$B_h = G_2 \frac{(h_b - h_g)}{\eta_b Q_{\text{net}}} \times \frac{1}{\eta_p \eta_h} \quad (5)$$

式中:  $G_2$  为热源首端供水流量,  $\text{t/h}$ ;  $h_b$  为过热器出口蒸汽比焓,  $\text{kJ/kg}$ ;  $h_g$  为锅炉给水焓值,  $\text{kJ/kg}$ ;  $\eta_b$  为锅炉效率;  $Q_{\text{net}}$  为燃料的低位发热量,  $\text{kg/h}$ ;

$\eta_p$  为管道效率;  $\eta_h$  为热网效率

故其性能指标函数表示为:

$$J(k) = \frac{s}{3.6 \times 10^6 \times \eta_1} \times \left( \frac{G_1}{\rho} \right)^3 \times J_{\text{电}} + \frac{G_2 (h_b - h_g)}{\eta_b Q_{\text{net}}} \times \frac{1}{\eta_p \eta_h} \times J_{\text{煤}} \quad (6)$$

$$\text{s.t.} \begin{cases} 60 \leq u_1(k) \leq 103 \\ 1000 \leq u_2(k) \leq 1980 \\ 40 \leq x_1(k) \leq 65 \\ -20 \leq x_2(k) \leq 20 \end{cases} \quad (7)$$

### 3.3 执行网络

本文中执行网络采用 1 输入 2 输出, 细胞单元个数即隐藏层规模为 50, LSTM 结构层数为 2 的神经网络结构, 输入为  $k$  时刻的回水温度序列, 输出为  $k$  时刻的供水温度序列和  $k$  时刻的供水流量序列。激活函数选择为 tanh 函数。

执行网络的训练以最小化  $J(k)$  为目标。训练过程分为两部分: 正向计算和反向误差传播。

正向计算:

$$a_{h1j}(k) = x(k) \cdot W_{a1ij}(k), \quad j = 1, 2, \dots, ku \quad (8)$$

$$a_{h2j}(k) = \tanh(a_{h1j}(k)), \quad j = 1, 2, \dots, ku \quad (9)$$

$$u_j(k) = \sum_{i=1}^{ku} \tanh(a_{h2j}(k)) \cdot W_{a2ij}(k), \quad j = 1, 2, \dots, m \quad (10)$$

式中:  $a_{h1j}(k)$  是执行网络隐含层第  $j$  个节点的输入;  $a_{h2j}(k)$  是执行网络隐含层第  $j$  个节点的输出;  $W_{a1}$  是输入层到隐含层的权值;  $W_{a2}$  隐含层到输出层的权值。

反向误差传播:

$$e_a(k) = \frac{\partial J(k)}{\partial u(k)} = \frac{\partial U(k)}{\partial u(k)} + \gamma \frac{\partial J(k+1)}{\partial u(k)} \quad (11)$$

$$\Delta W_a(k) = l_a(k) \cdot \left[ -\frac{\partial J(k)}{\partial w_a(k)} \right] \quad (12)$$

$$W_a(k+1) = W_a(k) + \Delta W_a(k) \quad (13)$$

### 3.4 评价网络

本文中评价网络采用 RNN 建立一个 3 输入 1 输出, 细胞单元个数即隐藏层规模为 50, LSTM 结

构层数为 2 的神经网络结构, 输入为  $k$  时刻的回水温度序列、 $k$  时刻的供水温度序列、 $k$  时刻的供水流量序列, 输出是对协状态  $\partial J(x(k))/\partial x(k)$  的估计, 将  $k$  时刻的协状态与  $k+1$  时刻的协状态求偏差, 通过最小化此偏差来实现对性能指标函数  $J(k)$  的近似。激活函数同样选择  $\tanh$  函数。

定义评价网络  $k$  时刻的输入向量为  $\text{inputC}(k)$ , 评价网络<sup>[17]</sup>的训练包括正向计算过程和误差的反向传播过程。

正向计算:

$$c_{h1j}(k) = x(k) \cdot w_{c11j}(k) \quad (14)$$

$$c_{h1j}(k) = \sum_{i=1}^{n+m} \text{inputC}_i(k) \cdot W_{c1ij}(k), \quad j = 1, 2, \dots, kj \quad (15)$$

$$c_{h2j}(k) = \tanh(c_{h1j}(k)), \quad j = 1, 2, \dots, kj \quad (16)$$

$$\lambda_i(k) = \sum_{j=1}^{kj} \tanh(c_{h2j}(k)) W_{c2j}(k), \quad i = 1, 2, \dots, n \quad (17)$$

式中:  $c_{h1j}(k)$  为评价网络隐含层第  $j$  个节点的输入;  $c_{h2j}(k)$  为评价网络隐含层第  $j$  个节点的输出;  $\lambda_i(k)$  为评价网络输出层第  $i$  个节点的输出。

反向误差传播:

$$e_c(k) = \lambda(k) - \frac{\partial^+ U(k)}{\partial x(k)} - \gamma \frac{\partial^+ J(k+1)}{\partial x(k)} \quad (18)$$

评价网络的权值更新过程:

$$\Delta w_c(k) = l_c(k) \cdot \left[ -\frac{\partial e_c(k)}{\partial w_c} \right] \quad (19)$$

$$w_c(k+1) = \Delta w_c(k) + w_c(k) \quad (20)$$

## 4 仿真结果

将第 3 小节中利用 LSTM 神经网络建立的集中供热系统热源模型, 作为 ADDHP 算法的模型网络, 将当前  $k$  时刻回水温度值  $x(k)$  设定为  $47.9^\circ\text{C}$ , 使用 Python 编程, 实现集中供热系统热源模型的建立及 ADDHP 优化控制器的设计, 通过对热源总热量生产的优化控制, 求解出在供热能耗最小时的供水温度  $u_1(k)$  和供水流量  $u_2(k)$  的优化控制序列<sup>[18]</sup>。仿真结果如图 11~12 所示。




图 11 ADDHP 求解热源优化供水温度的迭代过程  
Fig. 11 Iterative process of solving water supply temperature optimization of heat source with ADDHP




图 12 ADDHP 求解热源优化供水流量的迭代过程  
Fig. 12 Iterative process of solving water supply flow optimization of heat source with ADDHP

通过仿真结果可以看出, ADDHP 优化控制器最小化两个时刻的性能指标函数与效用函数的偏差以便调节 3 个神经网络的权值至最优的状态。在这个过程中, 前 25 个时间步曲线出现一定的波动, 经过不断学习训练使得整个系统收敛, 经过大约 25 个时间步后, ADDHP 各变化曲线逐渐趋于稳定, 且供水温度和供水流量都在合理的范围内变化。其中供水温度的稳定值为  $64.64^\circ\text{C}$ , 供水流量值稳定值为  $1590.6\text{ t/h}$ , 此时的回水温度的稳定值为  $48.3^\circ\text{C}$ 。将得到的值代入式(6)可以计算出当前时刻最小能耗费用为  $4192.8$  元, 再通过公式(1)可以计算出本文所参照供热系统的热源最优供热量  $109.9\text{GJ}$ 。目前供热公司大多采用人工经验方式调节热源供热量, 表 4 为人工经验调节与 ADDHP 优化控制结果对比。

表4 优化控制结果对比

Tab. 4 Comparison of optimal control results

对比项目	人工经验	ADDHP 优化
回水温度/(°C)	48.7	48.3
供水温度/(°C)	65.5	64.64
供水流量/(t/h)	1 628	1 590.6
热负荷/(GJ)	114.5	109.9
能耗/(元)	4 280.2	4 192.8

ADDHP 优化控制器比人工经验调节节省 2.1%，而且相比人工经验调节更加稳定、可靠。

## 5 结论

本文对集中供热系统热源总热量的优化控制主要从两方面进行了研究实验，首先通过对现有实际数据训练由 LSTM 神经网络建立的集中供热系统热源模型，然后在此模型的基础上设计了 ADDHP 优化控制器。通过对 ADDHP 控制器进行仿真实验，结果表明，ADDHP 算法具有较强的优化控制能力，收敛速度快、控制精度高，能够达到总供热量能耗最小的控制目标，实现了集中供热系统热源热量生产优化的目的，能够适应当前按需供热、节能降耗的要求，为后期的连续优化控制建立了基础。

## 参考文献:

- [1] 负海. 城市集中供热问题分析与探索[J]. 科技创新导报, 2013(16): 131.  
Yun Hai. The city central heating problem analysis and exploration of [J]. Technology Innovation Herald, 2013 (16): 131.
- [2] O'Dwyer E, Tommasi L D, Kouramas K, et al. Modelling and Disturbance Estimation for Model Predictive Control in Building Heating Systems[J]. Energy & Buildings(S0378-7788), 2016, 130: 532-545.
- [3] 魏宇杰. 集中供热系统控制策略研究[D]. 山西: 太原理工大学, 2015.  
Wei Yujie. Study on control strategy of central heating system [D]. Shanxi: Taiyuan University of Technology, 2015.
- [4] 王源. 城市集中供热系统建模及其控制方法研究[D]. 南京: 东南大学, 2013.  
Wang Yuan. Study on Modeling and control method of urban central heating system [D]. Nanjing: Southeast University, 2013.
- [5] 楼海雷, 高前东. 质量并调运行方式的实现与节能效果分析[J]. 区域供热, 2012, 1(5): 63-66.  
Lou yuan, Gao Qian Dong. Realization of quality adjustment and operation mode and analysis of energy saving effect [J]. regional heating, 2012, 1(5): 63-66.
- [6] 李丽. 集中供热系统的研究与优化[D]. 保定: 华北电力大学, 2009.  
Li Li. Research and optimization of central heating system [D]. Baoding: North China Electric Power University, 2009.
- [7] 郑泽宇, 顾思宇. TensorFlow 实战 Google 深度学习框架[M]. 1 版. 北京: 电子工业出版社, 2017: 199-210.  
Zheng Zeyu, Gu Siyu. TensorFlow, practical Google, deep learning framework, [M]. first edition. Beijing: Publishing House of electronics industry, 2017: 199-210.
- [8] 林晓峰, 宋绍剑, 宋春宁. 基于自适应动态规划的智能优化控制[M]. 北京: 科学出版社, 2013: 77-121.  
Lin Xiaofeng, Song Shaojian, Song Chuning. Intelligent optimization control based on adaptive dynamic programming[M]. Beijing: Science Press, 2013: 77-121.
- [9] 赵冬斌, 邵坤, 朱圆恒, 等. 深度强化学习综述: 兼论计算机围棋的发展[J]. 控制理论与应用, 2016, 33(6): 701-717.  
Zhao Dongbin, Shao Kun, Zhu Yuanheng, et al. A survey of depth reinforcement learning: also on the development of computer weiqi [J]. control theory and application, 2016, 33(6): 701-717.
- [10] 段艳杰, 吕宜生, 张杰, 等. 深度学习在控制领域的研究现状与展望[J]. 自动化学报, 2016, 42(5): 643-654.  
Duan Yanjie, Lü Yisheng, Zhang Jie, et al. Deep learning research status quo and Prospect [J]. Journal of automation in the field of control, 2016, 42(5): 643-654.
- [11] 杨建坤. 北方小城镇供热模式分析与热网优化控制的研究[D]. 上海: 同济大学, 2007.  
Yang Jiankun. Analysis of heating mode and optimization control of heat supply network in small towns in North China [D]. Shanghai: Tongji University, 2007.
- [12] 周守军. 基于管网动态模型的城市集中供热系统参数预测及运行优化研究[D]. 山东: 山东大学, 2012.  
Zhou Shoujun. Research on parameter prediction and operation optimization of urban central heating system based on pipe network dynamic model [D]. Shandong: Shandong University, 2012.

- [13] 冯小峰, 刘明波. 基于执行依赖启发式动态规划的紧急电压控制[J]. 华南理工大学学报(自然科学版), 2014, 42(4): 19-25, 58.  
Feng Xiaofeng, Liu Mingbo. Emergency voltage control based on execution dependent heuristic dynamic programming [J]. Journal of South China University of Technology (natural science edition), 2014, 42 (4): 19-25, 58.
- [14] Wang F Y, Zhang H, Liu D. Adaptive Dynamic Programming: An Introduction[J]. IEEE Computational Intelligence Magazine(S1556-603X), 2009, 4(2):39-47.
- [15] 魏庆来. 基于近似动态规划的非线性系统最优控制研究[D]. 沈阳: 东北大学, 2008.  
Wei Qinglai. Optimal control of nonlinear systems based on approximate dynamic programming Study [D]. Shenyang: Northeastern University, 2008.
- [16] Pirouti M, Bagdanavicius A, Ekanayake J, et al. Energy consumption and economic analyses of a district heating network[J]. Energy(S0360-5442), 2013, 57(8):149-159.
- [17] Prokhorov D V, Wunsch D C. Adaptive critic designs [J]. IEEE Transactions on neural Network(S1045-9227), 1997, 8(5): 997-1007.
- [18] Prokhorov D V, Wunsch D C. Adaptive critic designs.[J]. IEEE Transactions on Neural Networks, 1997, 8(5): 997-1007.
- [19] 唐巍. 基于质量并调的集中供热系统总供热量优化研究[D]. 包头: 内蒙古科技大学, 2016.  
Tang Wei. The total heating central heating system and the amount of quality optimization research based on [D]. Baotou: Inner Mongolia University of Science and Technology, 2016.

(上接第 1133 页)

- [12] 唐勇波, 彭涛, 熊印国, 等. 相对变换主元分析的变压器油击穿电压预测[J]. 仪器仪表学报, 2015, 36(7): 1640-1645.  
Tang Yongbo, Peng Tao, Xiong Yinguo, et al. Prediction method for breakdown voltage of transformer oil based on relative transformation principal component analysis[J]. Chinese Journal of Scientific Instrument, 2015, 36(7): 1640-1645.
- [13] 张彪, 邢健峰, 纪志成. 基于优化 SVM 的反渗透脱盐水故障诊断[J]. 系统仿真学报, 2015, 27(5): 1057-1063.  
Zhang Biao, Xing Jianfeng, Ji Zhicheng. Fault diagnosis of reverse osmosis water desalination based on optimized support vector machine [J]. Journal of System Simulation, 2015, 27(5): 1057-1063.
- [14] 唐贤伦, 周维, 张衡, 等. 一种基于多目标混沌 PSO 的机器人足球防守策略[J]. 系统仿真学报, 2014, 26(1): 51-55, 61.  
Tang Xianlun, Zhou Wei, Zhang Heng, et al. Robot soccer defensive strategy based on multi-objective chaotic PSO [J]. Journal of System Simulation, 2014, 26(1): 51-55, 61.
- [15] 唐勇波, 桂卫华, 彭涛, 等. PCA 和 KICA 特征提取的变压器故障诊断模型[J]. 高电压技术, 2014, 40(2): 557-563.  
Tang Yongbo, Gui Weihua, Peng tao, et al. Transformer fault diagnosis model based on PCA and KICA feature extraction [J]. High Voltage Engineering, 2014, 40(2): 557-563.
- [16] 尹金良. 基于相关向量机的油浸式电力变压器故障诊断方法研究[D]. 保定: 华北电力大学, 2013.  
Yin Jinliang. Study on oil-immersed power transformer fault diagnosis based on relevance vector machine [D]. Baoding: North China Electric Power University, 2013.
- [17] 唐勇波. 数据驱动的大型电力变压器故障诊断和预测研究[D]. 长沙: 中南大学, 2013.  
Tang Yongbo. Data-driven fault diagnosis and prediction for large-scale power transformer[D]. Changsha: Central South University, 2013.