

# 建筑物供暖节能中的 智能控制技术研究

文 西安建筑科技大学信控学院 任庆昌 于军琪 冯增喜 钱 荣

**【摘要】**我国北方地区是以集中供热的方式取暖,建筑物中供暖的能耗占总能耗的60%左右。研究在间歇式供暖方式下,整个供暖系统预热时间的精确控制既关乎燃料的消耗,又关乎环境的舒适性。因此文中基于热力学原理,得出了间歇供暖加热的数学模型,建立了预热时间的神经网络模型,提出了供暖系统最佳启停的自校正控制算法,对建筑物中的节能与温度环境的舒适性产生显著效果,具有重要的经济效益与社会效益。

**【关键词】**间歇式供暖 预热时间 智能控制 自校正控制

**建**筑能耗通常是指建筑物使用过程中消耗的能源,主要包括采暖、空调、降温、热水供应、炊事、家用电器和照明等能耗。据统计,欧美发达国家建筑能耗一般占到全国总能耗的30%~40%;在我国,建筑使用的能耗占全国能耗总量的37%。其中,建筑供暖的能耗占建筑能耗的比重相当大。我国的供暖技术比较落后,在设计、安装、运行、管理和设备生产,特别是供暖节能方面需要进行研究和提高。

按建筑物使用性质的不同,供暖制度可分为两大类:其一是连续供暖制度,即每天24小时内都是使用时间,要求室内平均温度全天都保持设定温度。其二是间歇供暖,即每天的使用时间并不是24小时,只求在使用时间内的室内平均温度保持设定温度;实际中,由于有些地方在夜间不工作,故在夜里不需要供暖系统设备运行,因而在夜间就不需要开放供暖系统,但是为了保证工作开始时室内环境的舒适,就需要提前对建筑进行预热。但是,如果预热的时间过长,将会造成能源的极大浪费;如果预热的时间过短,建筑物内部温度将达不到设定的温度,从而就会影响人们的健康。所以,通过对供暖系统最佳启停时间的计算和控制,可以在保证环境舒适的前提下,缩短不必要的供暖系统启动时间,达到节能的目的。

本文就是在间歇供暖的前提下,建立了需要预热房间的模型,在某小区统计的11月~3月共151组

数据的基础上,通过Matlab工具箱,利用神经网络技术对其进行了辨识和仿真。

## 1 供暖预热房间对象的模型

由于热源及建筑物存在着一定的热惯性,因此在房间使用之前必须给定一个时间段(即预热时间)提前启动热源系统,使得在房间使用时,其内部温度恰好处于人们感觉舒适的水平范围内。那么,预热时间究竟要多长,这只能通过估计得到。从图1上分析可知,对预热时间过长的估计(即 $t_p=t_1-t_0$ 的估计值大于实际值)会使在工作期末到来前房间的温度已经达到了舒适温度,这将导致燃料的浪费;反之,对预热时间估计不足(即 $t_p$ 的估计值小于实际值)将使在工作期到来时房间的温度还未达到舒适温度,这使人觉得不舒适。因此,应对预热时间 $t_p$ 进行精确的估计。

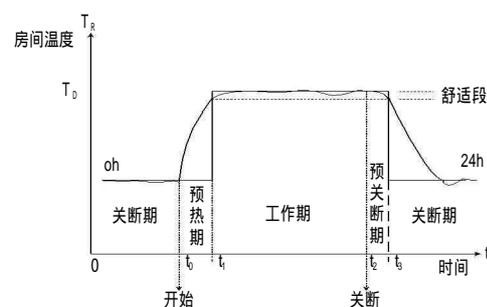


图1 热源系统的操作方式图

依据热力学第一定律和该定律与实际温度测量系统的一致性,能得到热力系统结构化和动态化时变规律(Wellstead, 1979)。因此,我们可以得到每个被加热区域的简化数学模型。

关于房间温度  $T_r$  及建筑物墙体温度  $T_b$  随时间变化的微分方程为:

$$\frac{dT_r}{d\tau} + \frac{T_r}{\tau_r} = \frac{Q_h}{C_r} + \frac{T_o}{C_r R_o} + \frac{T_b}{C_r R_s} \quad (1)$$

$$\frac{dT_b}{d\tau} + \frac{T_b}{\tau_s} = \frac{T_s}{C_s R_s} + \frac{T_o}{C_s R_{so}} \quad (2)$$

式中  $R$  为线性热阻,  $C$  为储存热容,  $T_o$  为室外气温,  $\tau_r$  为房间时间常数, 由下式决定

$$\tau_r = \frac{C_r R_s R_o}{R_s + R_o};$$

$\tau_s$  为房间结构常数, 由下式决定:

$$\tau_s = \frac{C_s R_s R_{so}}{R_s + R_{so}};$$

其中,  $\tau_s \gg \tau_r$ , 且  $R_{so} \gg R_o \gg R_s$ 。综合考虑以上因素,并考虑到实验的可能性,A.L.DEXTER对(1)(2)式简化改进如下:

$$\tau_1 \frac{dT_r(t)}{dt} + T_r(t) = \tau_1 R_1 \frac{dQ_h(t)}{dt} + (R_1 + R_2)Q_h(t) + T_o(t) \quad (3)$$

式中,  $\tau_1 = C_b R_2$ ,  $C_b$  为房间结构热容,  $R_1$  为内部线性热阻,  $R_2$  为外部线性热阻。

一般来说, 建筑物的温度在开启热源以前的变化是非常慢的。因此, 由(3)式可知, 在热源开启之后  $t$  时刻 ( $t > 0$ ) 的房间温度为:

$$T_r(t) = Q_h \{R_1 + R_2(1 - e^{-t/\tau_1})\} + T_b(t) \quad (4)$$

式中  $T_b(t)$  为房间墙体结构温度, 其取值可由下式定义:

$$\tau_1 \frac{dT_b(t)}{dt} + T_b(t) = T_o(t) \quad (5)$$

对于理想预加热控制, 起始时刻  $t=0$ ;  $T_r(t)=T_d$ ,  $T_d$  是房间期望温度。因此预加热时间的初值可由下式获得:

$$t_p(0) = \tau_1 \ln \left\{ \frac{R_2 Q_h}{Q_h (R_1 + R_2) - T_d + T_b(0)} \right\} \quad (6)$$

这个等式在参数上是非线性的, 且在自调节控制方案中不易实现。然而, 预加热时间通常要比房间的时间常数短的多, 当  $e^{-t_p/\tau_1} \approx 1 - t_p/\tau_1$  时, 上式可以更加简化为  $t_p(0) = \frac{\tau_1}{Q_h R_2} \{T_d - Q_h R_1 - T_b(0)\}$ 。

$Q_h$  和  $R$  代表热源系统能量和建筑物绝热品质。通常, 它可以设计的比期望值高一些。这样上式近似为

$$t_p(0) = k_1 + k_2 T_b(0) \quad (7)$$

迄今为止, 热输入  $Q_h$  对于房间或供热区域来说被认为是连续的, 然而供热源开启后, 它需要一段时间才能达到所需要的稳定输出。这个影响和房间惯性一起作用, 使得房间温度对热源的响应存在着一个时间死区。这种现象在整个采暖季节中都会存在, 并且是相似的。考虑上述影响, 于是等式(7)变为:

$$t_p(0) = \left\{ \frac{T_d - Q_h / Hi - T_b(0)}{Q_h \sqrt{4R_e / \Pi C_e}} \right\}^2$$

或者,  $t_p(0) = k_3 + k_4 T_b(0) + k_5 T_b^2(0) \quad (8)$

这是一个包含有线性情况的非线性关系式, 式中包含了线性特例(7)式。然而在这个结论中忽略了不可测扰动的可能性。因此, 用一个简单的首一非零滑动平均噪声过程来描述这个扰动在预加热时间模型中的影响。

考虑到以上因素, 如果用离散形式重写(8)式, 则预加热时间模型在第  $n$  时刻的采样值可用等式(9)表示:

$$t_p(n) = k_6 + k_7 T_b(n) + k_8 T_b(n)^2 + e(n) + k_9 e(n-1) \quad (9)$$

$e(n)$  取自零均值独立噪声序列。

## 2 神经网络预测器在供热系统预热时间预报中的应用

神经网络预测是根据系统当前的输入、输出信息来辨识系统的模型, 然后预测未来的输出值。因此在本文中的神经网络预测分为两步: 一是辨识模型; 二是利用所辨识的模型进行预测, 评估模型的性能。关于系统预测模型的辨识, 本文的辨识方法采用改进的BP算法, 考虑到辨识过程中的局部极小值问题和训练的时间问题, 故采用了动量法和快速BP算法, 这是因为动量法降低了网络对于误差曲面局部细节的敏感性, 有效地抑制了网络陷于局部极小。而快速BP算法, 可以有效的解决BP算法训练时间太长的问题。具体模型辨识步骤分为以下三步: (1) 网络模型结构的确定; (2) 输入输出数据的处理; (3) 网络的训练。

### 2.1 网络模型结构的确定

考虑对预热时间影响的主要因素以及时间序列

预测的思想,本文采用的输入节点有:建筑物墙体温度  $T_b$ 、 $T_b^2$ 、前一天的预热时间  $t_p^{(n-1)}$ 、前两天的预热时间  $t_p^{(n-2)}$ ;输出节点是当天的预热时间  $t_p^{(n)}$ 。人工神经网络选择3层前向网络,即为输入层,隐含层和输出层。输入层到隐含层的激活函数采用双曲正切S型传递函数,隐含层到输出层采用线性传递函数。隐含层利用2n+1的规则,采用9个神经元,也就是模型结构为4:9:1的三层网络结构(如图2)。

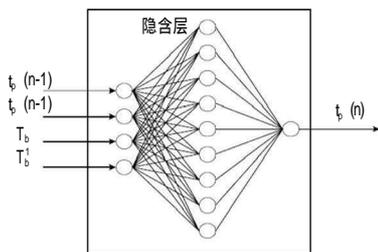


图2 输入模型结构图

其中,  $T_b$  为建筑物墙体温度;  $T_b^2$  为建筑物墙体温度  $T_b$  的平方;  $t_p^{(n-1)}$  为前一天的预热时间;  $t_p^{(n-2)}$  为前两天的预热时间;  $t_p^{(n)}$  为当天的预热时间。

## 2.2 输入输出数据的处理

输入节点有四个:  $T_b$ 、 $T_b^2$ 、 $t_p^{(n-1)}$ 、 $t_p^{(n-2)}$ , 输出节点为预热时间  $t_p^{(n)}$ , 下面分别进行处理。样本数据预处理。根据神经网络“类似输入产生类似输出”的原理,神经网络知识的获取只能从学习样本中得到,因此学习样本的数量和质量是影响神经网络学习效果和学习速度的重要因素。如果学习样本本身带有较大误差和干扰,则将对ANN模型将造成如下三个方面的负面影响:

(1)训练期间,非法数据带来大的训练误差,使网络不能收敛到理想误差;

(2)即使网络能够收敛,由于网络不能完全反映系统变化内在规律,预测误差较大;

(3)即使网络按正常样本训练完成,当以非法数据作为ANN的输入(比如今天的数据存在误差)预测明天的数据时,系统输出也会出现较大误差。

因此,为了避免以上情况出现,无论是利用历史数据作为训练样本对ANN进行训练,还是预

测时作为ANN的输入,都必须对历史数据进行预处理,对有明显异常的数据进行剔除或用正常数据置换。

数据的归一化处理。为了避免神经元饱和现象,在神经网络的输入层,用式(10)将原数据换算为  $[-1, +1]$  区间的值;在输出层,用式(11)换算回负荷值。

$$y = \frac{x - \frac{1}{2}(\bar{x} + \underline{x})}{\frac{1}{2}(\bar{x} - \underline{x})} \quad (10)$$

$$x = \frac{1}{2}(\bar{x} - \underline{x})y + \frac{1}{2}(\bar{x} + \underline{x}) \quad (11)$$

其中  $x$  为归一化前的原始数据,  $\underline{x}$  为原始数据最大值,  $\bar{x}$  为原始数据最小值,  $y$  为归一化后的数据。

$T_b$ 、 $T_b^2$  的计算如下:

$$T_b(k) = aT_b(k-1) + bT_o(k) + cT_R(k) \quad (12)$$

$$T_b^2(k) = [aT_b(k-1) + bT_o(k) + cT_R(k)]^2 \quad (13)$$

其中,  $a = 0.8$ , 是墙体温度时间常数,  $b = (1 - a)f$ ,  $c = (1 - a)(1 - f)$ ,  $f = 0.63$ 。  $T_o(k)$ 、 $T_R(k)$  分别为当天的室外温度及预热前的室内温度,  $T_b(k-1)$  为前一天的建筑物墙体温度,  $T_b(k)$  为当天的建筑物墙体温度。

## 2.3 网络的训练

本文采用的是把所有训练样本随机的分为两部分:即训练集和测试集,利用训练集的样本进行神经网络训练,利用测试集的数据进行测试。在神经网络的训练过程中,随着训练误差的不断减小,如果测试集的误差增大的大小或者次数达到一定的水平,则停止神经网络的训练。

将11月~3月共151组数据进行上面的归一化后分为两部分。120组数据(11月~2月)作为训练集,31组(3月)作为测试集。本次训练的最大循环次数  $ep$  为10000次,目标误差  $err-goal$  确定为0.001,动量因子  $mc$  为0.95,最大误差变化率为1.04,初始学习速率为0.03。初始权值、阈值利用  $initff$  函数生成,改进BP算法利用工具箱的  $trainbpx$  函数训练,其格式为:

$$[w1,b1,w2,b2] = initff(X,9,'tansig',1,'purelin');$$

$[w1, b1, w2, b2, te, tr] = \text{trainbpx}(w1, b1, 'tansig', w2, b2, 'purelin', X, Y, tp);$

其中,  $w1, b1, w2, b2$  分别是输入层到隐含层以及隐含层到输出层的权值和阈值,  $te$  是网络的实际训练次数,  $tr$  是网络训练误差平方和的行矢量。  $X$  为输入矢量,  $Y$  为目标矢量。  $tp$  为可选训练参数, 其作用是设定如何进行训练, 具体如下:  $tp(1)$  为显示间隔次数, 其默认值为 25;  $tp(2)$  为最大循环次数, 其默认值为 100;  $tp(3)$  为目标误差, 其默认值为 0.02;  $tp(4)$  为学习速率, 其默认值为 0.01;  $tp(5)$  为设定学习速率增加的比率, 其默认值为 1.05;  $tp(6)$  为设定学习速率减少的比率, 其默认值为 0.7;  $tp(7)$  为设定动量常数, 其默认值为 0.9;  $tp(8)$  为设定最大误差比率, 其默认值为 1.04。

训练 4893 次后误差平方和 SSE 小于为 0.001 的目标误差  $err\_goal$ , 达到了我们的实验要求。此时各层的权值及阈值如下:

$w1 = [0.6777 - 0.3090 0.9346 0.5062 - 2.2203 - 0.4026 - 0.4915 0.0809 0.6388 1.1369 1.1070 - 1.4036 2.2493 1.4762 - 0.3597 - 0.2740 1.2739 0.1119 - 0.9371 - 0.8897 1.2722 0.8855 - 1.4316 - 0.8403 - 2.4009 - 0.8872 1.1046 - 2.1108 - 0.3210 - 0.6760 1.2560 1.3418 - 0.4039 1.7833 - 0.1666 - 0.8519];$

$w2 = [0.4944 1.2063 1.2104 - 1.3660 0.3607 0.9697 - 1.4029 - 0.3070 - 1.0489];$

$b1 = [- 0.8950 - 0.2413 - 0.7859 - 1.9907 - 0.9480 - 1.3495 0.2891 0.4320 - 0.6209];$

$b2 = [0.1997];$

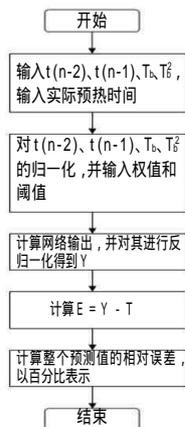


图3 神经网络预测器预测流程图

### 3 利用建立的预测模型对系统进行预测

依据实际记录的数据对, 利用上面得到的权值及阈值对系统进行预测, 其流程图如图 3。

仿真结束后, 打开 Matlab 数据统计功能框 Data Statistics, 可知误差最大值为 0.2148 (相当于 12 分钟), 误差最小值为 -0.1621。且其误差平方和 SSE 为 0.2916, 预测误差不到 3%, 所以, 神经网络能对供暖系统的预热时间做出较准确的预测, 从而实现建筑供暖节能的目的。

### 4 结束语

实验证明了神经网络控制器具有良好的预测和控制效果, 即使预测估计的初始化参数是不准确的, 而且在运行时不需要知道建筑物和供热系统的热工特性。并且与采用自适应控制算法的仿真结果相比, 采用神经网络算法的仿真结果要好的多。

尽管以上的结果都是试验性质的, 但它表明了用神经网络来设计建筑物最佳预热时间控制器是非常可行的。如果用此来开发控制产品, 在节能呼声甚高的今天, 将具有很大的市场前景。

### 参考文献

- 1 A.L.Dexter. Self-tuning optimum start control of heating plant. Automatic, Vol. 17, No. 3, pp. 1981:483 ~ 492
- 2 A.L.Dexter P.Haves. A robust self-tuning predictive controller for HVAC applications. ASHRAE Trans 95, Pt2, 1998: 431 ~ 438
- 3 BARNEY FLOOREZ. Temperature prediction models and their application to the control of heating systems. Automation, Vol. 17, No. 3, pp. 1985:1847 ~ 1852
- 4 任庆昌. 楼宇自控系统的先进控制策略. 西北地区新理念、新技术、新产品研讨会. 2005 年 10 月
- 5 冯增喜. 基于单片机实现的供暖系统最佳启停自校正调节器. 西安建筑科技大学学位论文. 2005
- 6 飞思科技产品研发中心. MATLAB 6.5 辅助神经网络分析与设计. 电子工业出版社. 2003
- 7 钱荣. 神经网络预测器在供热系统中的应用. 西安建筑科技大学学位论文. 2004
- 8 盛晓文. 热水供暖系统室温预测. 煤气与热力, 1997(3)