

# 基于神经网络的暖通空调控制系统延迟时间的确定

张 鹏 石来德 同济大学机械工程系 (200092)

## Abstract

This paper presents an artificial neural network (ANN) approach to determine the delay time for a heating, ventilating and air-conditioning (HVAC) plant to respond to control actions. The ANN is a fully connected four-layer network. An acceleration technique was used to improve the General Delta Rule for the learning process. Experimental data for heating and cooling modes were used with both the ANN and a traditional mathematical method to determine the delay time. The results show that ANNs can be used effectively determining the delay time for HVAC systems.

Keywords: artificial neural network, delay time, HVAC system

## 摘 要

本文提出一种人工神经网络 (ANN) 方法, 确定暖通空调 (HVAC) 系统对控制信号的响应延迟时间。在研究中选用了四层网络, 在网络学习过程中采用了一种加速方法, 以改善梯度下降法。对制热和制冷两种工作方式的实验数据, 采用 ANN 和传统算法两种方法确定延迟时间, 并进行比较。结果表明 ANN 可以有效地用于确定 HVAC 系统的延迟时间。

关键词: 人工神经网络 (ANN) 延迟时间, 暖通空调 (HVAC) 系统

## 1 前言

图 1 所示为一个普通的暖通空调反馈控制系统框图, 其中  $u(t)$ 、 $y(t)$ 、 $r(t)$  和  $e(t)$  分别为控制量、被控量、给定值和误差。当给定一个阶跃信号, 系统便会产生一个如图 2 所示的响应。图中,  $y(t)$  从 5% 上升到 95% 所需时间为上升时间 ( $T_s$ ) 如 BC 段所示; 在 AB 段, 系统没有响应, 这段时间为系统的延迟时间 ( $T_d$ )。从 A 到 C 的整个时间为系统响应时间 ( $T_r$ )。上升时间与系统和控制器有关, 而延迟时间只与系统有关。




图 1 反馈控制系统框图

延迟时间也可以用狄拉克 (Dirac) 脉冲来定义。当在图 1 中的 U 点施加一个狄拉克脉冲 (如图 3a 所示) 经过一段时间后, 在理想状态下, 系统在 Y 点处会产生一个如图 3b 所示的狄拉克脉冲响应, 在实际情况下, 会产生一个如图 3c 所示的响应。脉冲在系统在“传递”的这段时间就是延迟时间。在实际的控

制环境中, 控制器输出一个可以分解成一系列狄拉克脉冲的连续控制信号, 如图 4a 所示。系统则会产生一个与  $u(t)$  形状相似的响应曲线  $y(t)$  如图 4b 所示, 每部分响应都对与之相关的输入脉冲产生一个延迟时间, 线性系统对于连续控制信号的综合响应具有相同的延迟时间, 这样, 可以通过在时间域内比较控制量  $u(t)$  和被控量  $y(t)$  来确定延迟时间。




图 2 阶跃信号的系统响应

本文利用人工神经网络方法确定 HVAC 系统的

延迟时间,微机控制系统对输入信号和输出信号进行采样,得到一系列控制信号,  $u(0), u(T_c), u(2T_c), \dots, u(kT_c), \dots$ , 和一系列响应信号,  $y(0), y(T_c), y(2T_c), \dots, y(kT_c), y([n+1]T_c), y([n+2]T_c), \dots, y([n+k]T_c), \dots$ , 其中  $T_c$  是采样时间。如果控制信号  $u(kT_c)$  产生响应  $y([n+k]T_c)$  那么延迟时间  $T_d$ , 就是采样次数  $k$  与采样时间  $T_c$  的乘积:

$$T_d = k \cdot T_c \quad (1)$$




图3 狄拉克脉冲和它的响应  
(a)狄拉克脉冲 (b)理想的响应 (c)实际的响应




图4 实际控制信号和它的响应




图5 相似系数值

序列  $u(T_c), u(2T_c), \dots, u(kT_c), \dots$  和序列  $y([k+1]T_c), y([k+2]T_c), \dots, y([k+n]T_c), \dots$ , 形状相似, 经过整定, 对于每对都应有有一个取值在 0-1 之间的

相似的数值。这样,我们可以通过检查一段时间经过整定后的  $u(kT_c)$  和  $y([k+i]T_c) (i=1, 2, \dots, n)$  的值是否相似, 来确定延迟时间, 这个方法如图 5 所示, 当  $u(kT_c)$  和  $y([k+i]T_c)$  取值相同时, 输出  $z$  为 1.0, 否则  $z$  小于 1.0。经过整定后的  $u(kT_c)$  与  $y([k+i]T_c)$  越接近,  $z$  的取值越接近 1.0。此处的  $z$  被称为相似系数。在本文中,它是通过 ANN 来实现的,ANN 具有两个输入,一个是  $u(kT_c)$  另一个是  $y([k+i]T_c)$  一个输出给出相似系数值,把  $u(kT_c)$  序列和不同  $k$  值的  $y([k+i]T_c)$  序列输给 ANN, 在很长的采样间隔里 ( $n$  足够大) 使得 ANN 输出最大的平均相似系数的  $k$  对应的时间就是延迟时间 (见式 (1))。

## 2 人工神经网络的设计

本文采用如图 6 所示的四层 ANN, 它具有前向数据传递方式和 BP 学习算法。第一层是具有两个节点输入层, 第四层是只有一个神经元的输出层, 第二层和第三层是各有 5 个神经元的隐含层, 输入层的节点接受外界输入信号并把它直接传递到下一层。在本文中, 把控制器的输出和测得的响应 (温度) 作为 ANN 的输入信号, 他们都被整定为 0-1 之间的值。对于隐含层和输出层, 每个神经元相当于一个 Sigmoid 函数, 输出层的神经元给出 ANN 的输出结果, 取值在 0-1 之间。




图6 神经网络结构

ANN 通过图 5 所示的期望结果来学习, 建立神经元之间的连接权值, 对于每一组输入, 网络都会输出一个 0-1 之间的结果, 计算输出与期望输出存在误差, 利用 BP 算法更新连接权值以便减小误差。

我们研究过两个网络, 一个是三层网络, 另一个是四层网络 (五层网络较复杂, 需要的训练计算量大, 实际应用很少) 每个网络的隐含层都有 5 个神经元, 两个网络学习过程的计算机仿真结果见图 7 和图 8。可以采用两个标准来检验学习过程建立的连接权值是否准确, 一个是均方差 ( $E_a$ ) 另一个是最大绝对误差 ( $E_m$ ) 见下式,

$$E_m = \max \{ |b_s \Phi_b - Y_b| \} \quad (3)$$

其中  $D_b$  是一次学习循环的输入状态  $b$  的期望输出, 取值为 0 或 1;  $Y_b$  是计算输出, 取值在 0 - 1 之间。 $N_b$  是一次学习循环的输入状态数, 此处为 289。图 7 和图 8 表示学习过程的迭代次数, 均方差 ( $E_a$ ) 和最大绝对误差 ( $E_m$ ) 两个图形中, 曲线 1 是三层网的, 曲线 2 和 3 是四层网的, 曲线 2 和 3 的区别在后文说明。很明显, 三层网在 500 次迭代后还没有收敛,  $E_a$  大约为 0.1,  $E_m$  接近 1.0, 而四层网在 200 次迭代以前就已收敛。




图 7 均方差 ( $E_a$ ) 和迭代次数 ( $N_i$ ) 的关系  
(1 - 三层网络 2 - 四层网络 3 - 加速四层网络)




图 8 最大绝对误差 ( $E_m$ ) 和迭代次数 ( $N_i$ ) 的关系  
(1 - 三层网络 2 - 四层网络 3 - 加速四层网络)

另一个对网络特性影响较大的重要因素是学习方法。在网络的学习过程中应用比较广泛的学习方法是梯度下降法, 然而, 在大多应用中, 为了判断网络的连接是否正确, 最大绝对误差 ( $E_m$ ) 比均方差 ( $E_a$ ) 更重要, 我们提出一种加速方法, 以改善梯度下降法。在本文的研究中得到了成功的应用, 这个加速

方法的主要思想是, 只更新那些引起大的输出误差的输入的连接权值, 而小的误差, 比如小于 0.001, 被忽略。这使得学习过程集中在大的输出误差处, 以致加速了学习过程的收敛速度, 在图 7 和图 8 中, 曲线 2 表示利用没有加速的梯度下降法的结果, 而曲线 3 表示采用加速的梯度下降法的结果。曲线 2 经过 200 次迭代以后, 收敛到局部最小点,  $E_a$  大约为 0.015,  $E_m$  大约 0.2。曲线 3 经过 130 次迭代以后, 收敛到全局最小点,  $E_a$  小于 0.001,  $E_m$  小于 0.01, ANN 经过上述训练以后, 就可以用来识别什么时候的输入量相似。

### 3 实验

把 ANN 用于识别一个 HVAC 系统的延迟时间试验, 该系统由一个 2000 - cfm 的风机盘管、制冷剂、冷水、热水和蒸气盘管组成, 用一个通用控制器控制制热和制冷时的回风温度。制热时, 空气被蒸气经过二级换热器加热 (一个是蒸气 - 水, 另一个是水 - 空气) 制冷时, 气流被冷水盘管冷却, 对于不同的操作方式, 比如制热和制冷, 延迟时间也不同。

控制器由带有数据采集系统的微电脑实现。控制信号 (即控制器的输出) 和回风温度 (即系统响应) 被整定为取值在 0 - 1 之间。把这两组信号送给 ANN, 对从输出控制信号到检测到系统响应之间的不同的采样间隔  $k$ , ANN 都会算出其相似系数, 如前所述, 根据其中取值最大者相对应的  $k$ , 就可以算出延迟时间, 制热方式的结果, 见图 9 的曲线 1; 制冷结果见图 10 的曲线 1。图 9 指出控制信号和系统响应在  $k = 25$  处具有最大的相似系数 0.76, 采样间隔是 3.41 秒, 所以制热方式的延迟时间是 82.6 秒。图 10 指出在  $k = 10$  处有个最大的相似系数 0.84, 因此制冷方式的延迟时间是 34.1 秒。图 9 和图 10 中的曲线 2 和曲线 3 是由其他数据组得到的结果, 与曲线 1 相同。

把利用 ANN 得出的实验结果与利用传统计算方法得出的结果进行比较, 经过整定后的控制信号和整定后的系统响应之间均方差 ( $E_{as}$ ) 为:

$$(4)$$

取得最小  $E_{as}(k^*)$  的  $k^*$  给出延迟时间。制热方式下, 利用同样的实验数据,  $k$  取从 10 到 40 的不同值得出均方法, 最小的均方差在  $k = 26$  处, 与 ANN 得出的  $k = 25$  很相近。制冷方式下, 利用同样的实验数据,  $k$  取从 1 到 20 的不同值得到均方差, 这种情况

下,最小的均方差位于  $k = 10$  处,与 ANN 得出的结果相同。

### 4 结论

本文利用四层 ANN 来确定 HVAC 系统的延迟时间,计算机仿真和实验结果表明 ANN 是确定 HVAC 系统延迟时间的有效方法。




图9 制热方式下不同采样间隔的平均相似系数




图10 制冷方式下不同采样间隔的平均相似系数

ANN 与传统计算方法相比,优点是,它可以通过选择适当的神经元传递函数的偏移和比例系数,来消除不同水平的输入噪声干扰,这样,ANN 可以得到比传统方法更精确的结果。对于已经采用神经网络的控制系系统,这种方法可以很容易地加到控制器上,以便更好地估计系统延迟时间。

对于学习过程,这种加速方法可以改善普通的梯度下降法,这种加速方法主要降低大的输出误差,这样可以加快学习过程的收敛速度。

### 参考文献

1. Ferrano, F. J., Jr, and K. V. Wong. 1990. Prediction of thermal storage loads using a neural network. ASHRAE Transactions 96. 2.
2. Ichikawa, Y., and T. Sawa. 1992. Neural network application for direct feedback controllers. IEEE Transactions on Neural Networks 3 ( 2 )
3. Kong, S. - G., and B. Kosko. 1992. Adaptive fuzzy sys-

tems for backing up a truck - and - trailer. IEEE Transactions on Neural Networks 3 ( 2 )

4. Kreider, J. F., and X. A. Wang. 1991. Artificial neural networks demonstration for automated generation of energy use predictors for commercial buildings. ASHRAE Transactions 97. 2.
5. Lee, K. Y., Y. T. Cha, and J. H. Park. 1992. Short - term load forecasting using an artificial neural network. IEEE Transactions on Power Systems 7 ( 1 )
6. Park, D. C. 1991. Electric load forecasting using an artificial neural network. IEEE Transactions on Power Systems 6 ( 2 )
7. Widrow, B., and M. A. Lehr. 1990. 30 years of adaptive neural networks: Perception, madaline, and backpropagation. Proceedings of the IEEE 78. 9.
8. Yamada, T., and T. Yabuta. 1992. Neural network controller using autotuning method for nonlinear function. IEEE Transactions on Neural Networks 3 ( 4 )

(上接第 11 页)




图3 WWW 服务器端软件设计

图形资料可先在 AUTOCAD 下将图形资料录入,然后转入系统进行处理。

属性数据通过 MS Access2000 进行数据库系统录入。

多媒体资料、图象资料处理成 JPG 格式,声音资料处理成 WAV 格式,视频资料处理成 AVI 格式。

### 5 结束语

本设计继承了传统的 GIS 系统的优点,同时充分利用了计算机网络的优点,为学校物业管理部门提供了一套有关物业资料的有效管理系统,提高了系统的可扩展性,更加有效地利用了系统资源。

### 参考文献

1. 宋广惠等,南京市房产测绘信息系统的设计与实现,计算机应用研究,2000. 6
2. 张平,住宅小区的物业管理,青岛建筑工程学报,1997. 1
3. 张犁,林晖等,互联网时代的地理信息系统,测绘学报,1998. 1