

# 基于二级 RBF 神经网络的冷库温度的 在线预测优化控制

史国栋 王其红 徐 燕 薛国新

(江苏石油化工学院)

**摘 要:** 冷库温度预测优化控制在果蔬冷藏方面的应用尚有许多不足之处。主要问题之一是不能通过简练有效的计算完成制冷系统的在线优化控制计算。RBF 神经网络有极强的非线性映照能力和良好的插补性能,且训练速度快。该文提出使用二级 RBF 神经网络,并合理地综合利用状态量以往的测量值和预测的未来值来实现库温的在线预测优化控制。将该方法用于某冷库库温控制系统,取得了满意的结果。

**关键词:** RBF 神经网络; 冷库; 在线预测; 优化控制

冷库温度预测优化控制在农业工程特别是果蔬冷藏方面得到广泛应用。在冷库制冷过程中,目前主要有两类调节装置来控制库温变化。一为隔膜电动调节阀,另一为双位调节器。无论是采用哪一种调节装置,都面临如何选择最佳温度作为温控目标、预测库温变化并实现优化调节的问题。近年来,国内外学者对此问题进行了研究。较早使用的方法是将泰勒级数展开法和 PD 控制算法相结合进行优化调节<sup>[1]</sup>。后来人们将傅里叶变换法和 Chebyshev 数值逼近理论用于温度预测分析,使用了克服超调的计算方法,并用专家知识产生式结构来表示制冷过程的控制规则,取得了满意的制冷优化控制效果<sup>[2,3]</sup>。近年来有研究者将多级 BP 神经网络用于优化控制<sup>[4]</sup>,克服了以往方法不能很好地实现非线性映照的不足,但 BP 网络训练算法所需计算时间过长,且易陷入局部极小,故难以用于在线计算。为此,本文提出使用二级 RBF 神经网络来实现制冷系统的在线预测优化控制。第一级 RBF 神经网络用于确定当前系统最佳制冷温度即温控目标值,第二级 RBF 神经网络用于预测未来一段时间内的温度值,在此基础上采用预测控制算法进行控制计算,并直接指令制冷系统发生动作,从而实现在线控制。

## 1 二级 RBF 神经网络

使用二级 RBF 神经网络。第一级网络用于确定最佳冷藏温度。第二级网络用于预测库温。一般地,对于一个 RBF 神经网络,设共有  $n$  个输入量  $x_1, \dots, x_n$ ; 共有  $m$  个输出  $y_1, \dots, y_m$ 。记

$$x = (x_1, \dots, x_n)^T \quad (1)$$

$$y = (y_1, \dots, y_m)^T \quad (2)$$

$x$  和  $y$  分别表示  $n$  维输入空间  $R^n$  和  $m$  维输出空间中的点。设共有  $H$  个隐单元,每个隐单元使用两个参量,一为标量  $\sigma_k (> 0)$ , 另一为向量  $x^{(k)}$ 。设有训练样本集  $\{(x^{(k)}, y^{(k)}) \mid 1 \leq k \leq K\}$ 。一般地,应有  $n \leq H \leq K$ 。RBF 神经网络的基础是 RBF 插补。为改进插补性能提出使用下式计

收稿日期: 1999-06-01

史国栋, 教授, 常州市机场路 江苏石油化工学院教务处, 213016



算 RBF 神经网络的第  $j$  个输出

$$y_j = \frac{\sum_{h=1}^H w_{jh} \exp\left[-\frac{(x - \hat{x}_h)^2}{\sigma_h^2}\right]}{\sum_{h=1}^H \exp\left[-\frac{(x - \hat{x}_h)^2}{\sigma_h^2}\right]} \quad 1 \leq j \leq m \quad (3)$$

其中分子为传统的 RBF 插补算法表示式, 分母相当于对常数函数 1 进行插补, 它用以改进插值点远离样本集形成的闭区域时的指数函数衰减效应。

用于确定最佳冷藏温度的第一级 RBF 神经网络中的每个输入在每个隐单元的参数训练计算中均用到。

## 2 最佳冷藏温度的在线计算

冷藏温度的目标值的选取应综合考虑各种因素。为了合理地利用能量, 希望制冷过程有较高的性能系数  $e_0$ 。所谓性能系数即制冷量  $Q_0$  和所需输入的能量  $P$  之比

$$e_0 = Q_0 / P$$

研究表明,  $e_0$  随蒸发温度的上升, 冷凝温度的下降而增加。另外, 提高蒸发温度可减少系统与空气温度之差, 从而可减少结霜和露珠, 即减少干耗损失, 使果蔬保持新鲜。因此, 为了节能和保持果蔬新鲜, 应尽可能使系统在较高的蒸发温度和较低的冷凝温度下运行。但蒸发温度显然会受到被冷却物体温度的限制。

对于一种果蔬, 其入库时的最佳贮藏温度可由正交试验法得出。但随着冷藏时间的增加, 为了保证不变质, 最佳冷藏温度逐渐降低。单位重量第  $i$  种果蔬的贮藏损失为

$$L_i = L_i^{(1)} + L_i^{(2)}$$

上式右端第一项表示由冻伤等引起的损失, 第二项表示由变质引起的损失。第一项对时间  $t$  的偏导数随温度的降低而增加, 第二项对时间  $t$  的偏导数随温度的增加而增加。同时, 它们又都与贮藏时间  $t$  有关。即

$$\frac{\partial L_i^{(1)}}{\partial T} = f_i^{(1)} [T, t - t_i^0]; \quad \frac{\partial L_i^{(2)}}{\partial T} = f_i^{(2)} [T, t - t_i^0]$$

其中  $f_i^{(1)}$  和  $f_i^{(2)}$  分别随温度的增加而降低和增加,  $t_i^0$  表示入库初始时间,  $t - t_i^0$  表示冷藏时间。

$$L_i = \int_{t_i^0}^t (f_i^{(1)} [T, t - t_i^0] + f_i^{(2)} [T, t - t_i^0]) dt$$

对第  $i$  种果蔬, 当前最佳贮藏温度  $T_i^*$  满足下式

$$\frac{\partial L_i^{(1)} [T_i^*, t - t_i^0]}{\partial T} + \frac{\partial L_i^{(2)} [T_i^*, t - t_i^0]}{\partial T} = 0$$

第  $i$  种果蔬的重量  $g_i$ , 其贮藏损失为  $g_i L_i$ 。而在当单位时间内总的贮藏损失为

$$\frac{\partial L}{\partial T} = \sum_{i=1}^n g_i (f_i^{(1)} [T, t - t_i^0] + f_i^{(2)} [T, t - t_i^0])$$

将总体的最佳贮藏温度记为  $T^*$ , 它必须满足

$$\frac{\partial L(T^*, t)}{\partial T} = 0$$

$$\sum_{i=1}^n g_i \left( \frac{\partial L_i^{(1)} [T^*, t - t_i^0]}{\partial T} + \frac{\partial L_i^{(2)} [T^*, t - t_i^0]}{\partial T} \right) = 0 \quad (4)$$

求上式中的  $T^*$ , 需耗费较多的计算机时, 不便于在线计算。为此, 采用第一级 RBF 神经网络

来计算  $T^*$ 。该网络有一个输出端,用来表示  $T^*$ 。有  $2n$  个输入端,分别表示  $g_i, 1 \leq i \leq n$  和  $t_i^0, 1 \leq i \leq n$ 。采用  $H = n$  个隐单元。用(4)式用以产生数量足够多的训练样本。

### 3 库温的在线预测

为实现库温最优控制,关键之一是准确地进行预测。使用神经网络的预测方法由于容错性好和适应性强而越来越受到人们的关注<sup>[4]</sup>。较早使用的BP神经网络。但其训练时间较长,且易陷入局部极小。而RBF神经网络由于有较高的训练速度而愈来愈受到人们的重视<sup>[4~6]</sup>。我们将RBF神经网络用于库温的预测。为之选用一种等级式网络结构。为了进行库温预测,需要考虑到温度和湿度等量的耦合关系。因此,我们令在输出变量集中同时包含温度和湿度等。同时,要根据控制的执行与否来选用不同的输入变量。分如下两种情形:

#### 1) 不执行自动控制

一般地,设冷库有  $R$  个操作量  $u_1, \dots, u_R, S$  个状态量  $v_1, \dots, v_S$ 。取出一时间窗,它由  $2Q$  个等间隔的时间点

$$t_1 = t - (Q - 1)\Delta t, t_2 = t - (Q - 2)\Delta t, \dots, t_Q = t, t_{Q+1} = t + \Delta t, \dots, t_{2Q} = t + Q\Delta t$$

组成,分别用  $u_r^{(q)}$  和  $v_s^{(q)}$  表示  $u_r$  和  $v_s$  在时间点  $t_q (1 \leq q \leq 2Q)$  上的值。令

$$x = (u_1^{(1)}, \dots, u_R^{(1)}, v_1^{(1)}, \dots, v_S^{(1)}, \dots, u_1^{(Q)}, \dots, u_R^{(Q)}, v_1^{(Q)}, \dots, v_S^{(Q)})^T \quad (5)$$

$$y = (v_1^{(Q+1)}, \dots, v_1^{(2Q)}, \dots, v_S^{(Q+1)}, \dots, v_S^{(2Q)})^T \quad (6)$$

这里,  $n = (R + S)Q, m = QS$ 。所谓预测,就是根据(5)式的  $x$  来确定(6)式的  $y$ 。对于最新的当前时刻  $t_0$ ,可用到此为止的所有测量结果来构造预测网络的输入。假定在当前时刻以前的各操作量和状态量值都可通过测量得到,于是它们在当前时刻  $t_0$  以前的值均为已知,而以后的值为未知。为了构造一个预测样本,必须选择时刻  $t = t_0 - Q\Delta t$ 。否则样本中会出现未知值,而这是不合理的。

设已由测量值构造出足够多的样本  $(x^{(k)}, y^{(k)}), k = 1, 2, \dots, K$ 。先算出隐单元的参数,再用(3)式计算出库温的预测值。

#### 2) 执行自动控制

这时,输入变量集中仅包含环境温度、环境湿度以及库存果蔬品种和数量等不直接参与控制的变量(称它们为客观变量),而预测量则为在由上述输入量决定的客观条件下的状态量的稳态值。这时,RBF网络非线性映照功能被用于建立稳态模型。在求出状态量的稳态值后,再用控制算法去控制库温。之所以这样做而不采用1)中所述方法是为了预测量与作为控制对象的状态量不包含任何共同的变量,否则,它们互为因果,将难以得到正确的控制效果。

### 4 库温的在线调优

常规的单控制量PD控制算法离散化后的形式如下

$$u(k) = K_p \left\{ e(k) + \frac{T_s}{T_i} \sum_{i=0}^k e(i) + \frac{T_d}{T_s} [e(k) - e(k-1)] \right\} + u_s \quad (7)$$

其中的  $u_s$  相应于初始控制量,  $u(k)$  为控制变量的当前值,  $e(i)$  为离散时间点上被控制对象的设定值与实际值之差

$$e(i) = r - v(i) \quad (8)$$

式中  $v(i)$  为被控制对象  $v$  在第  $i$  个时间点上的数值,  $r$  为其设定值。(7)式写成增量形式为

$$\Delta u(k) = u(k) - u(k-1) = K_p [e(k) - e(k-1)] + K_i e(k) + K_d [e(k) - 2e(k-1) + e(k-2)] \quad (9)$$

式中  $K_i = K_c \frac{T_s}{T_i}$  ——积分系数;  $K_d = K_c \frac{T_d}{T_s}$  ——微分系数。上式可进一步表示为如下形式

$$\Delta u(k) = K_c \Delta e(k) + K_i e(k) + K_d \Delta^2 e(k) \tag{10}$$

在有了对被控制量的预测值之后, (9) 式或(10)式必须加以改变。设当前时刻为  $t_k$ , 由预测 RBF 神经网络所得的在时刻  $t_{k+1}, t_{k+2}$  上的变量  $v$  值分别为  $\hat{v}(k+1), \hat{v}(k+2)$ , 令

$$\hat{e}(k+1) = r - \hat{v}(k+1); \quad \hat{e}(k+2) = r - \hat{v}(k+2)$$

综合以往的  $v$  值和预测的  $v$  值来计算(10)式右端各项。令

$$\Delta \hat{e}(k) = \alpha_1 [e(k) - e(k-1)] + \beta_1 [\hat{e}(k+1) - e(k)] + \gamma_1 [\hat{e}(k+2) - \hat{e}(k+1)]$$

$$\hat{e}(k) = \alpha_2 e(k) + \beta_2 \hat{e}(k+1) + \gamma_2 \hat{e}(k+2)$$

$$\Delta^2 \hat{e}(k) = \alpha_3 [e(k) - 2e(k-1) + e(k-2)] + \beta_3 [\hat{e}(k+1) - 2\hat{e}(k) + \hat{e}(k-1)] + \gamma_3 [\hat{e}(k+2) - 2\hat{e}(k+1) + \hat{e}(k)]$$

我们将(10)式改为如下形状

$$\Delta u(k) = K_c \Delta \hat{e}(k) + K_i \hat{e}(k) + K_d \Delta^2 \hat{e}(k) \tag{11}$$

以上各式中的  $\alpha_1, \beta_1, \gamma_1, \alpha_2, \beta_2, \gamma_2, \alpha_3, \beta_3, \gamma_3$  分别满足

$$\begin{cases} \alpha_1 + \beta_1 + \gamma_1 = 1 \\ 0 & \alpha_1, \beta_1, \gamma_1 & 1 \end{cases}; \begin{cases} \alpha_2 + \beta_2 + \gamma_2 = 1 \\ 0 & \alpha_2, \beta_2, \gamma_2 & 1 \end{cases}; \begin{cases} \alpha_3 + \beta_3 + \gamma_3 = 1 \\ 0 & \alpha_3, \beta_3, \gamma_3 & 1 \end{cases}$$

因此, 我们要确定 6 个待定系数  $\alpha_1, \beta_1, \alpha_2, \beta_2, \alpha_3, \beta_3$ 。为此, 可令  $e^2(k)$  的数学期望取最小, 即通过求解如下问题

$$\min E [e^2(k)]$$

来确定自变量  $\alpha_1, \beta_1, \alpha_2, \beta_2, \alpha_3, \beta_3$ , 它们应满足的约束条件是:

$$0 \leq \alpha_i, \beta_i, 1 - \alpha_i - \beta_i \leq 1; \quad 0 \leq \alpha_j, \beta_j, 1 - \alpha_j - \beta_j \leq 1; \quad 0 \leq \alpha_s, \beta_s, 1 - \alpha_s - \beta_s \leq 1$$

作为初始值, 可取

$$\alpha_i = \beta_i = \alpha_j = \beta_j = \alpha_s = \beta_s = 1/3$$

### 5 应用实例

本文方法被用于某果蔬冷库的库温优化控制。表 1 给出了使用本文方法前后的库藏果蔬日损失率数学期望的比较。对于单一品种的第  $i$  种果蔬, 其日损失率定义为

$$l_i = L_i / E_i \quad 1 \leq i \leq N$$

其中,  $N$  为果蔬品种数,  $L_i, E_i$  分别表示第  $i$  种果蔬一天中的损失量与入库量的市场价表示,  $1 \leq i \leq N$ 。损失不仅考虑由于变质不能使用而抛弃的部分, 也考虑由于存放新鲜程度下降而带来的价格损失。令第  $i$  种果蔬库存量按市价计算

价值为  $w_i$ , 于是第  $i$  种果蔬在所有果蔬中所占的权重为  $w_i = w_i / \sum_{j=1}^N w_j$ , 总的日损失率可近

$$\text{似地用下式计算} \quad l = \sum_{i=1}^N w_i l_i$$

表 1 所列即为使用本文方法前后的的数学期望  $E[l]$  的对照结果, 它们由冷库运行管理资

表 1 两种方法的果蔬损失率和标准温度偏差的比较

Tab 1 The comparison of the loss rate of vegetables with the standard variation of temperature

日期	损失率/%		库温标准偏差/	
	传统方法	本文方法	传统方法	本文方法
1	7.5	5.5	1.22	0.38
2	8.5	4.2	1.02	0.32
3	9.2	3.1	0.95	0.41
4	7.3	3.5	0.83	0.33
5	6.6	4.6	1.34	0.23
6	9.7	4.3	1.53	0.24
7	8.1	5.0	1.12	0.26

料计算而得。另外,在表中也给出了每天中库温与其日平均温度偏差的数学期望即为库温的标准偏差。由以上结果可见,与传统库温控制方法相比,在使用本方法后,冷库的保鲜效果明显地得到改善,且系统运行更为稳定。

## 6 结 论

本文将 RBF 神经网络同时用于最佳冷藏温度计算及库温的预测,在此基础上将 PD 控制算法进行修正用于库温的在线预测优化控制,取得了满意的结果。由于 RBF 神经网络具有很强的非线性映照能力和良好的插补性能,并且其训练速度快,故特别适用于冷库的在线预测优化控制。本文方法可望推广应用于农业工程中的其它预测优化控制问题中。

### [参 考 文 献]

- [1] 孙光三,周兴禧,邹根南 制冷中的节能 鲍士雄译 上海:上海交通大学出版社,1987. 23~ 34,154~ 168
- [2] 李明忠,孙兆明 中小型冷库技术 上海:上海交通大学出版社,1995. 20~ 56
- [3] 史国栋,赵燕伟,王万良等 果蔬冷藏库智能优化调节 农业工程学报,1994,10(1): 103~ 109
- [4] W R Foster, F Collopy and L H Ungar Neural network forecasting of short noisy time series Computers Chem Engng, 1992, 16(4): 293~ 297
- [5] Ruan R R, Amer S and Zhang J. Prediction of dough rheological properties using neural networks Cereal Chemistry, 1995, 72(3): 7~ 13
- [6] David D Zhang Neural Networks System Design Methodology Peking: Tsinghua University Press, 1996. 1~ 7

## Online Predicative Optimum Control of the Temperature of a Cold Storage Based on the Two-Stage RBF Neural Network

SHI Guo-dong WANG Qi-hong XU Yan XUE Guo-xin

(Jiangsu Institution of Petrochemical Technology, Changzhou 213016)

**Abstract:** The predicative optimum control of the temperature of a cold storage has a wide application in agricultural engineering especially in fruit and vegetable cold storage. In recent years, the advanced control technology was used for the cold storage. But there is still a lot of shortcomings. One of the main problems is that the traditional methods can't realize the online predicative optimum control of a cooling system with simple and valid methods. A RBF neural network has a strong ability in nonlinear function and a good interval performance, and it has a higher training speed. Therefore a two-stage RBF neural network was proposed. Combining the measured values and the predicated values, the two-stage RBF neural network was used for the online predicative optimum control of the temperature of a cold storage. The application result of the new methods in a real cold storage showed a great success.

**Key words:** RBF neural network; cold storage; online prediction; optimum control