

RBF 神经网络在加速冷却控制系统中的应用¹⁾

柴天佑 王笑波

(东北大学自动化研究中心 沈阳 110006)

摘要 针对中厚钢板加速冷却过程,钢板入口温度波动大,钢板终冷温度难以实现闭环控制等特点,首先将 RBF(Radial Basis Functions)神经网络与优化设定技术相结合应用到加速冷却系统中,提出了加速冷却控制系统中基于 RBF 神经网络的每幕流量的控冷模型.仿真实验表明:该控冷模型能够实现对钢板加速冷却过程的有效控制.

关键词 RBF 神经网络, 加速冷却, 控冷模型.

APPLICATION OF RBF NEURAL NETWORKS IN CONTROL SYSTEM OF THE SLAB ACCELERATING COOLING PROCESS

CHAI Tianyou WANG Xiaobo

(Research Center of Automation, Northeastern University, Shenyang 110006)

Abstract In the slab accelerating cooling process, the range of the slab's inlet temperature variance is large, and closed-loop control of the slab finishing cooling temperature is difficult. In this paper, RBF neural networks are employed in the slab accelerating control systems, and an RBF neural network-based cooling control model for each curtain's rate is proposed. Simulation results and industrial experiments show that effective control of the slab accelerating cooling process is realized using this control model.

Key words RBF neural networks, accelerating cooling, cooling control model.

1 引言

中厚钢板轧制后的加速冷却工艺,是在精轧机与热矫直机之间增加一段冷却装置(如图1所示),将钢板从终轧后的温度(800~900℃)冷却到矫直温度(500~700℃).这一加工技术,不但能大大缩短钢板冷却时间,大幅度提高产量,而且更重要的是它能够通过控制冷却速度,改变钢板的金属组织结构,在不降低韧性的情况下,提高钢材的强度,同时减少钢板的不平整度和残余应力,从而明显地提高钢材的质量,为生产厂家带来显著的经济效

1) 国家自然科学基金和国家863/CIMS计划资助项目.

收稿日期 1998-11-16 收修改稿日期 1999-4-2

益^[1-3].




图1 层流冷却装置示意图

注: D1—— γ 射线测厚仪 T1~T3——红外测温仪

由于钢板加速冷却过程是一个多输入(输入量为:钢板入口温度、板厚、目标终冷温度、水温和环境温度等)、辅助输出(回路设定为:开幕数、每幕流量、上下幕流量比、辊道速度和辊道加速度)以及输出为钢板上下板温的非线性、强耦合的复杂系统. 参考输入为钢板终冷温度和冷却速度, 钢板只有在冷却装置的入口和出口处才能测得实际温度等参数. 终轧钢板的品种多, 厚度变化大, 钢板进入冷却系统的边界条件波动大, 同时钢板在冷却过程中发生相变产生的大量热量对冷却效果产生显著的影响, 但却无法对其进行测量. 文献[4]提出了对辅助输出开幕数及对每幕流量等进行优化设定, 保证钢板终冷温度的优化设定方法. 它采用工作点附近线性化方法, 建立产生辅助输出前馈模型的偏差信号. 本文采用 RBF 神经网络提出求取每幕流量优化设定值的方法, 有效地解决了控冷模型中的主要控制量-流量的控制问题.

2 加速冷却控制系统中的 RBF 神经网络设定模型

图2表示钢板加速冷却控制系统结构. 本文图中符号说明如下:

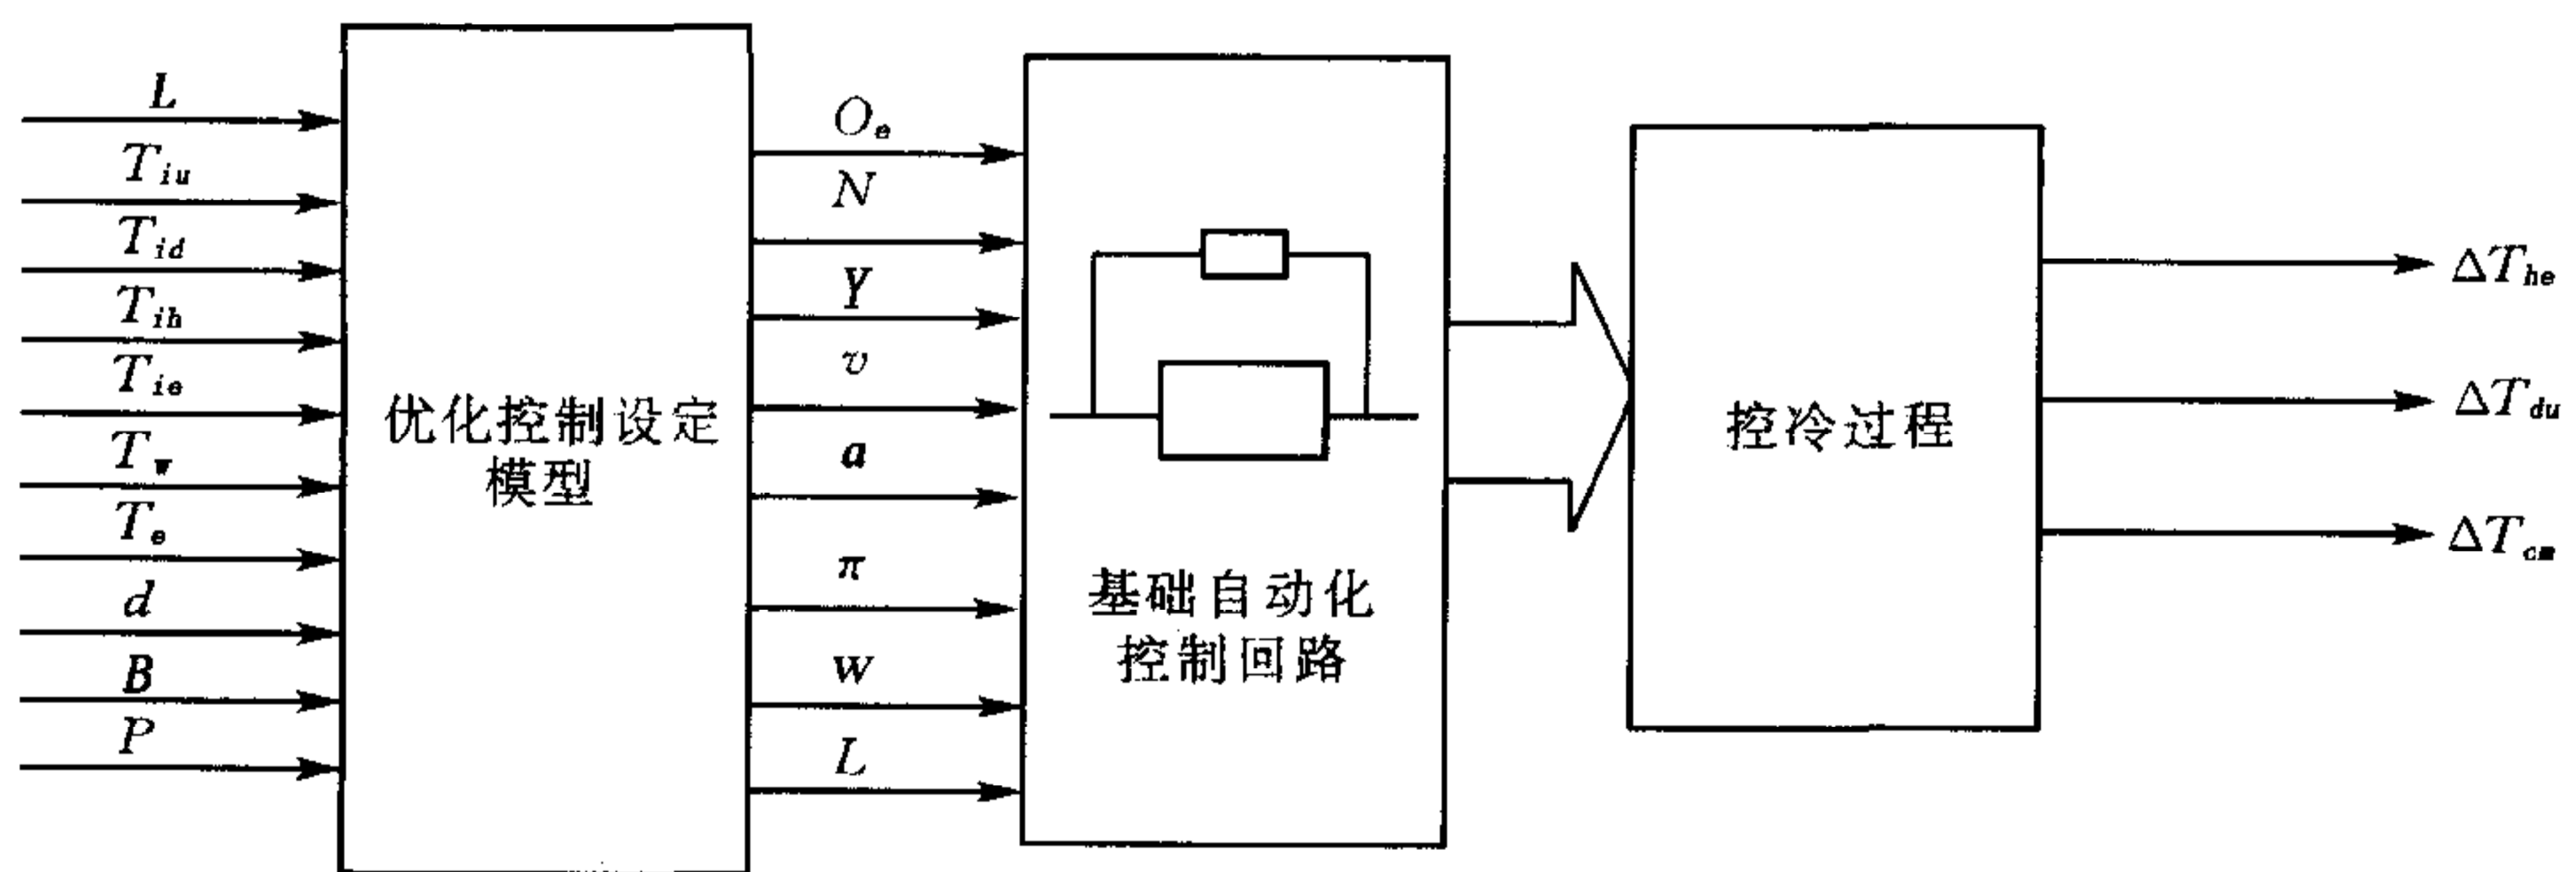


图2 钢板加速冷却控制系统结构示意图

T_c 为目标终冷温度($^{\circ}\text{C}$); T_{id}, T_{iu} 为入口下、上板温($^{\circ}\text{C}$); T_{ih}, T_{ie} 为入口头、尾板温; T_w 为水温($^{\circ}\text{C}$); T_e 为环境温度($^{\circ}\text{C}$); d, B, l 为钢板的厚、宽、长(mm); P 为钢板型号; N 为开幕数(个); Q_e 为上水幕每幕流量(m^3/h); γ 为流量比率; v 为辊道速度(m/s); a 为辊道加速度(m/s^2); π 为水幕分布; W 为遮蔽宽度(mm); L 为辊道联动范围; T_{cm} 为实际终冷温度; T'_{cm} 为网络输出温度; $\Delta T_{cm} = T_c - T_{cm}$; $\Delta T'_{cm} = T'_{cm} - T_{cm}$.

图2中优化控制设定模型, 根据输入产生保证钢板终冷温度的控制回路设定值, 并且

控制回路采用 DCS 来实现. 通过机理分析, 从工程化角度考虑, 将多输入/多输出控制冷却系统化为多输入/单输出系统, 从而简化了优化控制设定模型.

针对钢板加速冷却过程, 可以采用如下策略来确定和调整控制回路设定值.

1) 按钢板型号和厚度分级, 厚度分级间隔为2mm;

2) 在某一厚度级上, 由工艺确定 π, W, L, v ;

3) 在某一厚度级上, 加速度 a 与流量比 r 一旦调整准确后, 一定时期内基本上无需再调整. 因此, 先调整加速度与流量比模型, 使其基本准确后, 再修正流量 Q_e 和开幕数 N 模型; 实现每幕流量 Q_e 、开幕数 N 、加速度 a 和流量比 r 之间的解耦;

4) 根据工艺经验和机理分析, 一定厚度级上开幕数模型可取为

$$\Delta N = \Delta N_1 + \Delta N_2 = \frac{\Delta T - \Delta T_0}{\Delta T_0} N_0 + \frac{d - d_0}{d_0} N_0; \tag{1}$$

5) 由于开幕数 N 对控冷过程起主要作用, 而每幕流量 Q_e 只起到一种精调作用. 在整个冷却过程中, 影响开幕数 N 变化的主要因素是钢板温降和钢板厚度的变化. 因此, 利用 (1) 式来决定一定厚度级上开幕数 N 的变化, 即用该式来消除可测干扰温降的变化 ΔT_f 和钢板厚度的变化 Δd , 而将所有其它干扰因素, 连同模型 (1) 式的不准确因素, 都归结到每幕流量的变化中, 利用每幕流量 Q_e 的变化来予以消除.

因此, 如图3所示, RBF 神经网络设定模型就是进行每幕流量 Q_e 的设定, 实现冷却过程的精确控制.

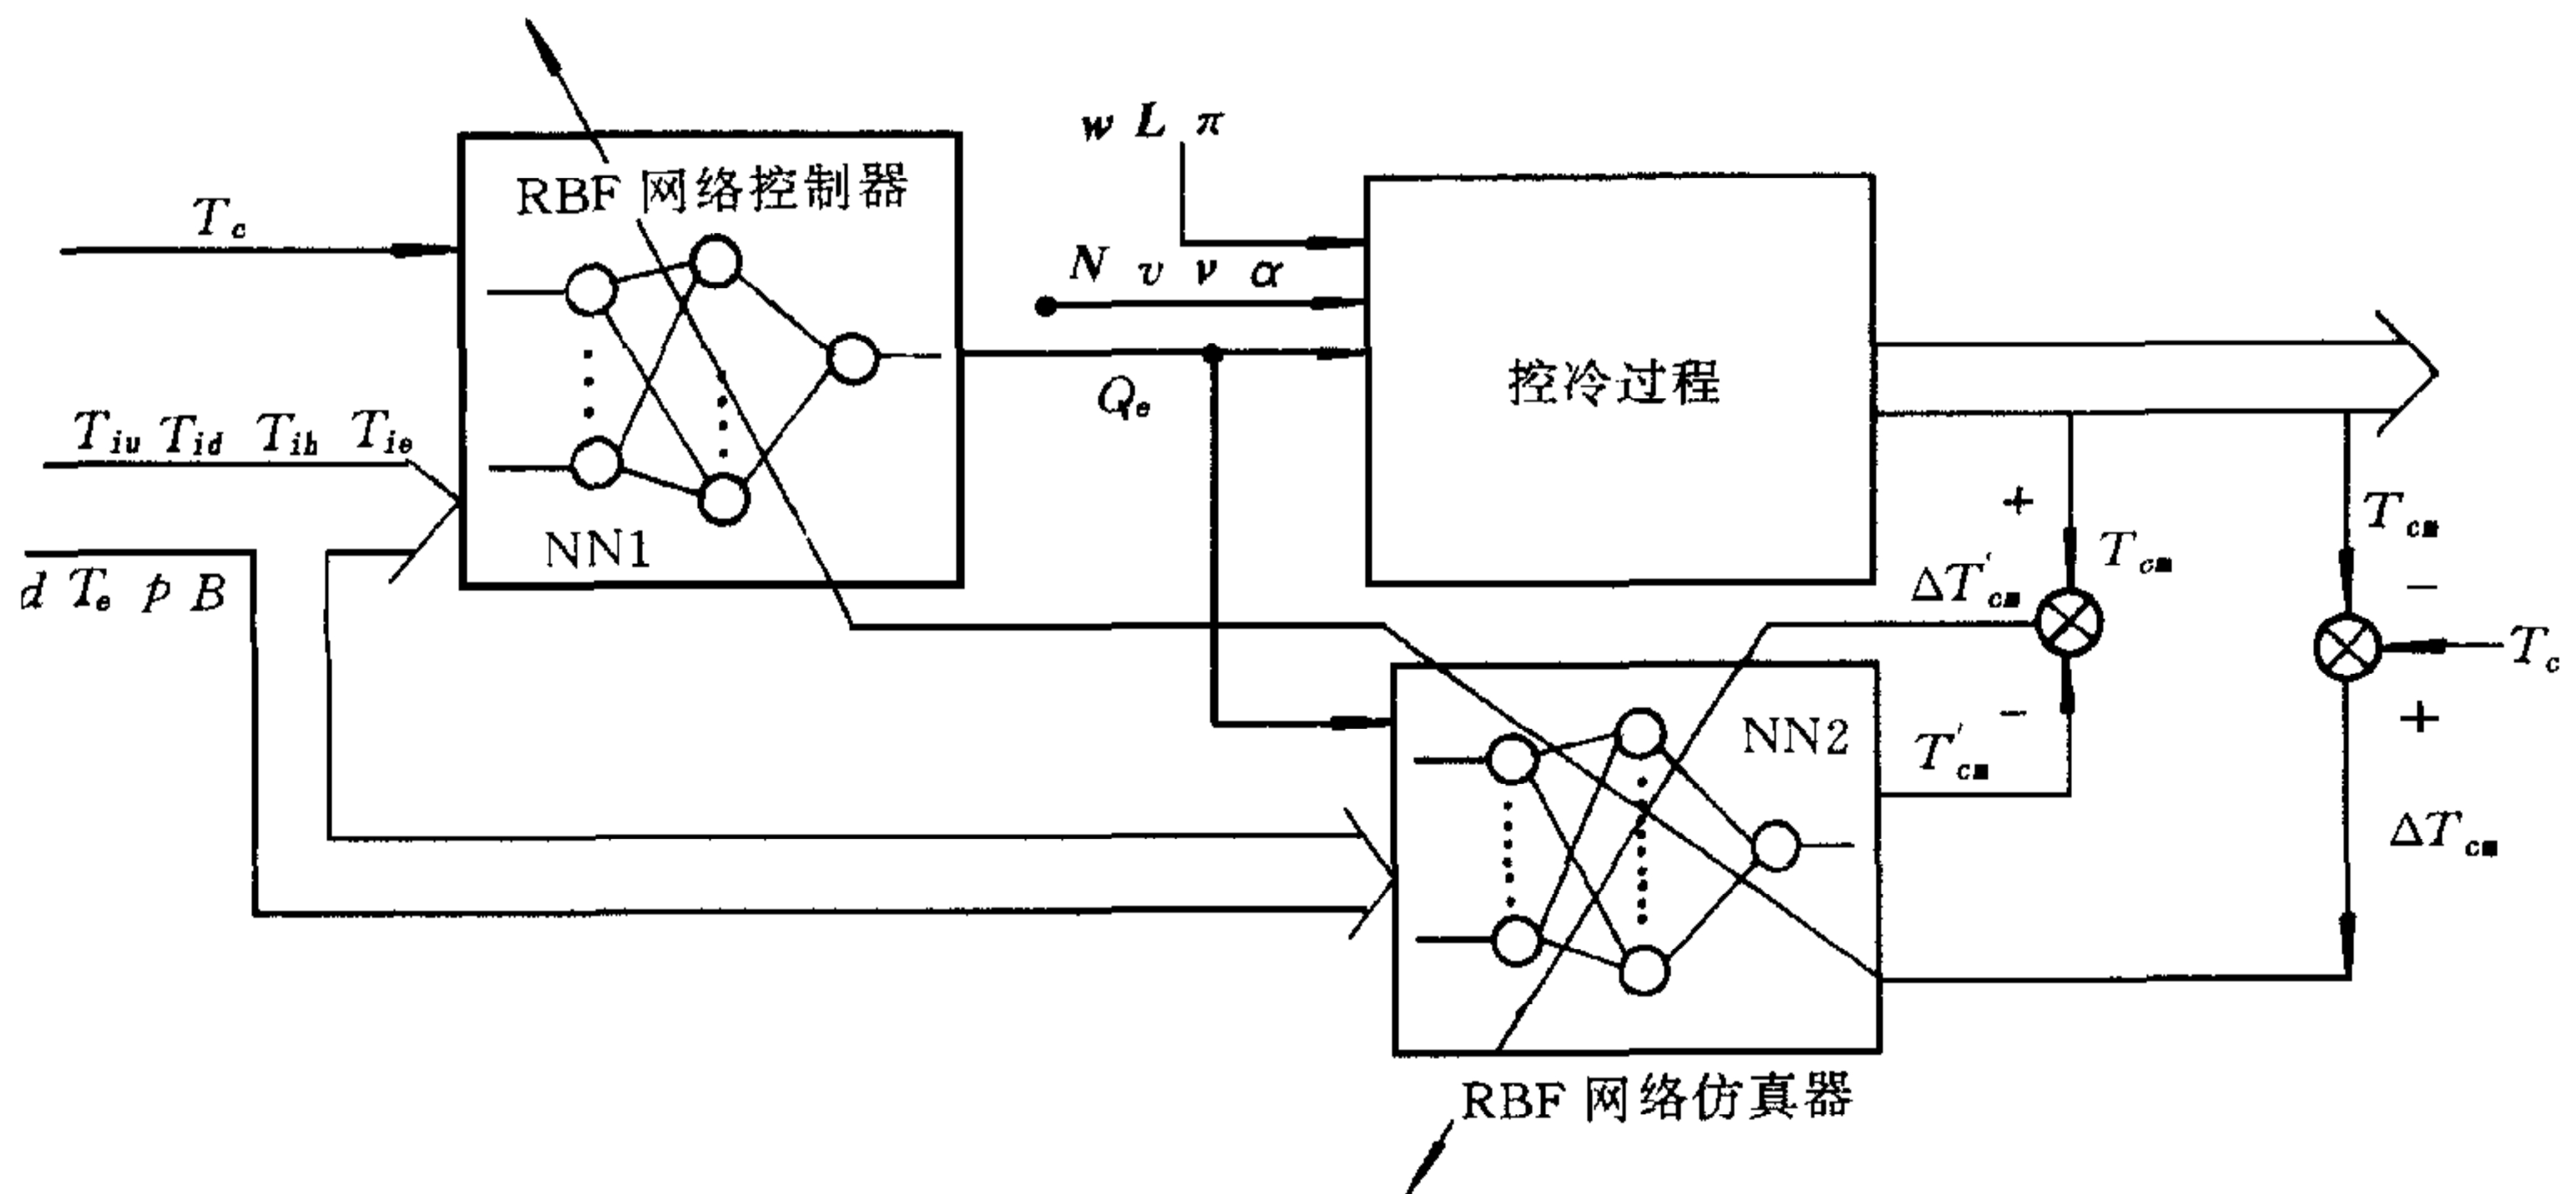


图3 层流冷却过程的多输入/单输出 RBF 网络控制器

3 控冷设定模型的 RBF 神经网络算法

3.1 RBF 神经网络的控制算法

RBF 神经网络^[5]在非线性系统建模和辨识方面具有收敛速度快和逼近能力强的优点^[6]. 它是一个两层神经网络, 输出层节点构成是由隐层节点计算的基函数输出的线性组合器. RBF 网络的响应实现一个映射 $Y: R^L \rightarrow R$, 在图3中, 定义 RBF 线性网络为

$$y_p = w_0 + \sum_j w_j \Phi(\|x_p - c_j\|), \tag{2}$$

其中 y_p 表示当前输入第 p 个样本时目标节点的输出; w_j 表示第 j 个径向基函数连接到输出节点的权值; w_0 表示目标节点的阈值; j 为隐层节点的个数; $x \in R^L$ 为网络输入向量; $\Phi(\cdot)$ 为基函数; $\|\cdot\|$ 表示欧几里德范数; $c_j \in R(1 \leq j \leq m)$ 为 RBF 网络的中心, m 为隐层的计算节点数. 在本文中, RBF 网络的隐层节点按下式计算, 输出为

$$z_i = f \left[\sum_{p=1}^L \frac{(x_p - c_{ip})^2}{\sigma_{ip}^2} \right], \quad (3)$$

其中 $f(x) = \exp\left(-\frac{x^2}{2}\right)$, 即节点的输出函数是高斯函数. (3) 式中 f 表示一个中心在 C_{ip} , 协方差为 σ_{ip} 的超椭球. 于是, (3) 式可写为

$$z_{ip} = \Phi(\|x_p - c_i\|) = \exp\left[-\sum_{p=1}^L \frac{(x_p - c_{ip})^2}{2\sigma_{ip}^2}\right], \quad (4)$$

z_{ip} 表示当输入第 p 个样本 x_p 时隐节点 i 的输出, c_i 表示径向对称函数的中心, σ_{ip} 为样本协方差矩阵中的元素(通常取样本协方差阵为对角阵).

RBF 网络的自学习算法采用加权遗忘因子的最小二乘递推算法. 目标累积误差为

$$J(n) = \lambda J(n-1) + \frac{1}{2} [y_d(n) - z^T(n)w(n-1)]^2, \quad (5)$$

式中 λ 为遗忘因子, $0 \leq \lambda \leq 1$; n 为第 n 次修正结果; $n-1$ 为第 $n-1$ 次修正结果.

3.2 RBF 神经网络的中心点的选取过程

RBF 网络的难点在于网络隐层节点的中心点的选取上^[7]. 加速冷却系统的中心点可由实际系统的输入/输出数据中获取, 利用递推算法, 求取达到控制精度的最少数目的中心点个数, 从而较好地解决了中心点不易选择的问题. 中心点的确定采用聚类算法, 具体实施如下

1) 从输入/输出数据中随机给定初始中心点 $c_i(0) \in R^m, 1 \leq i \leq n$ 及初始学习速率 $\alpha_c(0)$. 中心点的个数可由样本容量设定, 本文根据现场的 64 组实际数据, 选择中心点的个数为 32.

2) 计算各中心点与输入向量的欧氏距离, 寻找距离最小值及其中心点标号

$$a_i(k) = \|x(k) - c_i(k)\|, 1 \leq i \leq n, t = \arg[\min\{a_i(k), 1 \leq i \leq n\}]. \quad (6)$$

3) 更新中心点, 重新计算第 t 个距离

$$\left. \begin{aligned} c_i(k) &= c_i(k-1), 1 \leq i \leq n, i \neq t, \\ c_t(k) &= c_t(k-1) + \alpha_c(k)(x(k) - c_t(k-1)), \\ a_t(k) &= \|x(k) - c_t(k)\|, \end{aligned} \right\} \quad (7)$$

其中学习速率 $0 < \alpha_c(k) < 1$, 并且逐渐趋近于 0, 本文设 $\alpha_c(k) = \alpha_c(k-1)/(1 + \text{int}[k/n])^{1/2}$. 上述算法的收敛性已由文献[9]证明. 由于本系统采用的是线性学习规则, 因此可以保证误差收敛速度很快.

3.3 RBF 神经网络的分类处理以及如何反求修正量 ΔQ .


由于加速冷却系统所要处理的是 10—40mm 厚的钢板, 对于不同厚度的钢板, 冷却速度、开幕数、流量比、辊道速度、加速度等也都完全不同, 所以按厚度不同, 即将 10—40mm 的钢板每隔 2mm 分为一类, 共 16 类, 运用开关控制在程序中实现. 每个厚度级的控制过程都如同图 3 的控制过程.

图 3 所示的逆动态控制非常直接, 其目标是通过学习被控对象的逆模型使得从神经网络


络控制器 NN1 的输入至对象的输出端的函数近似为单位映射,进而得到被控对象的前馈控制器.同时 NN1 所使用的误差信号是对象输出 Y 与期望输出 Y_c 的偏差.这种学习方式在实际应用中遇到的最棘手的问题就是无法确定误差 $\Delta E (= Y_c - Y)$ 相对于 Q_e 的修正量 ΔQ_e ,即所谓的 Jacobian^[8]问题.因此一般在系统中加入一个过程仿真器 NN2,仿真器 NN2 的结构与控制器 NN1 的结构完全一致,只是在 NN1 中目标终冷温度为该网络的输入,流量为其输出;而在 NN2 中,其它输入量与 NN1 相同,流量为其输入,终冷温度为其输出.因为从实际的终冷温度误差信号,经过过程仿真器可以推算出流量误差,所以应用误差反传的方法解决了 $\Delta E \rightarrow \Delta Q_e$ 的映射问题.

4 仿真实验


从现场得到的达到终冷工艺指标要求(目标终冷温度为600℃)的流量设定数据64组(如图4(a)的实线),这64组数据的实际控制效果如图4(c)实线所示;用这64组数据对RBF网络仿真器进行离线训练,钢板厚度为20—22mm,入口温度750—850℃,RBF网络的中心点个数为32, $P = 200 * eye$, $\lambda = 0.99$,训练后的RBF网络输出与实际系统的




(a) 流量的给定值



(c) 仿真器跟踪实际终冷温度的曲线



(b) 钢板通过冷却装置的入口温度和出口温度



(d) 钢板厚度变化时,经分类处理控制的终冷温度曲线

图4 仿真实验曲线

控制效果完全一致. 将 RBF 网络控制器在线训练, 实际的钢板入口温度如图4(b)所示, 经过 RBF 网络仿真器反传, 得到新的流量设定值如图4(a)的虚线, 并且实际的控制效果也均能达到终冷温度的要求, 如图4(c)虚线所示; 当钢板厚度变化范围在20—26mm 时, 运用分类处理控制方法, 控制的精度也能够满足实际目标的要求, 如图4(d).

为了将加速冷却控制模型更好地在某钢厂加速冷却系统中实施, 我们研制了控冷工艺过程的仿真软件包, 从热平衡机理方程出发仿真钢板的整个控冷过程, 将此控制模型运用在软件包上, 并将 RBF 网络控制器加入到控制模型中, 对钢板的冷却过程进行自适应控制, 经过4块钢板就可达到目标终冷温度(600℃)的要求. 如图5所示.

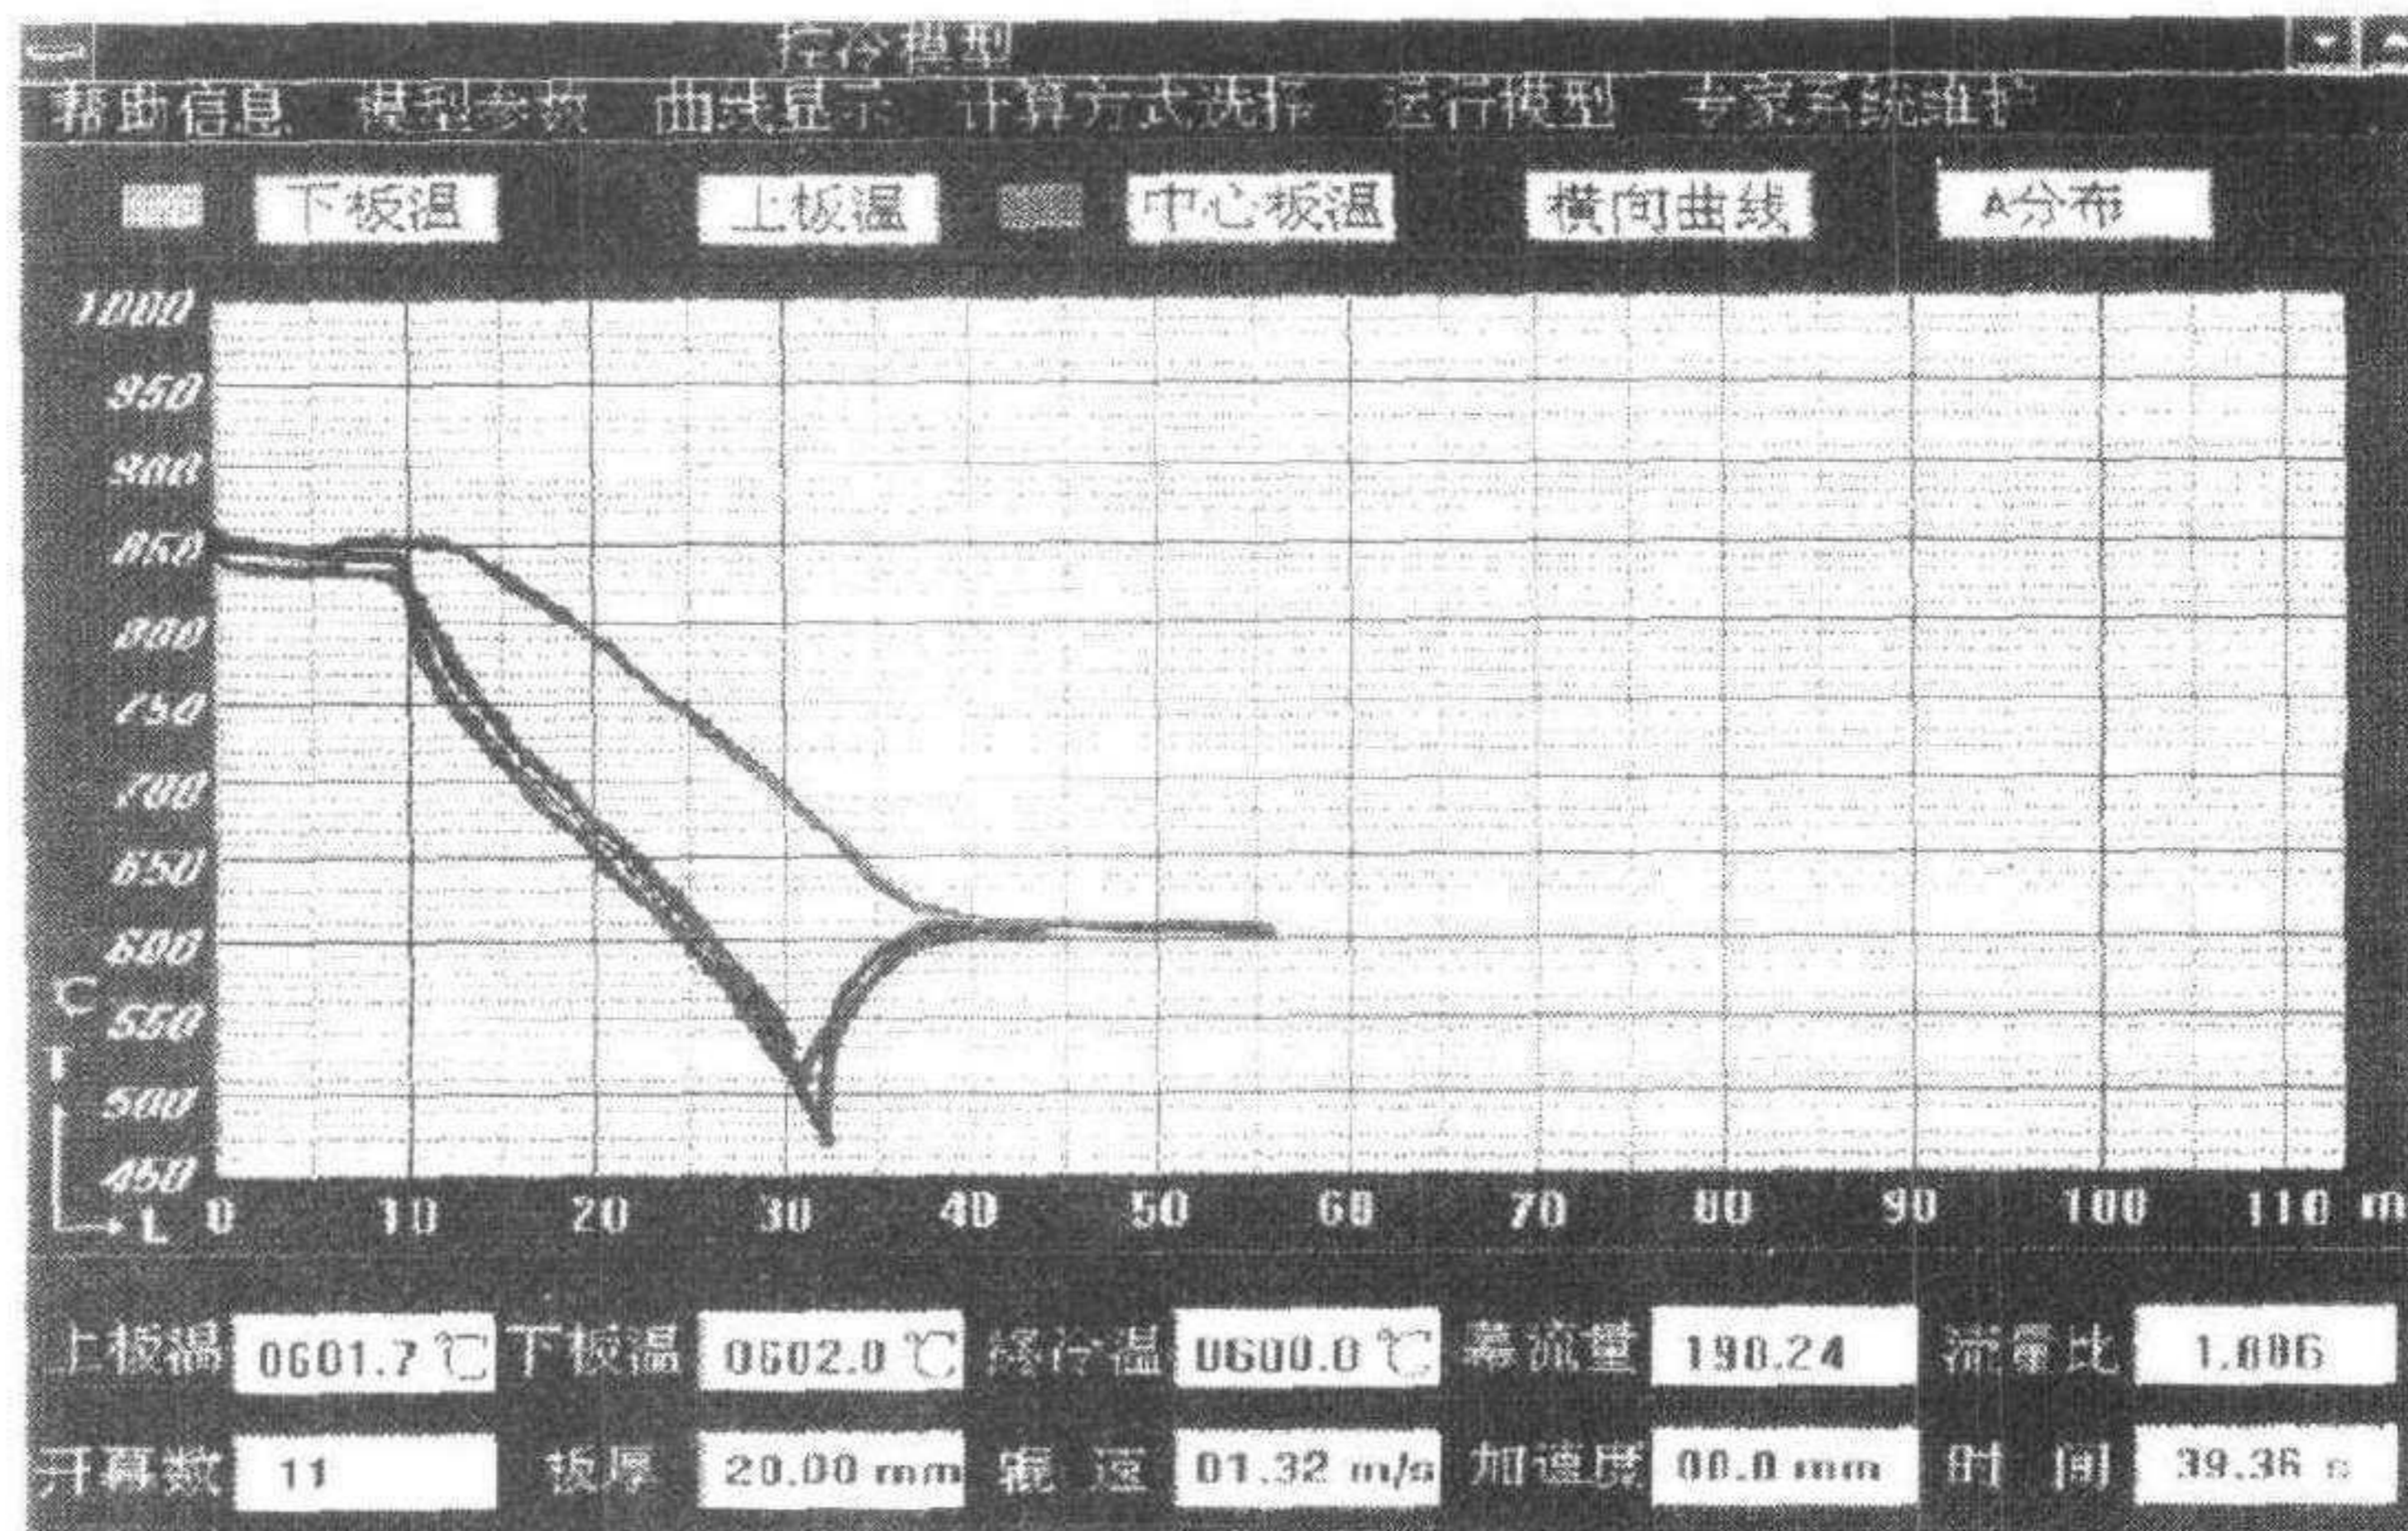


图5 钢板经过冷却装置时的控冷曲线

5 结论

理论分析和仿真实验表明, 采用 RBF 神经网络作为优化控制设定模型, 完成对中厚钢板加速冷却计算机集散控制系统中的主要控制回路的控制量——每幕流量的设定是可行的; 它有效地解决了由于控冷系统具有强非线性特性而使控冷模型难以建立的问题, 同时为用以神经网络控制为代表的先进控制技术, 解决采用常规控制技术难以有效控制的层流冷却工业过程的难题打下了基础.

参 考 文 献

- 1 Masahisa O, Tomoki K *et al.* The computer control of hot strip coiling temperature. Paper for the 7th World Congress of IFAC, 1978, 159~166
- 2 Hollander F. Design and control for advanced runout table processing. *Iron and Steel Engineer*, March, 1971, 81~91
- 3 Moffat R W *et al.* Computer control of hot strip cooling temperature with variable flow laminar spray. AISE Year Book, 1985, 474~481
- 4 Chai T, Guan S. Object-oriented integrated control technology of complex industrial processes. In: Proc., IFAC 5th symposium on Lowcost Automation, 1998, 1~3
- 5 Poggio T, Girosi F. Networks for approximation and learning. *IEEE Proc.*, 1990, 4(9): 1481~1497
- 6 Chen S, Billings S A, Grant P M. Nonlinear systems identification using neural networks. *Int. J. Control*, 1990, 51

(6): 1191~1214

- 7 Kwasny S C, Faisal K A. Rule-based training of neural networks. *Expert Systems with Applications*, 1991, **2**:47~58
- 8 Psaltis D, Sideris A, Yamamura A. A multilayered neural network controller, *IEEE Control Systems Magazine*, 1988, **10**(3): 44~88
- 9 Macqueen J. Some Methods for classification and analysis of multivariate observations. In: Proc. , the 5th Berkeley Symposium on Mathematics Statistics and Probability, 1967, 281~297

柴天佑 男,1947年生.现为东北大学自动化研究中心和国家冶金自动化工程中心主任、博士生导师、国际自控联(IFAC)技术局成员、IFAC 制造与仪表协调委员会主席.被 SCI 和 EI 检索收录论文130余篇,曾获国家教委科学进步一等奖、冶金部科学进步一等奖、辽宁省科学进步一等奖(两次)等.主要研究方向为自适应控制、智能控制、工业过程综合自动化.

王笑波 女,1963年生.1986年于辽宁大学物理系获理学士之后留校任教;1995年在东北大学自控系工业自动化专业获工学硕士;现为东北大学自动化研究中心博士生.主要研究方向为复杂工业过程的建模与控制、神经网络的研究、信号处理.

(上接第211页)

Title	2001	Place	Deadline	Further Information
IEEE/ASME Intl. Conference Advanced Interlligent Mechatronics (AIM'01)in cooperation with IFAC—	July 8—11	Como Italy	*	Prof. Bruno Siciliano e-mial; siciliano@unina. it
IFAC Conference Control Applications in Marine Systems —CAMS 2001	July 17—20	Glasgow UK	January 2001	Prof. M. J. Grimble e-mail: system@icu. strath. ac. uk
IFAC Symposium Large Scale Systems	July 18—20	Bucharest Romania	18 July 2000	Prof. Sergiu S. Iliescu e-mail; sil@info. cni. ro
IFAC Workshop Intelligent Control for Agriculture Applications	August 22—24	Bali Indonesia	1 Nov. 2000	Dr. Kundang B. Seminar e-mail; kseminar@indo. net. id
IFAC Workshop Periodic Control Systems	August 27—28	Como Italy	1 Nov. 2000	e-mail; bittanti@elet. polimi. it
IFAC Workshop Adaptation and Learning in Control and Signal Processing	August 29—31	Como Italy	1 Nov. 2000	Prof. Sergio Bittanti, Polit. di Milano Pza L. da Vinci, 32, I— 20133 Milano, Italy FAX: +39/02/23993412 e-mail; bittanti@elet. polimi. it http: // www. elet. polimi. it/ ALCOSP2001. html

(下转第239页)