

文章编号: 1000-8152(2008)06-1027-05

## 基于小波神经网络的板形板厚系统解耦预测控制

黄敏, 朱启兵, 崔宝同

(江南大学 通信与控制工程学院, 江苏 无锡 214122)

**摘要:** 带材轧制是一个复杂的非线性过程, 板形控制和板厚控制又是强耦合、非线性、含时延环节的复杂系统. 提出了一种基于小波神经网络的解耦预测控制方案; 利用小波神经网络来辨识原系统的 $\alpha$ 阶时延逆系统, 将该逆系统与原系统串联后形成一个伪线性复合系统, 从而把多变量系统控制转化为多个单变量系统的控制实现了系统解耦, 并对解耦后的系统采用闭环预测控制. 仿真表明该控制方法具有结构简单、易于实现, 且有较强的抗扰性和鲁棒性.

**关键词:** 小波神经网络; 板形板厚系统; 逆系统; 预测控制

**中图分类号:** TP183      **文献标识码:** A

## Strip flatness and gauge decoupling predictive control based on wavelet neural networks

HUANG Min, ZHU Qi-bing, CUI Bao-tong

(School of Communications and Control Engineering, Jiangnan University, Wuxi Jiangsu 214122, China)

**Abstract:** Strip rolling is a very complicated nonlinear process. Automatic flatness-control(AFC) and automatic gauge-control(AGC) are nonlinear, time-delay and coupling systems. A novel decoupling predictive control method of AFC-AGC is developed. Wavelet neural networks(WNN) is used to identify the  $\alpha$ -th order time-delay inverse system. This inverse system is connected in series with the AFC-AGC system to form a pseudo-linear system, thus, transforming the control of the MIMO nonlinear system into the control of a number of SISO systems and achieving a decoupling system. Predictive control is adopted for the decoupled system. Simulation results indicate that this method is simple and convenient for application, and able to resist the disturbance and improve the robustness.

**Key words:** wavelet neural networks; AFC-AGC; inverse system; predictive control

### 1 引言(Introduction)

板形和板厚是板带材轧制的两个重要指标. 将板形和板厚作为一个综合系统来研究已成为轧制技术研究领域的前沿课题<sup>[1]</sup>, 板形板厚综合系统(AFC-AGC)是一个具有非线性、时延、多变量、强耦合、复杂的实时系统, 难以建立精确的数学模型, 实时性要求非常高<sup>[2]</sup>. 在多变量系统控制中, 解耦控制是工程应用中是最普遍、最有效的控制方法之一. 神经网络解耦方法是智能解耦方法的代表. 较传统的解耦方法, 该方法可实现多输入到多输出的映射, 即使被控对象有很强的非线性, 也能有良好的解耦效果; 系统结构发生变化时, 网络也可以通过自学习以适应这种变化, 使解耦性能不变; 当存在系统建模困难时, 可通过神经网络辨识系统模型, 实行解耦控制. 因此对于那些具有时变、非线性、特性未知的对象, 神经网络解耦是一种有效的方法<sup>[3]</sup>.

小波神经网络(WNN)结合了小波分析和神经网络的优点, 已经成功应用于函数学习、过程控制、系统辨识、数据压缩等领域, 成为人工神经网络领域具有发展前景的研究方向<sup>[4~6]</sup>.

应用WNN的优点, 本文给出了一种板形板厚综合系统解耦控制新方法. 对五机架冷连轧机组末机架的仿真结果表明, 该控制方案具有较强的抗干扰能力和良好的动态性能.

### 2 AFC-AGC小波神经网络逆系统解耦实现(Inverse system decouple implement with WNN for AFC-AGC)

#### 2.1 小波神经网络逆系统解耦方法(Inverse system decouple method with WNN)

对于一般的非线性MIMO离散系统(假设其输入和输出都是 $p$ 维), 其输入输出差分方程可表示为

$$F[Y(k + \alpha), Y(k + \alpha - 1), \dots, Y(k + \alpha - n), U(k), U(k - 1), \dots, U(k - m)] = 0. \quad (1)$$

式中:

$$Y(k + \alpha - n) = [y_1(k + \alpha_1 - n_1), y_2(k + \alpha_2 - n_2), \dots, y_p(k + \alpha_p - n_p)]^T, \\ U(k - m) = [u_1(k - m_1), u_2(k - m_2), \dots, u_p(k - m_p)]^T,$$

$n_i$ 和 $m_i$  ( $1 \leq i \leq p$ )分别为 $i$ 通道系统阶次和输入迟滞,  $\alpha_i$ 为输出 $y_i$ 相对输入 $u_i$ 的时延, 一般情况下 $\alpha_i > 0$ .  $F$ 是定义在Hilbert空间中有界紧集 $D$ 上的连续平方可积函数向量.

**引理 1** [5] 对Hilbert空间中的任一连续平方可积函数 $f$ , 存在满足框架条件的小波框架 $(\psi_{j,k})_{j,k \in \mathbb{Z}}$ , 使得由小波函数作为隐层基函数的小波神经网络输出 $\hat{f} = \sum_{j,k} w_{j,k} \psi_{j,k}$ 可以以任意精度逼近 $f$ , 即对 $\forall \varepsilon > 0$ , 有 $\|f - \hat{f}\| < \varepsilon$ .

**定理 1** [3] 对于输入输出差分方程描述的MIMO离散系统 $\Sigma(1)$ , 若在某开集 $D$ 上有 $\det(\frac{\partial F}{\partial U(k)}) \neq 0$ , 且在 $D$ 上处处连续, 则系统在 $D$ 上可逆.

下面的定理2给出 $\alpha$ 阶时延逆系统小波神经网络存在的充分条件.

**定理 2** 设BIBO稳定的MIMO非线性系统 $F[Y(k + \alpha), Y(k + \alpha - 1), \dots, Y(k + \alpha - n), U(k), U(k - 1), \dots, U(k - m)] = 0$ , 其中 $F$ 是定义在Hilbert空间有界紧集 $D$ 上的连续平方可积函数向量, 如果 $\det(\frac{\partial F}{\partial U(k)}) \neq 0$ , 且在 $D$ 上处处连续, 则对 $\forall \varepsilon > 0$ , 必存在一个小波神经网络逆系统模型:

$$U(k) = G(X(k)) = \sum_{j,\bar{k} \in \mathbb{Z}} w_{j,\bar{k}} \psi_{j,\bar{k}}(X(k)). \quad (2)$$

式中:  $X(k) = [\varphi(k), \varphi(k-1), \dots, \varphi(k-n), U(k-1), \dots, U(k-m)]^T$  使得 $\|Y(k) - \varphi(k)\| < \varepsilon$ ,  $Y(k)$ 为

系统 $k$ 时刻的实际输出,  $\varphi(k) = Y_d(k + \alpha)$ 为 $k$ 时刻的逆系统输入.

**证** 根据已知条件, 由于 $F$ 是定义在Hilbert空间有界紧集 $D$ 上的连续平方可积函数向量, 且 $\det(\frac{\partial F}{\partial U(k)}) \neq 0$ , 所以 $F$ 是关于 $U(k)$ 在 $D$ 上的一致连续函数向量. 这样, 对于 $\forall \varepsilon > 0, \exists \delta > 0$ , 只要 $\|U^1(k) - U^2(k)\| < \delta$ , 且 $(\dots, U^1(k), \dots), (\dots, U^2(k), \dots) \in D$ , 就有 $\|F(\dots, U^1(k), \dots) - F(\dots, U^2(k), \dots)\| < \varepsilon$ 成立. 由隐函数定理可知, 在 $D$ 内存在一个隐函数:

$$U(k) = G[\varphi(k), \varphi(k-1), \dots, \varphi(k-n), U(k-1), \dots, U(k-n)], \quad (3)$$

$G(\cdot)$ 为光滑映射. 因为 $\|Y(k) - \varphi(k)\| < \varepsilon$ , 所以有 $[\varphi(k), \varphi(k-1), \dots, \varphi(k-n)] \in D$ , 该系统的初值为 $\varphi(k-i) = Y_d(k + \alpha - i), i = 1, 2, \dots, n$ , 使得

$$Y(k) = F \circ G[\varphi(k), \varphi(k-1), \dots, \varphi(k-n), U(k-1), \dots, U(k-m)]. \quad (4)$$

因为系统输入输出是有界的, 故 $G(\cdot)$ 是该有界范围内的平方可积函数, 由引理1, 即对 $\forall \delta > 0$ , 存在小波神经网络式(2)逼近式(3), 使得 $\|\hat{G}[X(k)] - G[X(k)]\| < \delta$ . 这样就有 $\|Y(k) - \varphi(k)\| = \|F \circ \hat{G}[X(k)] - F \circ G[X(k)]\| < \varepsilon$ . 证毕.

从工程实现的角度来说, 系统输入输出都是有界的, 因此将 $F$ 定义在有界紧集上是合理的, 并且 $G$ 也是能量有限的, 因此 $G$ 可由小波框架的有限项和表示. 式(3)就是以 $\varphi(k)$ ( $\varphi(k-n) = [\varphi_1(k-n_1), \varphi_2(k-n_2), \dots, \varphi_p(k-n_p)]$ )为输入,  $U(k)$ 为输出的 $\alpha$ 阶时延逆系统. 图1给出了小波神经网络 $\alpha$ 阶时延逆系统的辨识结构, 网络的结构和参数通过离线训练得到. 把训练好的 $\alpha$ 阶时延逆系统与原系统串联, 构成 $\alpha$ 阶时延伪线性离散系统. 尽管复合系统内部存在非线性耦合关系, 但它的输入输出已呈标准的带有 $\alpha$ 阶时延的线性解耦系统形式, 即原系统已被解耦成 $p$ 个相互无关的SISO伪线性时延子系统.




图1 小波神经网络 $\alpha$ 阶时延逆系统的辨识结构

Fig. 1 Identification structure of WNN  $\alpha$ -th order time delay inverse system

### 2.2 AFC-AGC建模(AFC-AGC modeling)

建立板形板厚综合系统的数学模型. 选择带材出口厚度作为厚度控制的目标变量, 带材出口横向张力差作为板形控制的目标变量.

当来料有扰动时, AFC-AGC系统对压下及弯辊力进行调节, 而每个单独控制系统(液压压下及液压弯辊力)要改变到所要求的数值需要一定的响应时间. 研究表明, 由液压缸、伺服阀、伺服放大系统组成的液压弯辊系统可以等效为一阶惯性环节, 输入的是电压, 输出的是液压弯辊力,  $G_1(s) = \frac{K_1}{1 + T_1s}$ , 辊缝调节由轧机的电气-液压压下装置完成, 也可以等效为一个1阶惯性环节, 其传递函数为  $G_2(s) = \frac{K_2}{1 + T_2s}$ ,  $K_1, K_2$  为增益系数;  $T_1, T_2$  为时间常数.

带材的厚度和板形检测装置均可看作一个时延环节  $e^{-\tau s}$ . 整个AFC-AGC综合系统可由如下矩阵方程表示:

$$\begin{bmatrix} \Delta\sigma_1 \\ \Delta h \end{bmatrix} = \begin{bmatrix} G_{11}(s) & G_{12}(s) \\ G_{21}(s) & G_{22}(s) \end{bmatrix} \begin{bmatrix} \Delta 2F \\ \Delta S \end{bmatrix} + \begin{bmatrix} \eta_1(s) \\ \eta_2(s) \end{bmatrix}, \quad (5)$$

$$G_{11}(s) = -\frac{\varphi_b E}{(1 - \nu^2)h} \cdot \left( \frac{1}{K_F} + \frac{1}{K_P} \frac{C_P Q}{C_P + Q} \frac{1}{C_F} \right) \cdot \frac{K_1}{1 + T_1s} e^{-\tau s},$$

$$G_{12}(s) = -\frac{\varphi_b E}{(1 - \nu^2)h} \cdot \frac{C_P Q}{K_P(C_P + Q)} \frac{K_2}{1 + T_2s} e^{-\tau s},$$

$$G_{21}(s) = \frac{C_P}{(C_P + Q)C_F} \cdot \frac{K_1}{1 + T_1s} e^{-\tau s},$$

$$G_{22}(s) = \frac{C_P}{C_P + Q} \cdot \frac{K_2}{1 + T_2s} e^{-\tau s},$$

$$\eta_1 = \left[ \frac{C_P Q}{K_P(C_P + Q)} \Delta H + \left( \frac{1}{K_w} - \frac{h}{H} \right) \Delta H_w + \frac{h \Delta \sigma_0}{E} (1 - \nu^2) \right] \cdot \frac{\varphi_b E}{(1 - \nu^2)h},$$

$$\eta_2 = \frac{Q}{C_P + Q} \Delta H.$$

公式(5)说明弯辊力调节  $\Delta 2F$  对轧制力变化  $\Delta\sigma_1$  所产生的主要影响、辊缝调节量  $\Delta S$  对出口厚度改变量  $\Delta h$  的主要影响以及来料厚度、来料凸度和入口横向张力差的变化量 ( $\Delta H, \Delta H_w, \Delta\sigma_0$ ) 等因素对  $\Delta 2F, \Delta\sigma_1$  的影响.  $h, H$  分别为轧后和来料平均厚度;  $K_P, C_P$  和  $K_F, C_F$  分别为轧机纵向、横向刚度系数和弯辊纵向、横向刚度系数;  $E, Q, \nu$  分别为轧件的弹性模量、塑性系数和泊松比;  $\varphi_b$  为考虑横向不均匀变形的系数, 其值小于1;  $\eta_1, \eta_2$  为扰

动信号. AFC-AGC的动态系统的特性可描述为

$$Y(k+1) = F[Y(k), Y(k-1), \dots, Y(k-n), U(k-d), U(k-d-1), \dots, U(k-d-m)], \quad (6)$$

其中:  $Y(k) = [\sigma_1(k), h(k)]^T$ ,  $\sigma_1$  为板形输出值,  $h$  为板厚输出值;  $U(k) = [\Delta 2F(k), \Delta S(k)]^T, m, n$  分别为输入和输出阶次,  $d$  为系统的时间延迟阶次, 可通过离散化方式获得. 由离散AFC-AGC模型可知:  $\det \frac{\partial F}{\partial U(k)} > 0$ . 由定理1和定理2可知, AFC-AGC综合系统可逆, 并存在AFC-AGC的小波神经网络  $\alpha$  阶时延逆系统.

### 2.3 AFC-AGC小波神经网络逆系统解耦实现(Inverse system decouple implement with WNN for AFC-AGC)

对于AFC-AGC, 其小波神经网络  $\alpha$  阶时延逆系统解耦实现步骤如下:

- 1) 确定模型各通道输入阶次  $n_i$  输出阶次  $m_i$  及时延阶次  $\alpha_i$ , 对于AFC-AGC, 可以依据其离散化模型以及系统的参数得到.
- 2) 对采样数据重新排序组合. 如果得到  $N$  对采样数据, 则可得到  $N - \alpha$  组有效输入和输出训练样本集.
- 3) 建立小波神经网络结构, 用训练数据对小波神经网络进行离线训练. 文中采用离散仿射小波神经网络, 网络的输入节点数为8个, 输出节点数为2个, 由于输入维数较多, 采用结构风险最小化原理优化网络完成小波神经网络的离线训练<sup>[6]</sup>.
- 4) 将训练好的时延逆系统串联到原系统之前组成伪线性复合系统, 如图2所示. 完成小波神经网络  $\alpha$  阶时延逆系统设计.




图2  $\alpha$ 阶时延伪线性复合系统

Fig. 2  $\alpha$ -th order time delay pseudo-linear system

从其实现过程来看, 小波神经网络的  $\alpha$  阶时延逆系统结构简单、易于设计, 仅由静态小波神经网络和若干表征逆系统特性的时延因子构成, 且对被控对象的数学模型的先验知识要求较少, 具有最小时延, 工程可实现. 这正是其实现多变量系统

解耦的优势所在。

### 3 基于小波神经网络的AFC-AGC解耦预测控制(AFC-AGC decoupling predictive control based on WNN)

#### 3.1 解耦预测控制系统框图(Block of decoupling predictive control system)

由于AFC-AGC含有时延环节,普通的反馈控制方法可能导致控制系统不稳定.预测控制是解决这个问题行之有效的方法之一<sup>[7]</sup>.

图3给出了AFC-AGC的小波神经网络 $\alpha$ 阶时延逆系统解耦预测控制框图.其中 $y_1^*, y_2^*$ 分别为板

形和板厚的设定值;  $y_1(k) = \sigma_1(k), y_2(k) = h(k)$ 分别为板形和板厚的输出值;  $G_{m1}, G_{m2}$ 分别为板形通道和板厚通道的预测模型传递函数; 虚线框内为由小波神经网络 $\alpha$ 阶时延逆系统和AFC-AGC综合系统构成的伪线性复合系统.  $k$ 时刻的输出可以表示为

$$\begin{cases} Y_1(k) = y'_1(k) + v_1(k), \\ Y_2(k) = y'_2(k) + v_2(k). \end{cases} \quad (7)$$

其中:  $y'_1(k), y'_2(k)$ 为复合系统的主要部分,而 $v_1(k), v_2(k)$ 为干扰环节以及复合系统所含弱非线性部分对应的输出.

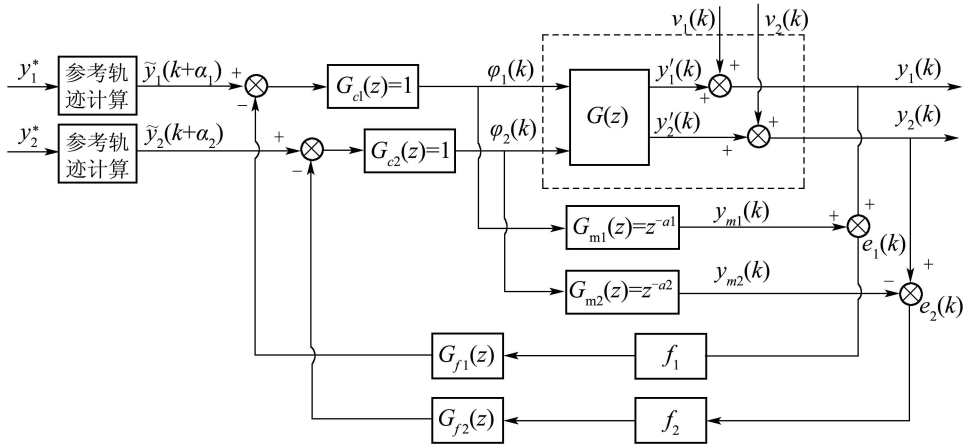


图3 AFC-AGC的小波神经网络 $\alpha$ 阶时延逆系统解耦预测控制

Fig. 3 Decoupling predictive control of AFC-AGC system using WNN  $\alpha$ -th order time delay inverse system method

对板形板厚系统可分别进行控制器设计,设计方法相同,为说明方便,去掉下角标,解耦后的预测模型可简化为

$$y_m(k + \alpha) = \theta(k) + \theta'(k) = \varphi(k), \quad (8)$$

$\theta'(k)$ 代表伪线性复合系统中的弱非线性因素.考虑 $\theta'(k)$ 及AFC-AGC在实际工作中来料干扰、模型参数变化等原因,引入伪线性复合系统和预测模型当前输出的偏差进行修正<sup>[8]</sup>.修正后的 $\alpha$ 步超前预测输出为

$$\begin{aligned} y_p(k + \alpha) = \\ y_m(k + \alpha) + y(k) - y_m(k) = \\ \varphi(k) + fe(k), \end{aligned} \quad (9)$$

式中:  $e(k)$ 为复合系统和预测模型 $k$ 时刻的误差,  $f$ 为误差修正系数.

参考轨迹设计是预测控制算法一个比较重要的环节.设 $y^*$ 为系统期望输出,为使系统平稳快速

地达到系统给定值,预测控制的参考轨迹采用如下形式:

$$\begin{cases} \tilde{y}(k + \alpha - 1) = y(k), \\ \tilde{y}(k + j) = \beta \tilde{y}(k + j - 1) + (1 - \beta)y^*, \\ j = \alpha, \alpha + 1, \dots, \end{cases} \quad (10)$$

式中 $\beta$ 为柔化因子,主要影响系统的鲁棒性;  $\beta$ 越大,鲁棒性越好,但系统的响应也越慢.

采用下面的目标函数:

$$\begin{aligned} J_p(k) = \frac{1}{2} [y_p(k + \alpha) - \tilde{y}(k + \alpha)]^2 + \\ \frac{1}{2} [\varphi^T \Lambda \varphi(k)], \end{aligned} \quad (11)$$

式中 $\Lambda = \text{diag}\{\lambda_1, \lambda_2\}$ 为两个控制量加权系数.

在图3中为进一步提高系统的鲁棒性,在反馈通道上增加了1阶反馈滤波器 $G_f(z) = \frac{1 - \beta_f}{1 - \beta_f z^{-1}}$ ,式中滤波器参数 $\beta_f$ 根据实际情况选取.

### 3.2 仿真结果及分析(Simulation results and analysis)

为了验证本文所提控制方法的有效性, 进行了仿真研究. 小波基函数采用多维径向基函数, 考虑系统希望输出为 $\sigma_1 = 0.01(10\text{ MPa})$ ,  $h = 1.35\text{ mm}$ , 控制系统中滤波器参数选取 $\beta_f = 0.2$ , 柔化系数 $\beta_f = 0.7$ , 误差反馈系数 $f = 1$ , 两通道控制参数相同. 仿真步长 $T = 1\text{ ms}$ . 仿真分下述3种情况进行.

1) 不加入任何扰动量, 测试跟踪效果. 入口厚度为 $H=1.51\text{ mm}$ ,  $H_w=0.01\text{ mm}$ ,  $\sigma_0=0.01(10\text{ MPa})$ . 设系统希望输出为方波形式:  $\sigma_1 = 0.01 \pm 0.01(10\text{ Mpa})$ ,  $h = 1.35 \pm 0.3(\text{mm})$ .

由图4中可知, 控制系统可以及时跟踪输入变化, 系统具有较高的响应性能, 输出没有余差.

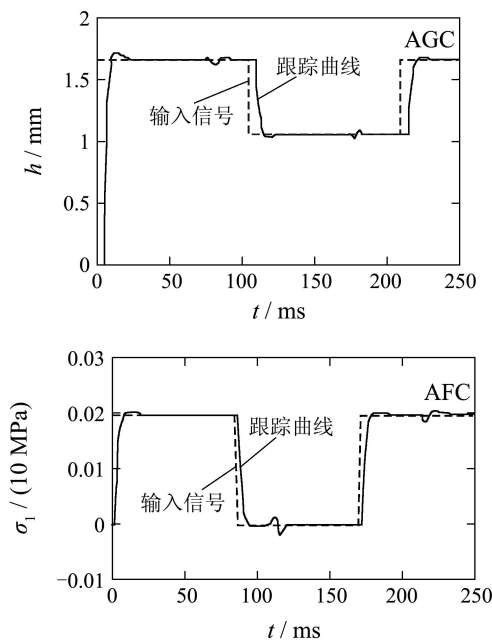


图4 控制系统仿真结果(不加扰动)  
Fig. 4 Simulation results of control system without disturbance

2) 加入板形板厚扰动. 考虑来料偏差为正弦波动形式, 只加入板厚扰动 $\Delta H = 0.06 \sin(10t)(\text{mm})$ 时, 仿真结果如图5(a)所示. 只加入板形扰动, 加入凸度扰动 $\Delta H_w = 0.001 \sin(10t)(\text{mm})$ 、横向张力差扰动 $\Delta \sigma_0 = 0.01 \sin(10t)(10\text{ MPa})$ 时, 仿真结果如图5(b)所示. 同时加入板厚板形扰动 $\Delta H, \Delta H_w, \Delta \sigma_0$ , 仿真结果如图5(c)所示.

从图5所示的仿真结果中可以看出, 由小波神经网络构造的 $\alpha$ 阶时延逆系统解耦器改善了控制系统的性能. 当加入板厚扰动时, 板厚的调整基本上没有影响到板形; 当加入板形扰动时, 板形的

调整基本上没有影响到板厚, 过渡过程相对比较平稳, 说明解耦是成功的. 从图5(c)中可以看出, 当系统存在来料板形板厚干扰时, 系统仍能获得板形和满意的厚度精度, 且调节时间、超调量均能满足控制要求, 说明控制系统具有较强的抗干扰能力.

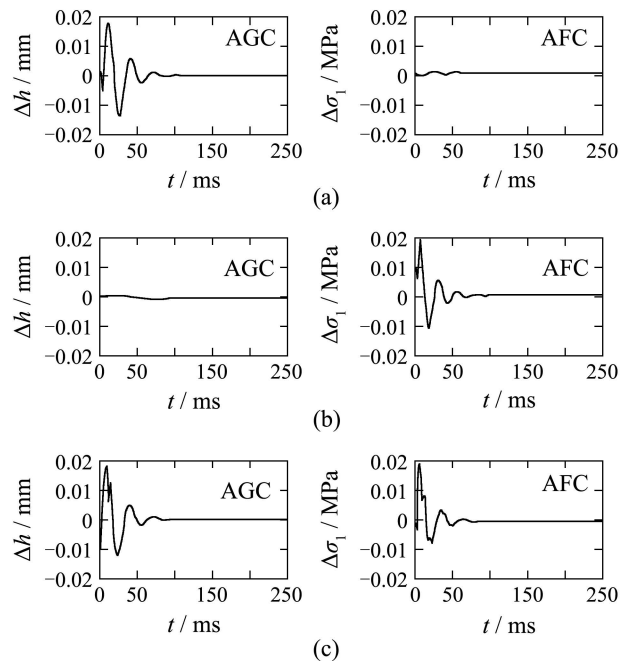


图5 控制系统仿真结果(加扰动)

Fig. 5 Simulation results of control system with disturbance

3) 考虑被控对象的模型参数变化扰动. 假定液压压下和液压弯辊系统参数有变动, 即 $\Delta T_1 = 0.00025$ ,  $\Delta T_2 = 0.00025$ , 仿真结果见图6.




图6 控制系统仿真结果(加入模型摄动扰动)

Fig. 6 Simulation results of control system with model disturbance

从图中可以看出, 系统可以有效的抑制干扰, 同时对模型误差具有很好的鲁棒性, 且系统的动态性能满足控制要求.

### 4 结论(Conclusion)

针对板形板厚综合系统的多变量、强耦合和纯时滞特点, 研究了一种基于小波神经网络的解耦预测控制方法. 用小波神经网络来逼近板形板厚