

## CONTROLE NEURAL ADAPTATIVO DE UM TREM DE LAMINAÇÃO A QUENTE

Francisco Guido Rossomando<sup>\*</sup>, Edson de P. Ferreira<sup>†</sup>, and Jose Denti Filho<sup>†</sup>

<sup>\*</sup> LCI, DEL, CT, Universidade Federal do Espírito Santo  
29060-900, Av. Fernando Ferrari, s/n, Vitória, ES, Brasil, +55-27-3335-2687  
e-mail: frosoma@ele.ufes.br; edinho@ele.ufes.br; j.denti@ele.ufes.br

**Palavras Chaves:** controle neural, laminação a quente, estrutura de celdas dinamicas.

**Resumo.** *Este artigo propõe e explicita uma estratégia de controle adaptativo neural para o processo de controle de variação da espessura da tira num trem de laminação a quente. A qualidade do produto laminado depende da minimização da variação da espessura da tira. O modelo do sistema, extremamente complexo, é apresentado numa formulação em variáveis de estado e serve de base para um ambiente de simulação, desenvolvido para apoiar a validação da estratégia proposta, que também pode ser utilizado no desenvolvimento de outras estratégias. A estratégia proposta apresenta melhor desempenho quando comparada com os resultados reais do controle convencional de um trem de laminação, gentilmente fornecidos pela SIDERAR S. A., siderúrgica da Argentina.*

## 1. INTRODUÇÃO

O processo de laminação de planos consiste em submeter uma placa de metal a um conjunto de cilindros rotativos que imprimirão nesta placa uma deformação permanente, isto é, a redução de espessura. As máquinas que promovem esta deformação, nas quais se encontram os conjuntos de cilindros

rotativos, são as cadeiras de laminação. Um conjunto de cadeiras de laminação constitui um trem de laminação. Na Fig. 1 tem-se um esquema de duas cadeiras de laminação simples com quatro cilindros cada uma e com sistemas de ajuste de espessura (parafuso). Os cilindros em contato com a tira imprimindo-lhe deformação desejada são os cilindros de trabalho. No processo de laminação normalmente temos 6 cadeiras, onde nas 4 primeiras o objetivo de controle é de manter o esforço aplicado constante, deixando para as duas últimas o ajuste da espessura desejada de tira, por isso neste trabalho levamos em conta somente as duas últimas cadeiras do trem de laminação. As cadeiras de laminação são constituídas por quatro cilindros, dois cilindros de trabalho e dois de apoio ou encosto,

Tomando como base a Fig. 1 passamos a discorrer brevemente sobre o funcionamento da cadeira.

A tira proveniente das cadeiras anteriores em forma de produto plano ou de uma bobina (material enrolado), é introduzida na abertura entre os cilindros de trabalho, que é menor que a espessura da tira, esta abertura (gap) é determinada pela posição dos parafusos que posicionam os cilindros.

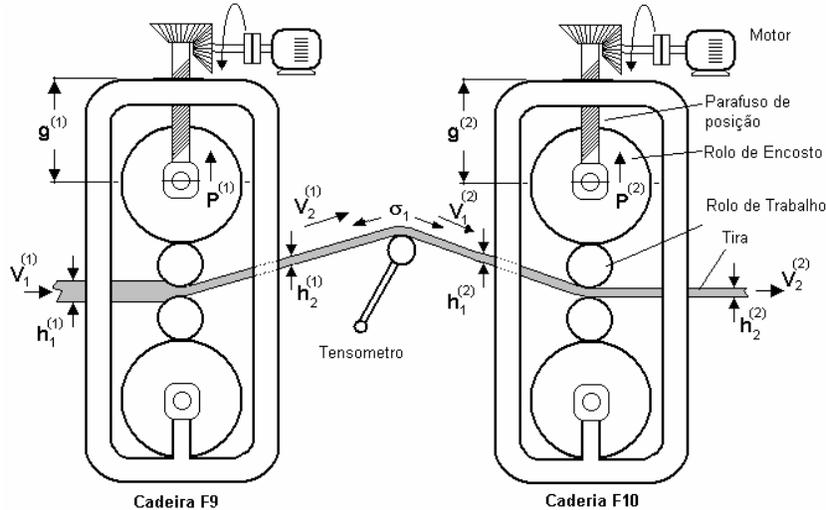


Fig. 1: Cadeiras de Laminação com dois rolos de trabalho e dois de encosto.

Estes cilindros arrastam a tira para o interior da cadeira, promovendo uma redução de espessura na mesma. Esta tira deve sair, e entrar na outra cadeira até obter a espessura desejada ou ser bobinada na saída da última cadeira.

Nossa principal motivação neste trabalho é a redução das variações da espessura de saída para qualquer de duas perturbações das variáveis de entrada do processo (Temperatura da tira

ou espessura de entrada), a Fig. 2 mostra três gráficos de um processo real de laminação nas quais observamos a presença de zonas frias pontos (indicados pela seta) Fig. 2 (b), que são pontos de contato com os roletes refrigerados dos fornos de aquecimento. Estas zonas tem maior resistência a deformação o que produz um aumento da força de separação na cadeira de laminação Fig. 2 (a). Estas variações da força de separação. produzem variações no estiramento da cadeira de laminação, produzindo variações na espessura de saída da cadeira.

Observando a temperatura na saída do laminador, vêm-se zonas localizadas de temperatura mais baixas que são as marcas dos roletes anteriormente mencionadas, Por outro lado observa-se uma queda de temperatura do inicio ao fim. Esta perda térmica, produz aumentos proporcionais na força de separação e conseqüentemente na espessura Fig. 2 (c), sendo principalmente as variações da temperatura e da espessura de entrada as que produzem variações na força de separação alterando a espessura de saída.

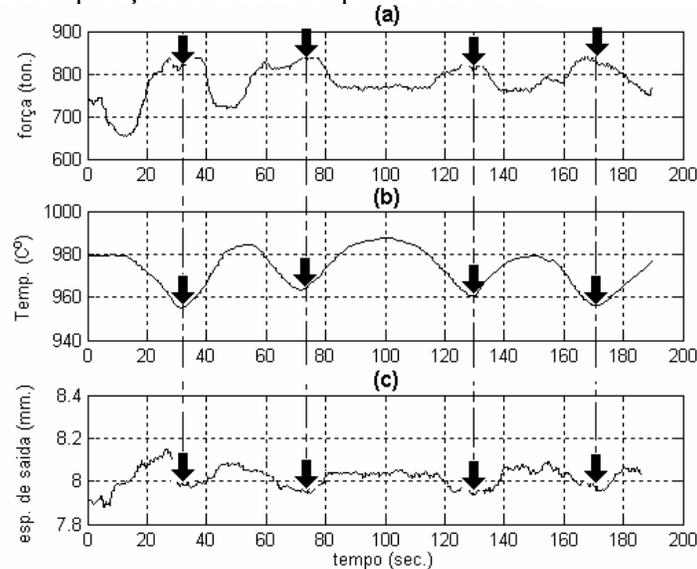


Fig. 2: Pontos frios na tira.

Neste trabalho é apresentada uma proposta de estratégia de controle da espessura de saída na laminação de produtos planos. Esta estratégia leva em consideração o conhecimento do processo, para a implementação de técnicas de controle adaptativo neural.

Para a análise e a síntese de estratégias de controle, para o problema em questão, foi desenvolvido um ambiente de simulação, também apresentado neste trabalho. Este ambiente mostrou-se versátil e bastante adequado na validação da estratégia proposta bem como na comparação, com uma estratégia convencional, em uso na indústria siderúrgica.

Nos itens subseqüentes é descrita a estratégia convencional de controle e a estratégia adaptativa proposta, incluindo a modelagem analítica que serve de base para a implementação do simulador. Finalizando apresentamos uma análise comparativa dos resultados e as conclusões.

2. CONTROLE CONVENCIONAL

O sistema de controle de espessura *force feed forward* (FFF) é baseado na detecção de flutuações na resistência a deformação do material que esta sendo laminado na primeira cadeira sendo esta informação enviada ao modelo de setup.

Mantendo-se constante o gap em cada cadeira, as diferenças na resistência a deformação são refletidas sobre a carga de laminação. O material laminado é monitorado continuamente, e é possível ajustar o gap das próximas cadeiras antes da chegada de distúrbios.

Os cálculos são feitos considerando a tira dividida em fatias. Para cada fatia de tira na primeira cadeira, a carga de laminação é lida. A resistência de deformação atual e a evolução térmica sobre o trem de laminação são usadas para calcular a espessura que a tira deveria ter na saída de cada cadeira. As espessuras são avaliadas, sendo as menores correspondentes aos pedaços mais frios e as maiores a os pedaços da tira mais quente. Finalmente, as variações medidas na carga são usadas para ajustar os cálculos e para poder agir sobre o gap nas últimas duas cadeiras de laminação.

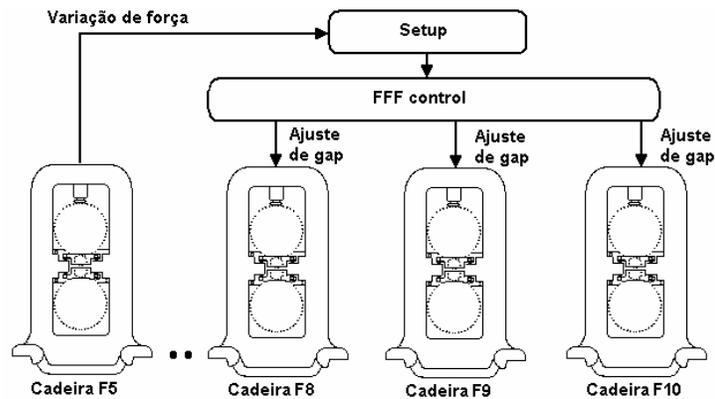


Fig. 3: Controle com Force Feed Forward.

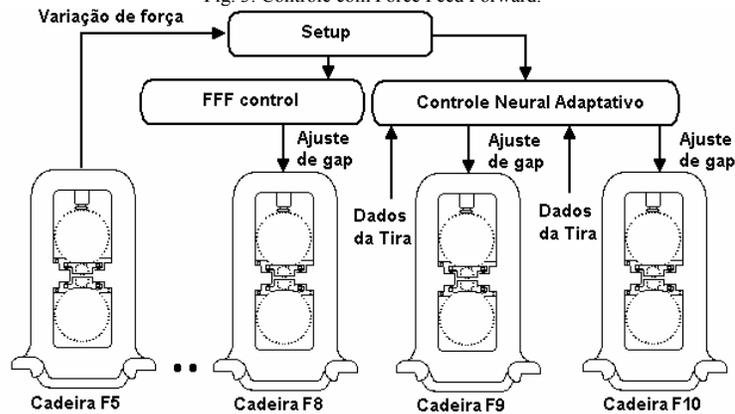


Fig. 4: Controle proposto com controle adaptativo sobre as duas ultimas cadeiras.

### 3. CONTROLE PROPOSTO

Para desenvolver o controle nas duas últimas cadeiras aplicamos técnicas de controle neural adaptativo ao modelo representado em espaço de estado.

Para o sistema considerado nossas entradas de controle são  $\Delta g_{in}^{(1)}$ ,  $\Delta V_{in}^{(1)}$ ,  $\Delta g_{in}^{(2)}$  as saídas controladas são  $\Delta h_2^{(1)}$ ,  $\Delta \sigma_1$ ,  $\Delta h_2^{(2)}$ , sendo as saídas medidas  $\Delta h_2^{(1)}$ ,  $\Delta \sigma_1$ ,  $\Delta h_2^{(2)}$ ,  $\Delta P^{(1)}$  e  $\Delta P^{(2)}$ . O objetivo básico de controle é de manter a variação da espessura de saída da tira ( $\Delta h_2$ ) o mais próximo possível do valor zero, para qualquer variação da temperatura, ou da espessura de entrada no sistema.

Qualquer alteração nas variáveis de entrada são consideradas perturbações e o sistema de controle deve manter a variação da espessura o mais próximo do valor zero agindo sobre o gap ( $\Delta g$ ), a qual é a nossa variável de controle da variação da espessura de saída ( $\Delta h_2$ ). O mesmo acontece para a variação de tensão que depende da quantidade da tira acumulada entre as cadeiras F9 e F10 e esta tensão é função das diferenças de velocidade de saída e de entrada da tira nas cadeiras F9 e F10 respectivamente, em nosso caso esta tensão é controlada pela variação da velocidade periférica dos cilindros da cadeira F9

#### 3.1. Modelagem analítica do processo

Neste trabalho apresentamos um modelo matemático das duas últimas cadeiras F9 e F10 do trem de laminação, para poder avaliar a técnica de controle proposta. (O sistema FFF faz o ajuste de espessura nas duas últimas cadeiras), o modelamento analítico aqui utilizado destina-se tão somente a permitir a validação, via simulação, dos resultados obtidos.

Esses resultados são comparados com os valores reais medidos nas cadeiras de laminação controlados pelo controle FFF (*force feed forward*) (Bryant. et al 1973)<sup>1</sup> (Ginzburg et al. 1989)<sup>2</sup>.

Para obter um modelo aproximado da cadeira de laminação, trabalho-se com as teorias de Orowan (Orowan et al 1944)<sup>3</sup>, e Alexander (Alexander et al 1972)<sup>4</sup>, as quais aparecem como as mais confiáveis para a obtenção da carga de laminação, podendo usá-las numa ampla faixa de condições de laminação. O modelo matemático foi ajustado e calibrado com valores reais medidos no processo, obtendo uma resposta muito próxima ao valor de carga real este modelo esta representado de forma geral pela eq. (4) e o escorregamento pela eq. (5).

Agora apresentamos o desenvolvimento do ambiente de simulação utilizando uma representação do processo em espaço de estados.

A espessura de saída de cada cadeira é função do gap dos cilindros e do estiramento da cadeira.

$$h_2^{(i)} = g^{(i)} + \frac{P^{(i)}}{K^{(i)}} \quad (1)$$

Onde:

$h_2^{(i)}$ : Espessura de saída da cadeira (i).

$g^{(i)}$ : gap dos cilindros para a cadeira (i)

$P^{(i)}$ : Carga de laminação na cadeira (i).

$K^{(i)}$ : Índice de elasticidade da cadeira (i).

$(i)$ : Cadeira de laminação  $i=1$  (F9),  $i=2$  (F10).

A tensão entre as cadeiras de laminação é função da diferença da velocidade de saída para cadeira F9 menos velocidade de entrada para a cadeira F10:

$$\frac{d\sigma_1}{dt} = \frac{E}{L}(V_2^{(1)} - V_1^{(2)}) \quad (2)$$

Onde:

$\sigma_1$ : tensão da tira entre a cadeira F9 e F10.

$E$ : Modulo de Young da tira

$L$ : Distância de separação entre cadeiras (i).

$V_2^{(1)}$ : Velocidade de saída da tira na cadeira F9.

$V_1^{(2)}$ : Velocidade de entrada da tira na cadeira F10.

A continuidade de volume da tira no gap dos cilindros esta definida como:

$$V_1^{(i)} h_1^{(i)} = V_2^{(i)} h_2^{(i)} \quad (3)$$

A força de laminação esta representada pela equação:

$$P^{(i)} = P(h_1^{(i)}, h_2^{(i)}, \sigma_1^{(i)}, \sigma_2^{(i)}, S^{(i)}, \mu^{(i)}, T^{(i)}) \quad (4)$$

Onde:

$\sigma_2^{(i)}$ : tensão a frente para a cadeira (i)

$g^{(i)}$ : gap dos cilindros para a cadeira (i)

$\mu^{(i)}$ : Coeficiente de atrito da cadeira (i)

$S^{(i)}$ : Tensão de escoamento da cadeira (i)

A função de escorregamento esta definida como:

$$f^{(i)} = f(h_1^{(i)}, h_2^{(i)}, \sigma_1^{(i)}) \quad (5)$$

### 3.2. Considerações básicas do modelo

A principal consideração é que o controle é aplicado só quando existe tira entre duas cadeiras, ou seja, não é considerado o momento anterior a entrada da tira na última cadeira.

Consideramos as variações infinitesimais dos valores nominais. Por exemplo a variável  $x$ , sendo  $\Delta x$  a variação infinitesimal e  $x^*$  o valor nominal.

Consideramos também que a força de laminação função da espessura de entrada, espessura de saída temperatura e da tensão entre cadeiras. As curvas de sensibilidade representam a variação da força de laminação (Denti,1994)<sup>5</sup> e (Hoshino,1988)<sup>6</sup>

$$\begin{aligned} \Delta P^{(1)} &= \beta_1 \cdot \Delta \sigma_1 + \beta_2 \cdot \Delta h_2^{(1)} + \beta_3 \cdot \Delta h_1^{(1)} + \beta_4 \cdot \Delta T^{(1)} \\ \Delta P^{(2)} &= \beta_5 \cdot \Delta \sigma_1 + \beta_6 \cdot \Delta h_2^{(2)} + \beta_7 \cdot \Delta h_1^{(2)} + \beta_8 \cdot \Delta T^{(2)} \end{aligned} \quad (6)$$

Onde os coeficientes da função linearizada são::

$$\begin{aligned} \beta_1 &= \frac{\partial P^{(1)}}{\partial \sigma_1}; \beta_2 = \frac{\partial P^{(1)}}{\partial h_2^{(1)}}; \beta_3 = \frac{\partial P^{(1)}}{\partial h_1^{(1)}}; \beta_4 = \frac{\partial P^{(1)}}{\partial T^{(1)}} \\ \beta_5 &= \frac{\partial P^{(2)}}{\partial \sigma_1}; \beta_6 = \frac{\partial P^{(2)}}{\partial h_2^{(2)}}; \beta_7 = \frac{\partial P^{(2)}}{\partial h_1^{(2)}}; \beta_8 = \frac{\partial P^{(2)}}{\partial T^{(2)}} \end{aligned} \quad (7)$$

A variação do escorregamento é função da espessura de entrada, da espessura de saída e da tensão da tira e esta representado pelas equações:

$$\begin{aligned} \Delta f^{(1)} &= \alpha_1 \cdot \Delta \sigma_1 + \alpha_2 \cdot \Delta h_2^{(1)} + \alpha_3 \cdot \Delta h_1^{(1)} \\ \Delta f^{(2)} &= \alpha_4 \cdot \Delta \sigma_1 + \alpha_5 \cdot \Delta h_2^{(2)} + \alpha_6 \cdot \Delta h_1^{(2)} \end{aligned} \quad (8)$$

Onde os coeficientes são:

$$\begin{aligned} \alpha_1 &= \frac{\partial f^{(1)}}{\partial \sigma_1}; \alpha_2 = \frac{\partial f^{(1)}}{\partial h_2^{(1)}}; \alpha_3 = \frac{\partial f^{(1)}}{\partial h_1^{(1)}} \\ \alpha_4 &= \frac{\partial f^{(2)}}{\partial \sigma_1}; \alpha_5 = \frac{\partial f^{(2)}}{\partial h_2^{(2)}}; \alpha_6 = \frac{\partial f^{(2)}}{\partial h_1^{(2)}} \end{aligned} \quad (9)$$

A variação das velocidades de saída da tira são expressadas pela variação do coeficiente de escorregamento e pela velocidade periférica do cilindro:

$$\begin{aligned} \Delta V_2^{(1)} &= (1 + f^{*(1)}) \cdot \Delta V^{(1)} + V^{*(1)} \cdot \Delta f^{(1)} \\ \Delta V_2^{(2)} &= (1 + f^{*(2)}) \cdot \Delta V^{(2)} + V^{*(2)} \cdot \Delta f^{(2)} \end{aligned} \quad (10)$$

As variáveis controladas não são diretamente afetadas pela velocidade periférica da última cadeira. Então fazemos  $\Delta V_2 = 0$ .

Cada atuador tem uma dinâmica que pode ser aproximada a um sistema da primeira ordem descrita como:

$$T_g \frac{dg^{(i)}}{dt} = g_{in}^{(i)} - g^{(i)} \quad (11)$$

$$T_v \frac{dV^{(i)}}{dt} = V_{in}^{(i)} - V^{(i)} \quad (12)$$

As variáveis  $\Delta h_1^{(1)}$ ,  $\Delta T^{(1)}$  e  $\Delta T^{(2)}$  serão consideradas perturbações para o sistema:

A variação da espessura de saída da cadeira F9 é igual á variação da espessura de entrada da cadeira F10 com um tempo de retardo definido:

$$Td = L / (V^{*(1)} + \Delta V^{(1)}), \text{ então } \Delta h_1^{(2)} = \Delta h_2^{(1)} e^{-s \cdot Td}$$

A estrutura geral do modelo representado em espaço de estados é mostrada na equação (13)

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A} \cdot \mathbf{x} + \mathbf{B} \cdot \mathbf{u} + \mathbf{E}_1 \cdot \mathbf{p} \\ \mathbf{y} = \mathbf{C} \cdot \mathbf{x} + \mathbf{E}_2 \cdot \mathbf{p} \\ \mathbf{z} = \mathbf{F} \cdot \mathbf{x} + \mathbf{E}_3 \cdot \mathbf{p} \end{cases} \quad (13)$$

Onde os vetores de entrada, de variáveis de estado, de perturbação e de saída são:

$$\mathbf{x} = \begin{pmatrix} \Delta \sigma_1 \\ \Delta g^{(1)} \\ \Delta V^{(1)} \\ \Delta g^{(2)} \end{pmatrix}; \mathbf{y} = \begin{pmatrix} \Delta h_2^{(1)} \\ \Delta \sigma_1 \\ \Delta h_2^{(2)} \end{pmatrix}; \mathbf{p} = \begin{pmatrix} \Delta h_1^{(1)} \\ \Delta T^{(1)} \\ \Delta T^{(2)} \end{pmatrix}; \mathbf{u} = \begin{pmatrix} \Delta g_{in}^{(1)} \\ \Delta V_{in}^{(1)} \\ \Delta g_{in}^{(2)} \end{pmatrix}; \mathbf{z} = \begin{pmatrix} \Delta P^{(1)} \\ \Delta P^{(2)} \end{pmatrix}$$

Os coeficientes obtidos para construir as matrizes de espaço de estado são:

$$\begin{aligned} \varepsilon_1 &= \left( \frac{K^{(1)}}{K^{(1)} - \beta_2} \right); \varepsilon_2 = \left( \frac{\beta_1}{K^{(1)} - \beta_2} \right); \varepsilon_3 = \left( \frac{\beta_3}{K^{(1)} - \beta_2} \right); \varepsilon_4 = \left( \frac{\beta_4}{K^{(1)} - \beta_2} \right) \\ \varepsilon_5 &= \left( \frac{K^{(2)}}{K^{(2)} - \beta_6} \right); \varepsilon_6 = \left( \frac{\beta_5}{K^{(2)} - \beta_6} \right); \varepsilon_7 = \left( \frac{\beta_7}{K^{(2)} - \beta_6} \right); \varepsilon_8 = \left( \frac{\beta_8}{K^{(2)} - \beta_6} \right) \\ T_\sigma &= -1 \left/ \left\{ \frac{E}{L} \left( V^{*(1)} \cdot (\alpha_1 + \alpha_2 \cdot \varepsilon_2) - V^{*(2)} \cdot (\alpha_4 + \alpha_5 \cdot \varepsilon_6) \cdot \frac{h_2^{*(2)}}{h_1^{*(2)}} \right) \right\} \right. ; M_1 = \frac{E}{L} \cdot (V^{*(1)} \cdot \alpha_2 \cdot \varepsilon_1) \cdot T_\sigma \\ M_2 &= -\frac{E}{L} \cdot \left( V^{*(2)} \cdot \alpha_5 \cdot \varepsilon_5 \cdot \frac{h_2^{*(2)}}{h_1^{*(2)}} \right) \cdot T_\sigma \\ M_3 &= \frac{E}{L} \cdot (1 + f^{*(1)}) \cdot T_\sigma ; p_1 = \frac{E}{L} \cdot \left( V^{*(1)} \cdot (\alpha_2 \cdot \varepsilon_3 + \alpha_3) \right) \cdot T_\sigma \\ p_2 &= \frac{E}{L} \cdot \left( V^{*(1)} \cdot \alpha_2 \cdot \varepsilon_4 \right) \cdot T_\sigma ; p_3 = -\frac{E}{L} \cdot \left( \frac{h_2^{*(2)}}{h_1^{*(2)}} \cdot V^{*(2)} \cdot (\alpha_5 \cdot \varepsilon_7 + \alpha_6) \right) \cdot T_\sigma \\ p_4 &= -\frac{E}{L} \cdot \left( \frac{h_2^{*(2)}}{h_1^{*(2)}} \cdot V^{*(2)} \cdot \alpha_2 \cdot \varepsilon_4 \right) \cdot T_\sigma \end{aligned}$$

Os valores de A,B,C,F são:

$$\begin{aligned} \mathbf{A} &= \begin{pmatrix} -1/T_\sigma & M_1/T_\sigma & M_3/T_\sigma & M_2/T_\sigma \\ 0 & -1/T_g^{(1)} & 0 & 0 \\ 0 & 0 & -1/T_v & 0 \\ 0 & 0 & 0 & -1/T_g^{(2)} \end{pmatrix} ; \mathbf{B} = \begin{pmatrix} 0 & 0 & 0 \\ 1/T_g^{(1)} & 0 & 0 \\ 0 & 1/T_v & 0 \\ 0 & 0 & 1/T_g^{(2)} \end{pmatrix} \\ \mathbf{C} &= \begin{pmatrix} \varepsilon_2 & \varepsilon_1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ \varepsilon_6 & 0 & 0 & \varepsilon_5 \end{pmatrix} ; \mathbf{F} = \begin{pmatrix} \beta_1 & \beta_2 \cdot \varepsilon_1 & 0 & 0 \\ \beta_5 & 0 & 0 & \beta_6 \cdot \varepsilon_5 \end{pmatrix} \end{aligned}$$

As Matrizes E<sub>1</sub>; E<sub>2</sub> e E<sub>3</sub> são as matrizes de perturbação do sistema:

$$\mathbf{E}_1 = \begin{pmatrix} p_1/T_\sigma & p_2/T_\sigma & p_3/T_\sigma & p_4/T_\sigma \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} ; \mathbf{E}_2 = \begin{pmatrix} \varepsilon_3 & \varepsilon_4 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & \varepsilon_7 & \varepsilon_8 \end{pmatrix} ; \mathbf{E}_3 = \begin{pmatrix} \beta_3 & \beta_4 & 0 & 0 \\ 0 & 0 & \beta_7 & \beta_8 \end{pmatrix}$$

O modelo anterior é convertido a espaço de estado em tempo discreto com um tempo de mostragem t<sub>0</sub>=0.4 seg. sendo mesmo período de mostragem dos dados.

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}' \cdot \mathbf{x}(k) + \mathbf{B}' \cdot \mathbf{u}(k) + \mathbf{E}_1 \cdot \mathbf{p}(k) \\ \mathbf{y}(k) = \mathbf{C}' \cdot \mathbf{x}(k) + \mathbf{E}_2 \cdot \mathbf{p}(k) \\ \mathbf{z}(k) = \mathbf{F} \cdot \mathbf{x}(k) + \mathbf{E}_3 \cdot \mathbf{p}(k) \end{cases} \quad (14)$$

### 3.3. Controlador neural adaptativo por referência a modelo (CARM).

O projeto de controladores para sistemas com acoplamento não linear entre estados e controles constitui uma área de aplicação importante para as redes recorrentes (Puskorius e

Feldkamp,1994)<sup>7</sup>,e (Puskorius et al, 1996).<sup>8</sup>,O projeto do sistema é complicado adicionalmente por outros fatores como a presença de perturbações aleatórias e não-mensuradas, a possibilidade de uma inversa não-única da planta e a presença de estados da planta que não são observáveis.

Uma estratégia de controle bem adequada para o uso de redes neurais é o controle adaptativo por referência a modelo (CARM), neste caso, o projetista deve estar familiarizado com o sistema considerado, no caso, o laminador de tiras a quente,

(Narendra e Annaswamy, 1989) <sup>9</sup>. A fig. 5 mostra o diagrama de blocos de um sistema como este no qual a adaptabilidade é utilizada para levar em conta o fato que a dinâmica da planta é desconhecida.

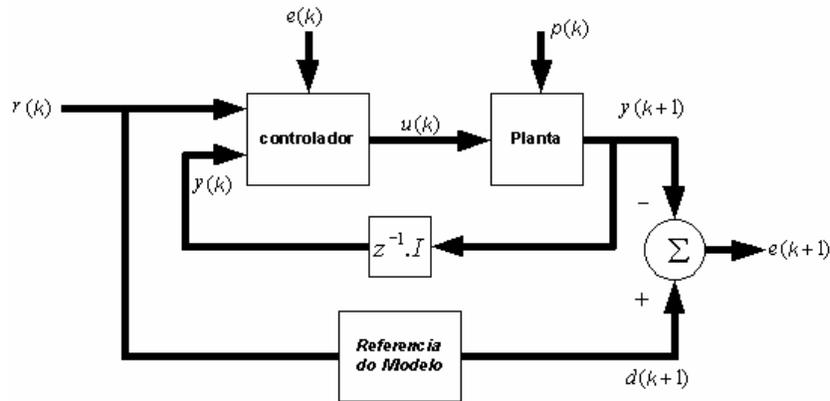


Fig. 5: Controle Adaptativo por referência a modelo utilizando controle direto

O controlador e a planta formam um sistema realimentado, que constitui uma rede externamente recorrente. A planta recebe uma entrada  $u(k)$  do controlador juntamente com uma perturbação externa  $p(k)$ . Conseqüentemente a planta evolui no tempo como uma função das entradas impostas e do seu próprio estado  $x(k)$ . A saída da planta, representada por  $y(k+1)$ , é uma função de  $x(k)$ . A saída da planta pode estar também corrompida pelo erro de medições.

O controlador recebe duas entradas: Um sinal de referência  $r(k)$  externamente especificado (que em nosso caso é  $r(k)=[0,0,0]^T$ , variação da referencia.) e  $y(k)$  representando uma versão atrasada de um passo de saída da planta  $y(k+1)$ . O controlador produz um vetor de sinais de controle definido por:

$$u(k)=f_1(x(k),y(k),r(k),w) \quad (15)$$

Onde  $x(k)$  é próprio estado do controlador e  $w$  é um vetor de parâmetros que esta disponível para ajuste. A função vetorial  $f_1(.,.,.)$  define o comportamento de entrada-saída do controlador. A resposta desejada  $d(k+1)$  para a planta é fornecida pela saída de um modelo de referência estável, que é produzido em resposta à variação da referência  $r(k)$ . A resposta desejada  $d(k+1)$  é, portando, uma função do sinal de variação referência  $r(k)$  e do próprio estado do modelo  $x(k)$ , ilustrada na equação (16).

$$d(k+1)=f_2(x(k),r(k),) \quad (16)$$

A função de valor vetorial  $\mathbf{f}_2(, )$  define o comportamento de entrada-saída do modelo de referência.

Considerando que o erro de saída (i.e., o erro entre a saída da planta e a saída de referência do modelo) seja representado por

$$\mathbf{e}(k+1) = (\mathbf{d}(k+1) - \mathbf{y}(k+1)) \quad (17)$$

O objetivo de projeto é ajustar o vetor de parâmetros  $\mathbf{w}$  do controlador de modo que a norma euclidiana do erro de saída  $\mathbf{e}(k)$  seja minimizada sobre o tempo  $k.t_0$ .

Diz-se que o método de controle utilizado no sistema CARM da fig. 5 é direto no sentido de que não é feito qualquer esforço para identificar os parâmetros da planta, e os parâmetros do controlador são diretamente ajustados para melhorar o desempenho do sistema.

### 3.4. Controlador DCS.

O controlador baseado em DCS (Dynamic Cell Structures) (Ahrns I, et. al., 1995)<sup>10</sup> são muito mais complexas que as RANs (resource allocating network) e que as redes de dimensão fixa as RBFs standard (Ahrns I, et. al., 1995). De fato, em adição à estrutura de interpolação para a estimação da saída de uma função não linear  $\mathbf{y}(\cdot)$ , as DCSs são caracterizadas por uma estrutura de conexão lateral adicional entre as unidades neurais da camada escondida. Esta estrutura é usada para refletir a topologia das entradas múltiplas. Para executar uma topologia de aprendizagem perfeita, é comumente usada uma aprendizagem Hebbiana.

Diferentemente das RANs, nas DCSs de padrões normais os centros são atualizados através de uma aprendizagem competitiva de uma maneira similar ao método de Kohonen, para aprender a distribuição das mostras de entrada de forma espacial. Durante a aprendizagem supervisionada o erro de estimação  $\mathbf{e}(k)$  é acumulado localmente e usado para determinar onde vai ser colocada a próxima unidade. Este critério de colocação a unidade é um pouco diferente do tipo RAN. Originalmente desenvolvida para aplicações off-line. O algoritmo DCS foi recentemente ampliado à aprendizagem supervisionada on-line pelo uso de um erro de estimação das regras de Kohonen modulada para a adaptação dos centros (Fiske.B, 1995)<sup>11</sup>. Os passos para ajuste do controlador são explicados a seguir:

1. Inicialização com unidades gaussianas (centros)  $a$  e  $b$  em posições aleatórias  $\mu_a$  e  $\mu_b$  e ativações aleatórias  $w_a$  e  $w_b$  definindo as larguras das funções gaussianas como  $\sigma_a = \sigma_b = \|\mu_a - \mu_b\|/2$ .
2. Lê um par de dados de entrada e saída  $[\mathbf{u}(k), \mathbf{y}(k)]$ .
3. Encontra a unidade mais próxima  $s_1$  e segunda mais próxima  $s_2$  para o par de entrada saída  $[\mathbf{u}(k), \mathbf{y}(k)]$ .
4. Acrescenta o peso de todas as unidades associadas a unidade mais próxima  $s_1$ .
5. Avalia a estimação atual de  $\hat{\mathbf{y}}(k)$ .
6. Acrescenta o erro absoluto de estimação para a variável associada a  $s_1$ :  $\Delta \text{err}(s_1) = |\mathbf{y}(k) - \hat{\mathbf{y}}(k)|$ .
7. Desloca a unidade  $s_1$  e seus vizinhos  $s_n$  para a  $\mathbf{u}(k)$  seguindo o erro da regra modulada de Kohonen.

$$\mu_{s1}(k+1) = \mu_{s1}(k) + g(\overline{\text{err}} / \text{err}(s_1)) \cdot \epsilon_1 \cdot (\mathbf{u} - \mu_{s1})$$

$\mu_{sn}(k+1) = \mu_{sn}(k) + g(\overline{err} / err(s_n)) \cdot \varepsilon_n \cdot (\mathbf{u} - \mu_{sn})$  para todo  $n$  pertencente na vizinhança  
 Onde  $g(\cdot)$  é uma função positiva monotonicamente decrescente com  $g(0)=1$  e  $g(1)=0$  respectivamente;  $\varepsilon_l$  e  $\varepsilon_n$  são os coeficientes de adaptação ( $\varepsilon_l \gg \varepsilon_n$ ).

8. Se  $s_1$  e  $s_2$  estão conectadas, coloca-se nesta conexão o valor 1, se não existe a conexão cria-se uma conexão com o valor 1.
9. Diminuir o valor das outras conexões não próximas pelo valor  $\alpha (<1)$ . Se o valor da conexão é menor que o umbral  $\alpha_{TH}$ , apagar a conexão.
10. Se o número de mostras é múltiplo do parâmetro inserção  $\lambda$  e o número de neurônios é menor que o número inicial acrescenta o número de unidades ( $N_{ma}$ ). Para acrescentar deve fazer:

- Determina a unidade  $s_q$  com o erro acumulado máximo.
- Coloca nova unidade  $s_r$  a meio caminho entre  $s_q$  e o vizinho  $s_f$  com maior erro:  $\mu_r = (w_q - w_f)/2$ . Interpola os parâmetros da nova unidade  $s_r$  como segue  $\sigma_r = (\sigma_q - \sigma_f)/2$ ,  $w_r = (w_q - w_f)/2$   $err(s_r) = (err(s_q) - err(s_f))/2$ .

11. Executa um passo de adaptação dos parâmetros da rede  $\theta = [w_1, \dots, w_n, \sigma_1, \dots, \sigma_n]$  usando a regra delta.

$$\theta(k+1) = \theta(k) - \eta \cdot \left. \frac{\partial \hat{y}(k)}{\partial \theta(k)} \right|_{(k)} \cdot e(k)$$

12. Decresce o erro  $err(s_q)$  e  $err(s_f)$  das unidades existentes multiplicando pela constante  $\alpha$ .
13. Decresce todas as variáveis de erro pelas cte.  $\delta$ .
14. Volta ao passo 2.

### 3.5. Controlador MIMO Adaline.

O modelo ADALINE, aproxima um vetor sinal  $y \in \mathbf{R}^n$  como uma combinação linear de  $M$  sinais de entrada  $x \in \mathbf{R}^m$ , p.ex  $Y = W \cdot x$ , onde  $W \in \mathbf{R}^{m \times n}$  é uma matriz de números reais que são atualizados em linha (estados). A matriz  $W$  é atualizada pelo uso de um passo de gradiente descendente para minimizar o erro quadrático meio, a lei de atualização é.:

$$W(k+1) = (W(k) - \gamma \cdot err(k) \cdot x(k)) \quad (18)$$

Onde  $\gamma$  é o índice de aprendizagem e  $err(k) = y(k) - \hat{y}(k)$  é a estimação do erro. Para este controlador existem diferentes modificações para as regras do passo de gradiente descendente, p.e. modificação sigma, e-modificação, zona morta e projecção (M. Polycarpou, 1998)<sup>12</sup>.

Para fazer a avaliação da técnica de controle usaram-se dados reais obtidos da laminação da bobina de aço N° 982 1612 feita na planta de SIDERAR S.A. na Argentina.

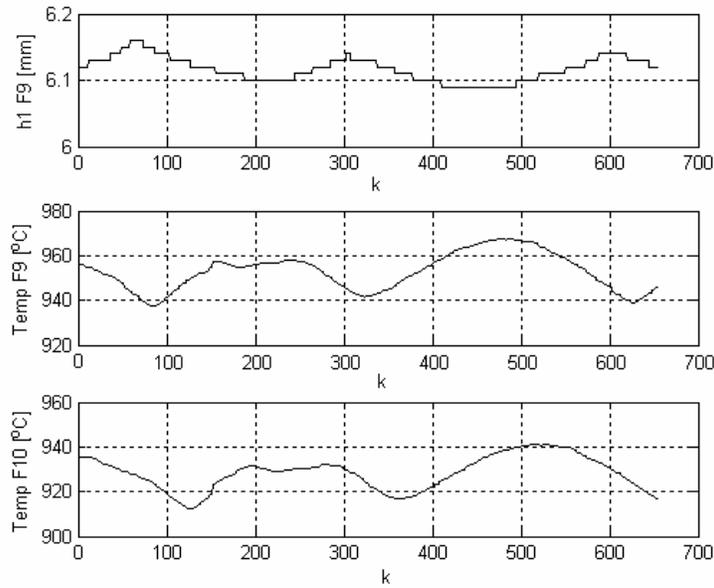


Fig. 6: Perturbações de espessura de entrada e de temperatura da tira no modelo.

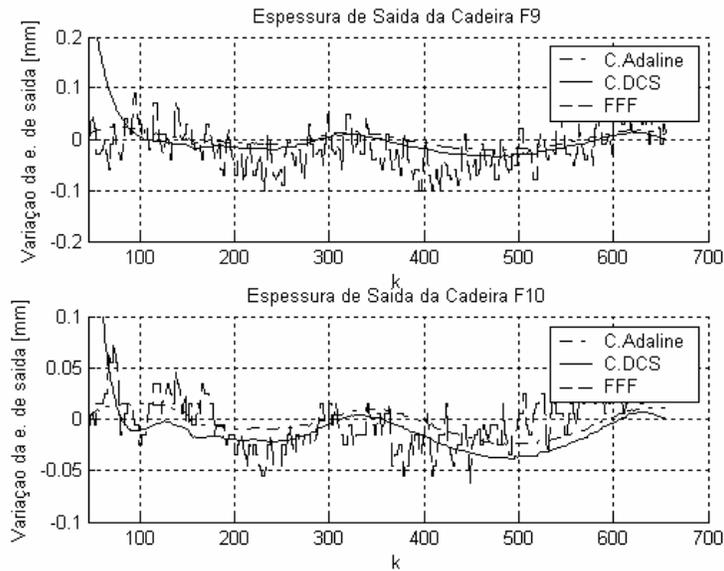


Fig. 7: Saída de variação de espessura para controle Adaptativo e FFF.

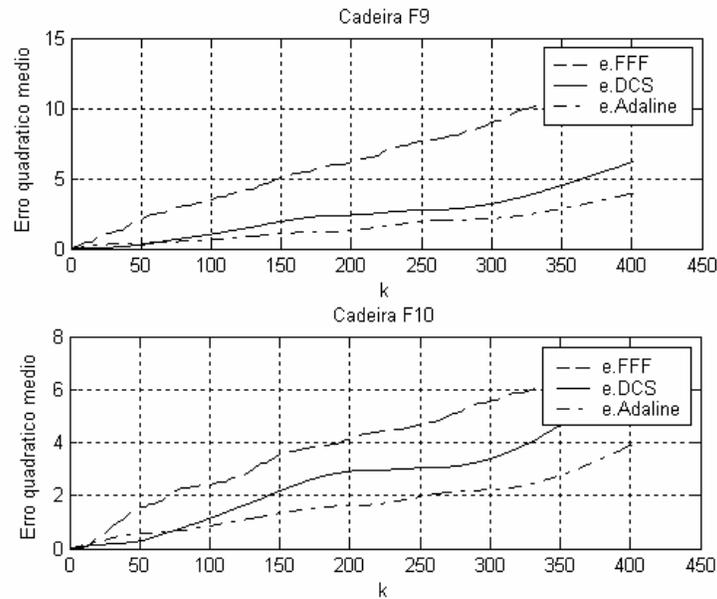


Fig. 8: Evolução da integral do erro produzido pelos diferentes controladores

Na fig. 6 mostra-se a espessura de entrada, a variação da temperatura medida no processo de laminação real e que são aplicadas ao modelo para testar o controle proposto. Só são introduzidas as variações com respeito a ponto de operação. Na simulação só são plotadas as variações de espessura de saída ( $\Delta h_2^{(1)}$  e  $\Delta h_2^{(2)}$ ) fig. 7. Os resultados de controle são comparados, os controladores neurais adaptativos (Adaline e DCS) com o controle FFF. Que em ambos casos obteve-se um erro menor do controlador FFF fig. 8, para o calculo do erro foi considerado o tempo k entre 100 e 500, já que para valores menores de 100 os controladores estavam na fase de treinamento.

A fig. 7 mostram as variações da espessura de saída para as cadeiras F9 e F10, sendo a variação de referência desejada para a saída igual a zero. O erro para o controlador neural adaptativo é menor de 50  $\mu\text{m}$  e no caso do controlador convencional (FFF) chega até 100  $\mu\text{m}$ . Obtiveram-se os mesmos resultados para diferentes dados obtidos no processo de laminação e o erro de espessura no caso de controle neural adaptativo é menor ao erro do controle FFF, que é o controlador real da planta.

#### 4. CONCLUSÕES

O modelo de laminação apresentado neste artigo é baseado no modelo de laminação dinâmico calibrado com valores reais medidos no processo de laminação. Depois fazendo a linearização do modelo no ponto de operação construímos o modelo representado em variáveis de estados. Desta forma possuímos um modelo dinâmico para as duas últimas cadeiras de laminação com um comportamento muito similar ao processo real dentro da faixa de operação que foi considerada.

Os resultados que se observam das variações de espessura comparando as duas técnicas de

controle são que, o processo controlado com técnicas de controle neural adaptativo teve menor variação de espessura que o sistema force feed forward FFF, sendo que esta última técnica apresenta uma maior dispersão da espessura. O controlador neural adaptativo, em contrapartida precisa da medição da temperatura e a espessura na entrada das duas últimas cadeiras. A técnica proposta poderia ser usada em paralelo ou em troca do sistema Force feed forward (FFF) nas duas últimas cadeiras. A principal vantagem desta técnica é que o treinamento do controlador neural é feita on-line sem precisar de tempo adicional para fazer o treinamento.

## 5. REFERÊNCIAS.

- [1] Bryant. G. "The automation of tandem cold mills", The Iron Steel Institute, London, (1973).
- [2] Ginzburg "Steel Rolling Technology: Theory and Practice. Marcel Dekker. New York and Basel (1989).
- [3] Orowan, E.. "The Calculation of Roll Pressure in Hot and Cold Rolling"; *Proc. Inst. Of Mechanical Engineers*, 150,140-67, (1944).
- [4] Alexander, J.M.. "On the Theory of Rolling"; *Proc. R. Soc. London*, A. 326, p.535-63,(1972)
- [5] Denti Filho, J.. *Um método de Controle Dinâmico de Laminadores reversíveis*, UFMG, (1994)
- [6] Hoshino I.,Maekawa Y.,Fujimoto T., Kimura H.e Kimura H. "Observer-based multivariable control of the aluminium cold tandem mill". *Automatica*, **24** ,pp 741-758 (1988).
- [7] Puskorius e Feldkamp, (1994), "Neurocontrol of nonlinear dynamical systems with Kalmanfilter trained recurrente networks", *IEEE Transactions on Neural Networks*,vol.5 pp.279-297.
- [8] Puskorius et. al., (1996), "Dynamic Neural network methods applied to on-vehicle idle speed control",proceedings of the IEEE,vol 84,pp.1407-1420.
- [9] Narendra e Annaswany, (1989), *Stable Adaptive Systems*, Englewood Cliffs,NJ: Prentice Hall.
- [10] Ahrns I.,Bruske J., Sommer G., (1995),"On-line learning with dynamic cell structures", Proc. Int. Conf. Artificial Neural Networks, vol.2 pp.141-146.
- [11] Firske B., (1995) "Growing cell strutures: a self-organizing network for unsupervised and supervised learning", *Neural Networks*, voll. 7 pp. 1441-1460.
- [12] M. Polycarpou, (1998), "On-Line Approximators for nonliear System Identification: Aunified Approach" *Control and Dynamic System Series, Volume 7, Neural Network Systems Techniques anda Applications* (ac. Press, Jan 1998)