

SISTEMA DE SUPERVISÃO PARA DETERMINAR A MELHOR AÇÃO DE CONTROLE DE ESPESSURA NA LAMINAÇÃO A FRIO, VIA FATORES DE SENSIBILIDADE

Luis E. Zárate

Departamento de Ciência da Computação, Pontifícia Universidade Católica de Minas Gerais, Av. Dom José Gaspar 500, Coração Eucarístico, CEP: 30535-610, Belo Horizonte-MG,Brazil
E-mail: zarate@brhs.com.br

RESUMO: A equação que governa o processo de laminação é uma equação não-linear de diversos parâmetros (espessura de entrada, tensões a frente e a ré, tensão média de escoamento, atrito, entre outros). Qualquer alteração num ou em todos os parâmetros causará alterações sobre a carga de laminação, e conseqüentemente, sobre a espessura de saída. Este artigo apresenta um Sistema Supervisor para um laminador de uma única cadeira, o qual insere um método para determinar o ajuste apropriado para controle da espessura de saída. O sistema determina a ação e o valor do ajuste apropriado para controle da espessura considerando três possíveis parâmetros de controle (gap, tensão a frente ou tensão a ré), no qual as equações de sensibilidade do processo, obtidos pela diferenciação de uma rede neural são utilizadas. O método considera como melhor ação de controle aquela que demanda o menor ajuste. Aplicação e resultados são apontados ao final do artigo

Keywords: Sistemas de Supervisão, Processos de Laminação, Redes Neurais

ABSTRACT: The rolling process governing equation is a non-linear function on several parameters (entry thickness, front and back tensions, average yield stress and friction coefficient among others). Any alteration in one of them will cause alterations on the rolling load and, consequently, on the outgoing thickness. A Supervisor System for single stand rolling mills is presented. This system uses a method for the determination of the appropriate adjustment for thickness control considering three possible control parameters (roll gap, front or back tensions), in which the sensitivity equation of the process, obtained by differentiating a neural network, is used. The method considers as the best control action the parameters that demand the smallest adjustment. An application and results are presented.

Keywords: Supervisor System, Rolling Process, Neural Networks

1. INTRODUÇÃO

A equação que governa uma única cadeira de laminação é função não-linear sobre diversos parâmetros, Equação (1). Qualquer alteração num ou em todos os parâmetros do processo: espessura de entrada (h_e), tensão a frente (t_f), tensão a ré (t_r), tensão de escoamento média (\bar{y}) ou no coeficiente de atrito (m) causará mudanças na carga de laminação (P) e conseqüentemente sobre a espessura de saída (h_s).

$$h_s = f(P, h_e, t_r, t_f, m, \bar{y}, E, R, W, M) \quad (1)$$

onde:

E = módulo de Young do material da tira sendo laminada

R = raio do cilindro de trabalho

W = largura da tira

M = módulo de rigidez do laminador

Quando as alterações no processo de laminação ocorrem, três parâmetros de controle são normalmente utilizados para restaurar a espessura de saída em seu valor nominal

garantindo a condição $\Delta h_s = 0$: a abertura do gap e as tensões a frente e a ré. O melhor parâmetro de controle deverá ser aquele parâmetro que restaura a espessura de saída para seu valor nominal com o menor ajuste possível.

Neste trabalho é proposto a estrutura de um Sistema Supervisor para laminadores a frio de uma única cadeira. O Sistema monitora os parâmetros do processo, calcula as possíveis ações de controle e implementa um algoritmo para determinar o melhor parâmetro de controle. O método utilizado é baseado nas equações de sensibilidade do processo que são obtidas pela diferenciação de uma rede neural previamente treinada como mostrado em Zárate 1998 e Zárate et. al. 1998a .

O artigo é organizado em seis seções. Na segunda seção a estrutura do Sistema Supervisor é apresentada. Na terceira seção são discutidos: a representação do processo via redes neurais e o calculo das equações de sensibilidade. Na quarta seção é mostrado o método para determinar as ações de controle. Na seguinte seção, o kernel do algoritmo para obter o melhor parâmetro de controle é apresentado. Finalmente, uma aplicação e as conclusões do trabalho são apresentadas na última seção.

2. ESTRUTURA DO SISTEMA SUPERVISOR

A Figura 1, mostra a estrutura do Sistema Supervisor proposto para uma cadeira de laminação. Os parâmetros do processo medidos x_1, x_2, \dots, x_N alimentam uma rede neural artificial (RNA) previamente treinada da qual são calculadas as saídas y_1, y_2, \dots, y_M . Os fatores de sensibilidade $S_1^i, S_2^i, \dots, S_N^i$ com $i=1..M$ são calculados a partir dos parâmetros nominais do processo $x_1^*, x_2^*, \dots, x_N^*$.

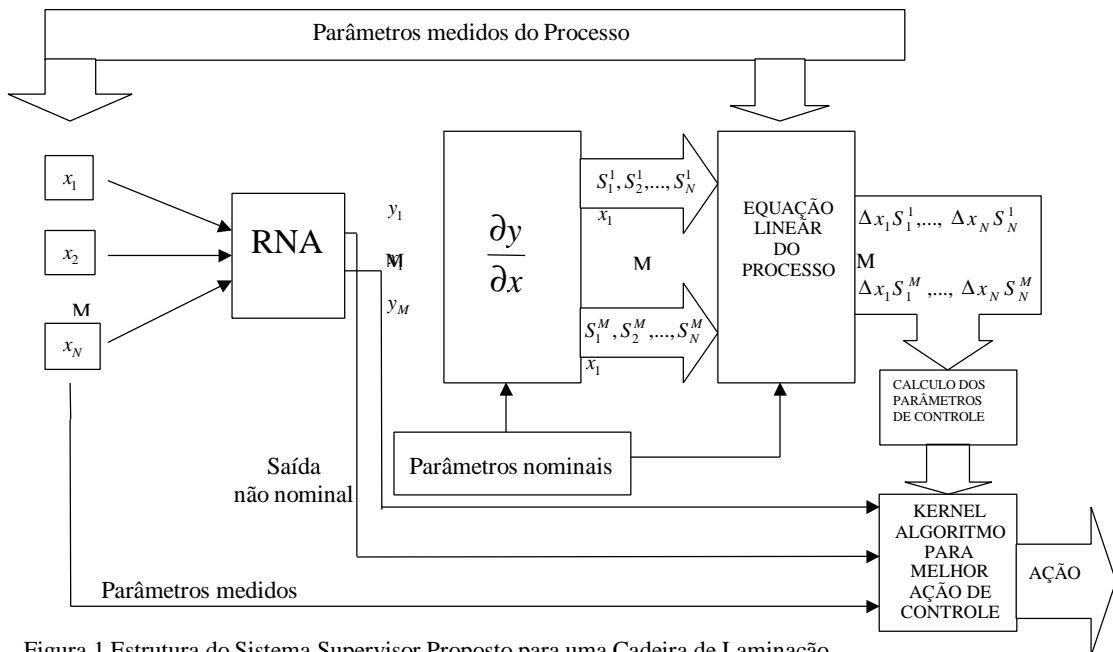


Figura 1 Estrutura do Sistema Supervisor Proposto para uma Cadeira de Laminação

Com os fatores de sensibilidade e com os parâmetros nominais e medidos são construídas as equações lineares que representam o processo $\Delta x_1 S_1^i, \Delta x_2 S_2^i, \dots, \Delta x_N S_N^i$.

A partir destas equações é possível calcular os valores dos parâmetros de controle g, t_r, t_f . Estes parâmetros são submetidos ao algoritmo proposto que determina a melhor ação de controle sobre o critério do menor ajuste. Nas próximas seções serão descritos cada etapa do sistema proposto.

3. REPRESENTAÇÃO DO PROCESSO VIA REDES NEURAIS E OBTENÇÃO DOS FATORES DE SENSIBILIDADE

Atualmente as redes neurais artificiais têm recebido grande atenção na indústria metalúrgica (Andersen, et. al. (1992), Zárate et. al. (1998 a, b) e Zárate (1998). Nesta seção a representação do processo (Equação 2) via RNA e o cálculo das equações de sensibilidade são apresentados.

Para a representação do processo via RNA, foi considerada uma rede multicamadas com seis entradas (N=6), duas saídas (M=2) e uma camada escondida com treze neurônios (L=13, considerando 2N+1). Como função ativadora foi selecionado a função sigmóide.

$$(h_e, g, \mathbf{m}, t_r, t_f, \bar{y}) \xrightarrow{\text{Neural Network}} (h_s, P) \quad (2)$$

Os conjuntos de dados foram submetidos a um processo de normalização antes de serem utilizados no processo de treinamento da RNA. A seguir o processo adotado é mostrado:

- Para acelerar a convergência da Rede no processo de treinamento o intervalo de valores normalizados foi reduzido de [0, 1] para [0,2; 0,8].
- Os dados foram normalizados e desnormalizados através das seguintes expressões:

$$f^a(Lo) = Ln = (Lo - Lmín) / (Lmax - Lmin) \quad (3)$$

$$f^b(Ln) = Lo = Ln * Lmax + (1 - Ln) * Lmín \quad (4)$$

onde Ln é o valor normalizado, Lo o valor a normalizar, $Lmin$ e $Lmax$ são os valores mínimos e máximos de cada parâmetro do processo envolvido no treinamento da rede respectivamente.

- $Lmin$ e $Lmax$ são calculados da seguinte forma:

$$Lmín = (4 \times \text{LimiteInf.} - \text{LimiteSup}) / 3 \quad (5)$$

$$Lmáx = (\text{LimiteInf.} - 0.8 \times Lmín) / 0.2 \quad (6)$$

As Equações (5) e (6) são obtidas considerando na Equation (3) $Ln = 0.2$ com $Lo = \text{LimiteInf}$ e $Ln = 0.8$ com $Lo = \text{LimiteSup}$ respectivamente. Onde LimiteInf e LimiteSup são os valores mínimos e máximos dos parâmetros originais.

O método para obter os fatores de sensibilidade é proposto por Zárate (1998). As expressões para cálculo dos fatores de sensibilidade são genéricas para N entradas, M saídas e L neurônios na camada escondida. A expressão de cálculo dos fatores de sensibilidade, Equação 7, depende dos pesos obtidos do treinamento.

$$\frac{\partial Z_k}{\partial U_i} = \begin{bmatrix} R_1 W_{11}^o & R_1 W_{12}^o & \Lambda & R_1 W_{1L}^o \\ R_2 W_{21}^o & R_2 W_{22}^o & \Lambda & R_2 W_{2L}^o \\ \text{M} & \text{M} & \text{M} & \text{M} \\ R_M W_{M1}^o & R_M W_{M2}^o & \Lambda & R_M W_{ML}^o \end{bmatrix} \begin{bmatrix} \frac{Q_1 W_{11}^h}{e_{\max_1} - e_{\min_1}} & \frac{Q_1 W_{12}^h}{e_{\max_2} - e_{\min_2}} & \Lambda & \frac{Q_1 W_{1N}^h}{e_{\max_N} - e_{\min_N}} \\ \frac{Q_2 W_{21}^h}{e_{\max_1} - e_{\min_1}} & \frac{Q_2 W_{22}^h}{e_{\max_2} - e_{\min_2}} & \Lambda & \frac{Q_2 W_{2N}^h}{e_{\max_N} - e_{\min_N}} \\ \text{M} & \text{M} & \Lambda & \text{M} \\ \frac{Q_L W_{L1}^h}{e_{\max_1} - e_{\min_1}} & \frac{Q_L W_{L2}^h}{e_{\max_2} - e_{\min_2}} & \Lambda & \frac{Q_L W_{LN}^h}{e_{\max_N} - e_{\min_N}} \end{bmatrix} \quad (7)$$

com:

$$Q_k = \frac{\exp\left(-\left(\sum_{i=0}^N W_{ki}^h X_i\right)\right)}{\left(1 + \exp\left(-\left(\sum_{i=0}^N W_{ki}^h X_i\right)\right)\right)^2} \quad k = 1, \dots, L$$

$$R_k = (s_{\max_k} - s_{\min_k}) \frac{\exp^{-V_k}}{\left(1 + \exp^{-V_k}\right)^2} \quad k = 1, \dots, M$$

$$\frac{\partial V_k}{\partial U_i} = \frac{\partial}{\partial U_i} \left(W_{k0}^o + \sum_{j=1}^L W_{kj}^o f_j^h \left(\sum_{i=0}^N W_{ji}^h f_i^a(U_i) \right) \right)$$

Onde :

$U_i, i = 0, \dots, N$ são as entradas da rede (não-normalizadas) e $U_0 = 1$ é uma entrada de polarização

$f_i^a(\cdot) i = 0, \dots, N$ são as funções de entrada de normalização, Equação 3, com $f_0^a(\cdot) = 1$
 $X_i, i = 0, \dots, N$ são as entradas normalizadas $X_0 = U_0$

$W_{ij}^h i = 1, \dots, L$ and $j = 0, \dots, N$ é o peso correspondente ao neurônio i e entrada j

$f_j^h(\text{net}_j^h) j = 0, \dots, L$ where $f_0^h(\text{net}_0^h) = 1$ é a função sigmoide da camada escondida.

$W_{ij}^o i = 1, \dots, M$ and $j = 0, \dots, L$ é o peso do neurônio i e saída j para a camada de saída

$f_j^o(\text{net}_j^h) j = 1, \dots, M$ é o valor da função sigmoide para a camada de saída

$f_i^b(\cdot) i = 1, \dots, M$ são as funções desnormalizadoras da saída, Equação 4

$Z_i, i = 1, \dots, M$ valores da saída da rede

$e_{\max_k}, e_{\min_k} k = 1, \dots, N$ maiores e menores valores das entradas

$s_{\max_k}, s_{\min_k} k = 1, \dots, M$ maiores e menores valores das saídas

4. DETERMINAÇÃO DOS PARÂMETROS DE CONTROLE

Os passos para determinar os ajustes nos parâmetros de controle são:

I. As entradas e saídas nominais são definidas pelos vetores

$$\bar{X}^* = (h_e^*, g^*, \mathbf{m}^*, t_r^*, t_f^*, \bar{y}) \text{ e } \bar{Y}^* = (h_s^*, P^*) \text{ respectivamente.}$$

II. Através da Equação (7) é possível calcular a sensibilidade para um ponto nominal selecionado.

III. Após cálculo dos fatores de sensibilidade é possível obter as equações lineares do processo, Equação (8) em torno do ponto nominal de operação:

$$\Delta h_s = \Delta h_e \frac{\partial h_s}{\partial h_e} + \Delta g \frac{\partial h_s}{\partial g} + \Delta \mathbf{m} \frac{\partial h_s}{\partial \mathbf{m}} + \Delta t_r \frac{\partial h_s}{\partial t_r} + \Delta t_f \frac{\partial h_s}{\partial t_f} + \Delta y \frac{\partial h_s}{\partial y} \quad (8)$$

sendo $\Delta X = X^* - X$

Se houver variação num ou em todos os parâmetros operacionais $h_e, g, \mathbf{m}, t_r, t_f, \bar{y}$, uma alteração ocorrerá no valor de h_s . Objetivando o controle da espessura final, existe um fator K tal que $\Delta h_s = 0$, ver Equação (9):

$$0 = \Delta h_e \frac{\partial h_s}{\partial h_e} + \Delta g \frac{\partial h_s}{\partial g} + \Delta \mathbf{m} \frac{\partial h_s}{\partial \mathbf{m}} + \Delta t_r \frac{\partial h_s}{\partial t_r} + \Delta t_f \frac{\partial h_s}{\partial t_f} + \Delta y \frac{\partial h_s}{\partial y} + K \quad (9)$$

$$\text{Igualando as Equações (8) e (9) tem-se: } K = -\Delta h_s \quad (10)$$

O valor de K depende do parâmetro de controle selecionado: gap, tensão a frente ou tensão a ré os quais podem ser definidos como:

$$K = \Delta g \frac{\partial h_s}{\partial g} \text{ or } K = \Delta t_r \frac{\partial h_s}{\partial t_r} \text{ or } K = \Delta t_f \frac{\partial h_s}{\partial t_f} \quad (11)$$

Se a ação de controle for através da abertura do gap, a equação para a ação de controle fica dada por:

$$K = \Delta g \frac{\partial h_s}{\partial g} = -\Delta h_s \quad \Delta g = -\frac{\Delta h_s}{\frac{\partial h_s}{\partial g}} \quad g = g^* + \frac{\Delta h_s}{\frac{\partial h_s}{\partial g}} \quad (12)$$

Da mesma forma, em termos da tensão a ré e a frente têm-se:

$$t_r = t_r^* + \frac{\Delta h_s}{\frac{\partial h_s}{\partial t_r}} \quad t_f = t_f^* + \frac{\Delta h_s}{\frac{\partial h_s}{\partial t_f}} \quad (13 \text{ e } 14)$$

5. ALGORITMO PARA OBTER A MELHOR AÇÃO DE CONTROLE

Na última seção, três parâmetros de controle foram calculados para restaurar variações na espessura de saída. Um critério para selecionar o melhor parâmetro de controle pode ser aquele parâmetro que requer o menor ajuste.

O método proposto considera que para valores menores que a sensibilidade do instrumento de medida, deverá ser saturado nesse valor (Por exemplo, $\pm 0,001$). Para valores da tensão a frente e a ré o limiar de saturação deve ser de 85% do valor da tensão de escoamento para o estado plano de deformação, na entrada (S_i) e na saída (S_o) da interface cilindro material. O kernel do algoritmo é mostrado a seguir:

Begin

calculate : $g = g^* + \frac{\Delta h_s}{\partial h_s / \partial g}$ value of the control action by means of the roll gap

$t_r = t_r^* + \frac{\Delta h_s}{\partial h_s / \partial t_r}$ value of the control action by means of the back tension

$t_f = t_f^* + \frac{\Delta h_s}{\partial h_s / \partial t_f}$ value of the control action by means of the front tension

calculate : $\text{Var}_g = |g^* - g| * 100 / g^*$ adjustment of the roll gap

$\text{Var}_{t_r} = |t_r^* - t_r| * 100 / t_r^*$ adjustment of the back tension

$\text{Var}_{t_f} = |t_f^* - t_f| * 100 / t_f^*$ adjustment of the front tension

If $\text{Var}_g < \text{Var}_{t_r}$ and $\text{Var}_g < \text{Var}_{t_f}$

then If $|g^* - g| < 0,001$ then $g = 0,001$

If $P \uparrow$ then $g \downarrow$ (control action)

If $P \downarrow$ then $g \uparrow$ (control action)

else

If $\text{Var}_{t_r} \leq \text{Var}_{t_f}$

then If $t_r > 0,85 * S_i$ then $t_r = 0,85 * S_i$

If $P \uparrow$ then $t_r \uparrow$ (control action)

If $P \downarrow$ then $t_r \downarrow$ (control action)

else If $\text{Var}_{t_f} < \text{Var}_{t_r}$

then If $t_f > 0,85 * S_o$ then $t_f = 0,85 * S_o$

If $P \uparrow$ then $t_f \uparrow$ (control action)

If $P \downarrow$ then $t_f \downarrow$ (control action)

End.

6. APLICAÇÃO, RESULTADOS E CONCLUSÕES

Como exemplo uma aplicação numérica para o processo de laminação será apresentada. O ponto de operação nominal foi escolhido como: $h_e=5,0$ mm; $h_s= 3,6$ mm; $g=1,846$ mm.; $m=0,12$; $t_f=9,098$ kgf/mm²; $t_r=0,441$ kgf/mm²; $\bar{y}=46,918$ kgf/mm²; $W = 500$ mm; $E=20.400$ kgf/mm²; $R= 292,1$ mm; $M=500.000$ kgf/mm² and $P= 875,31$ tf. With $S_i = 25,550$ kgf/mm² e $S_o = 54,545$ kgf/mm². Para obter o conjunto de dados para treinamento da RN, a variação dos parâmetros foram escolhidos como: $h_e=\pm 8\%$; $h_s, = \pm 3\%$; $m=\pm 20\%$ $t_f = \pm 30\%$; $t_r = \pm 30\%$ e $\bar{y} = \pm 10\%$. Três valores distintos foram escolhidos para cada parâmetro resultando em 729 conjuntos de treinamento. A carga de laminação foi obtida através do modelo de Alexander (Alexander, 1972) e o gap pela equação elástica do laminador (Equação 15).

$$h_o = g + \frac{P}{M} \quad (15)$$

Os pesos finais para as camadas escondida e de saída, com seus respectivos pesos de polarização são:

$$W^h = \begin{bmatrix} 6.2010 & 9.4161 & -1.7278 & -0.2642 & 1.8475 & 1.3078 \\ -1.5239 & -9.2425 & -2.4238 & 0.0734 & 0.7813 & -6.0229 \\ -11.4365 & -1.7129 & 1.2562 & -0.2171 & -0.6941 & 3.3125 \\ -0.2767 & -8.3214 & -5.5920 & -0.2737 & -3.3595 & -0.8293 \\ 3.3504 & 5.2707 & 3.4006 & 0.0343 & -0.5938 & 4.7363 \\ 8.9832 & 3.9726 & 0.7990 & 9.7730 & 0.9096 & 5.5016 \\ -6.1621 & 3.4810 & 7.4542 & 0.5558 & -7.0447 & -0.9006 \\ -4.8199 & -3.2388 & 6.5208 & -3.4559 & -0.6086 & 8.9722 \\ 0.8914 & -8.2071 & -7.6049 & -0.1518 & -2.2323 & -1.5593 \\ -1.2378 & -10.6099 & -0.0338 & 0.0399 & 0.4850 & -2.1458 \\ 8.3913 & 2.3521 & 5.9967 & -8.1868 & -4.0553 & 1.8826 \\ -1.4947 & -11.9576 & -1.6808 & 0.0733 & 0.7387 & -4.2602 \\ 2.9411 & 4.8319 & -11.5151 & -1.5484 & -4.0985 & -4.2330 \end{bmatrix}$$

$$W_{bias}^h = \begin{bmatrix} -11.4784 \\ 8.9265 \\ 2.5654 \\ 10.9804 \\ -10.4911 \\ -15.1094 \\ 5.3887 \\ -4.5520 \\ 7.1306 \\ 8.8376 \\ -0.4583 \\ 8.7774 \\ 2.5081 \end{bmatrix}$$

$$W^o = \begin{bmatrix} 0.5503 & 0.4083 \\ -1.7551 & -2.1593 \\ -0.9245 & -0.1960 \\ -0.2976 & 0.2163 \\ 4.2976 & 0.9087 \\ 0.0021 & 0.0045 \\ 0.1479 & 0.1406 \\ 0.1378 & 0.0480 \\ -1.1542 & -0.0074 \\ -6.4508 & 1.0470 \\ -0.0276 & -0.0106 \\ -3.9372 & 2.4463 \\ 0.1814 & 0.0746 \end{bmatrix}$$

$$W_{bias}^o = \begin{bmatrix} 6.4599 \\ -1.4106 \end{bmatrix}$$

A sequência de eventos para determinar os ajustes de controle são descritos a seguir:

- 1) Definir a entrada e a saída nominal: $[h_e^*, g^*, \mathbf{m}^*, t_r^*, t_f^*, \bar{y}] = [5,00; 1,846; 0,12; 0,441; 9,098; 46,918]$ e $[h_s^*, P^*] = [3,6; 875,31]$;
- 3) Calcular os coeficientes de sensibilidade, Equação 7, para o ponto nominal selecionado: $[\frac{\partial h_s}{\partial h_e}, \frac{\partial h_s}{\partial g}, \frac{\partial h_s}{\partial \mathbf{m}}, \frac{\partial h_s}{\partial t_r}, \frac{\partial h_s}{\partial t_f}, \frac{\partial h_s}{\partial y}] = [0,3566; 0,6436; 4,7345; -0,0163; -0,011; 0,0327]$;
- 4) Na presença de variação nos parâmetros, calcular as entradas atuais como: $[h_e, g, \mathbf{m}, t_r, t_f, \bar{y}] = [4,9; 1,846; 0,118; 0,432; 9,098; 46,918]$;
- 5) Utilizando a rede neural previamente treinada, determinar as saídas atuais: $[h_s, P] = [3,552; 855,527]$;
- 6) Determinar os parâmetros de controle utilizando as Equações 12, 13 e 14: $[\bar{g}, \bar{t}_r, \bar{t}_f]$. Isto corresponde a correções de: +3.8%, -639.9% e -54% respectivamente;
- 7) Através do algoritmo a menor porcentagem de correção indica a melhor ação de controle. Daí a correção dos desvios na espessura de saída deve ser feita através do gap. Note que o valor calculado para \bar{t}_r é negativo e deveria ser saturado para $\bar{t}_r = 0$. De forma a verificar os ajustes calculados, foram simuladas as três possíveis correções através de um processo iterativo utilizando o modelo de Alexander e a Equação (15). Para ação no gap ($\bar{g} = 1,920$) o valor da espessura de saída foi 3,585 mm com um erro de 0,42%. Para ação na tensão a ré ($\bar{t}_b = 0$) o valor da espessura de saída foi 3,555 mm com um erro de 1,25% e para ação na tensão a frente ($\bar{t}_f = 4,734$) o valor da espessura de saída foi 3,584 mm com um erro de 0,44%.

REFERÊNCIAS

- Alexander, J. M., (1972). On the theory of rolling. *Proc. R. Soc. Lond. A.* 326, pp. 535-563.
- Andersen, K., Cook, G.E. and Barnett, R.J., (1992). Gas Tungsten Arc Welding Process Control Using Artificial Neural Networks. *Inter. Trend in Welding, Science and Technology, ASM*, pp. 877-1030.
- Zárate, L.E., (1998). Um Método de Análise para Laminadores Tandem a Frio. *Teses de Doctorado*, Federal University of Minas Gerais, Belo Horizonte, MG, Brazil.
- Zárate, L.E., and H. Helman, J.M. Gálvez (1998 a). Um Modelo para Processos Baseados em Fatores de Sensibilidade, Utilizando Redes Neurais. *XII Congresso Brasileiro de Automática*, Vol. I, pp.23-28, September 14-18, Uberlândia, MG, Brazil.
- Zárate, L.E., J.M. Gálvez and H. Helman, (1998 b). A Neural Network Based Controller Steel Rolling Mills by Using Sensitivity Functions. *XII Congresso Brasileiro de Automática*, Vol. I, pp.29-34, September 14-18, Uberlândia, MG, Brazil.