

Análise Qualitativa de Processos Através dos Fatores de Sensibilidade Via Redes Neurais e Sua Aplicação na Laminação em Tandem

Luis Enrique Zárate, Fabrício Roulin Bittencout
Deptº de Ciência da Computação,
Pontifícia Universidade Católica de Minas Gerais,
PUC-MG, Av. Dom José Gaspar 500, Coração Eucarístico,
CEP. 30535-610 - Belo Horizonte - MG - Brasil,
E-mail: zarate@brhs.com.br

Abstract

In this work a new method for model linearization and qualitative analysis are presented. The analysis is based on the differentiation of neural network outputs to obtain sensitivity factors. In a final analysis, this corresponds to the decomposition of the actual model into the linear terms of the multivariable Taylor's series. The proposed method leads to analytic equations which well represent the process in some neighborhood of an operation point. As an example, this paper presents the application of the method to analysis the qualitative behavior of the tandem mill. Final comments and conclusions are also presented.

1. Introdução

O entendimento de um processo físico, químico, econômico, etc. pode ser obtido através do estudo das variáveis envolvidas no processo. A relação das variáveis pode ser expressa por meio de equações analíticas que compõem o modelo e que permitem analisar as relações causa-efeito entre as variáveis. A modelagem física é sempre uma atividade que demanda um grande tempo de análise e entendimento do processo. A dificuldade de obter um modelo é diretamente proporcional à complexidade do fenômeno em estudo. A modelagem é um trabalho árduo e pode levar, dependendo do processo, anos para sua conclusão. Por outro lado durante o desenvolvimento de um modelo matemático existem complexidades que não possuem fácil solução analítica. Isto pode levar a soluções numéricas que demandem grande esforço computacional [1].

Na maioria das vezes modelos físicos de processos apresentam características não lineares que dificultam a aplicação em sistemas de controle e de supervisão "on-line". A primeira porque a aplicação da teoria de controle clássico exige modelos lineares, e a segunda, porque modelos complexos que proporcionam valores de simulação para supervisionar um processo podem

requerer de solução numérica com grande esforço computacional.

Frequentemente não é possível obter uma relação direta entre um *parâmetro A* (causa) e uma *função B* (efeito). No entanto pode-se as vezes correlacionar experimentalmente o *parâmetro A* com valores das derivadas da *função B* (efeito).

Considere uma função não linear dado pela eq. (1). Para obter um modelo matemático linear supõe-se que as variáveis variam muito pouco dentro de uma condição de operação.

$$Z = f(U_1, U_2, U_3, \dots, U_N) \quad (1)$$

Se a condição nominal de operação corresponde a $Z^*, U_i^*, i=1, \dots, N$, então a eq. (1) pode ser expressa na série de Taylor em torno do ponto de operação, na forma seguinte:

$$\begin{aligned} \Delta Z = & \left[\frac{\partial Z}{\partial U_1} \Delta U_1 + \frac{\partial Z}{\partial U_2} \Delta U_2 + \frac{\partial Z}{\partial U_3} \Delta U_3 + \dots + \frac{\partial Z}{\partial U_N} \Delta U_N \right] \\ & + \frac{1}{2!} \left[\frac{\partial^2 Z}{\partial U_1^2} \Delta U_1^2 + \frac{\partial^2 Z}{\partial U_2^2} \Delta U_2^2 + \frac{\partial^2 Z}{\partial U_3^2} \Delta U_3^2 + \dots + \frac{\partial^2 Z}{\partial U_N^2} \Delta U_N^2 \right] + \dots \end{aligned} \quad (2)$$

onde os termos derivativos são calculados para o ponto nominal de operação. Se as perturbações são pequenas podem-se desprezar os termos de ordem superior, obtendo-se a equação linear, eq. (3).

$$\begin{aligned} \Delta Z = & \frac{\partial Z}{\partial U_1} \Delta U_1 + \frac{\partial Z}{\partial U_2} \Delta U_2 + \\ & \frac{\partial Z}{\partial U_3} \Delta U_3 + \dots + \frac{\partial Z}{\partial U_N} \Delta U_N \end{aligned} \quad (3)$$

onde:

$$\Delta Z = Z^* - Z \text{ e } \Delta U = U^* - U \quad (4)$$

Redes Neurais Artificiais (RNA) tem sido o foco de uma grande atenção durante os últimos anos devido a sua capacidade em resolver problemas não-lineares por aprendizado. Neste trabalho é apresentado um método de linearização [2] e [7] para obter as equações de sensibilidade de processos, através da diferenciação da RNA. Esta nova representação, permite obter as equações do processo para diferentes pontos de operação sem a necessidade de realizar novos cálculos numéricos complexos, se for utilizado um modelo físico do processo. Isto abre a possibilidade de utilização do método em sistemas de controle e supervisão "on-line".

Neste trabalho será apresentada uma aplicação do método para analisar qualitativamente os pontos de operação de um laminador tandem.

Este trabalho é dividido como se segue: Na seção 2, é conceituada a estrutura básica da Rede Neural Artificial utilizada neste trabalho. Na seção 3, são apresentadas as bases para obtenção dos fatores de sensibilidade da rede neural. Na seção 4 é apresentada a aplicação para o processo de laminação tandem e finalmente resultados e as conclusões do trabalho são apresentados.

2. Estrutura de Rede neural considerada

Em [3] é apresentada a fundamentação de redes neurais artificiais discutindo sua aplicação para modelagem e controle de sistemas não-lineares. Em [8], [9], [10] e [11] aplicação de redes neurais em processos de laminação para representação e controle são apresentados.

A RNA considerada neste trabalho é uma rede multicamadas de uma camada escondida. O treinamento da mesma é baseado na técnica "back-propagation". Como função ativadora do neurônio foi escolhido a função sigmóide eq. (5).

$$f = \frac{1}{1 + \exp^{-\sum \text{Entrada} \times \text{Pesos}}} \quad (5)$$

Geralmente, o maior esforço para o treinamento de uma rede neural encontra-se na coleta de dados e no pré-processamento que a elas deve ser aplicado. O pré-processamento consiste na normalização dos dados da entrada e da saída. Para a rede em questão o único requisito é que os valores das entradas e das saídas se encontrem no intervalo de 0 a 1.

Os seguintes procedimentos foram adotados para normalizar os dados de entrada associados às suas respectivas saídas, antes de usá-los na Rede Neural Artificial descrito neste trabalho:

a) Como os valores de 0 e 1 são valores infinitos para a função sigmóide, é recomendável diminuir este intervalo para valores de 0,2 e 0,8 respectivamente, com o objetivo de facilitar a convergência durante o treinamento da rede.

b) Os dados foram normalizados e desnormalizados através das seguintes expressões:

$$f^a(Lo) = Ln = (Lo - Lmín) / (Lmax - Lmin) \quad (6a)$$

$$f^b(Ln) = Lo = Ln * Lmax + (1 - Ln) * Lmín \quad (6b)$$

onde : Ln é o valor normalizado; Lo o valor a normalizar; $Lmín$ e $Lmáx$ são valores mínimos e máximos dentre os valores das variáveis.

c) Pelo exposto no item a) faz-se necessário a mudança de escala dos dados, para valores que proporcionem quando normalizados, valores limites entre 0,2 e 0,8. As fórmulas para calcular $Lmín$ e $Lmáx$ são as seguintes:

$$Lmín = (4 \times \text{LimiteInf.} - \text{LimiteSup}) / 3 \quad (7a)$$

$$Lmáx = (\text{LimiteInf.} - 0,8 \times Lmín) / 0,2 \quad (7b)$$

As equações (7a) e (7b) são obtidas da substituição na equação (6a) de $Ln = 0,2$ e $Lo = \text{LimiteInf}$ e de $Ln = 0,8$ e $Lo = \text{LimiteSup}$. Onde LimiteInf e LimiteSup são os valores mínimos e máximos respectivamente dos conjuntos de dados originais.

3. Fatores de sensibilidade

A RNA considerada neste trabalho é uma rede multicamadas com N: entradas, M: saídas e L: neurônios na camada escondida.

O objetivo principal é obter os fatores de sensibilidade eq (8), do processo em questão através da diferenciação da rede neural previamente treinada.

$$\frac{\partial Z}{\partial U} = \begin{bmatrix} \frac{\partial Z_1}{\partial U_1} & \frac{\partial Z_1}{\partial U_2} & \dots & \frac{\partial Z_1}{\partial U_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial Z_M}{\partial U_1} & \frac{\partial Z_M}{\partial U_2} & \dots & \frac{\partial Z_M}{\partial U_N} \end{bmatrix} \quad (8)$$

onde :

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

$f_i^a(.)$ $i = 0, \dots, N$ são as funções normalizadoras das entradas, eq. (6) e $f_0^a(.) = 1$

X_i , $i = 0, \dots, N$ são as entradas normalizadas e $X_0 = U_0$

W_{ij}^h $i = 1, \dots, L$ e $j = 0, \dots, N$ contém o peso do neurônio i e entrada j

$net_j^h = \sum_{i=0}^N W_{ji}^h X_i$ $j = 1, \dots, L$ produto de pesos

pelas entradas

$f_j^h(net_j^h)$ $j = 0, \dots, L$ onde $f_0^h(net_0^h) = 1$ é a

função sigmóide para a camada escondida

I_j , $j = 0, \dots, L$ são as respostas da função sigmoide

$I_0 = 1$

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

$net_j^o = \sum_{i=0}^L W_{ji}^o I_i$ $j = 1, \dots, M$ produto de pesos

pelas entradas, para a camada de saída

$f_j^o(net_j^o)$ $j = 1, \dots, M$ é a função sigmoide para a camada de saída

Y_j , $j = 1, \dots, M$ são as saídas normalizadas da rede,

obtidas da função sigmoide

$f_i^b(\cdot)$ $i = 1, \dots, M$ são as funções desnormalizadoras das saídas, ver eq. (6)

Z_i , $i = 0, \dots, M$ são as saídas da rede

$e \max_k, e \min_k$ $k = 1, \dots, N$ são as valores máximos e mínimos das entradas

$s \max_k, s \min_k$ $k = 1, \dots, M$ são os valores máximos e mínimos das saídas

A continuação será apresentado o procedimento para obter as expressões de sensibilidade da rede neural:

$$\begin{aligned} Z_1 &= f_1^b(Y_1) \\ Z_2 &= f_2^b(Y_2) \\ &\vdots \\ Z_M &= f_M^b(Y_M) \end{aligned} \quad (9)$$

Trabalhando adequadamente as variáveis, obtêm-se a eq. (10) que relaciona as entradas com as saídas não normalizadas da RNA:

$$\begin{aligned} Z_1 &= f_1^b(f_1^o(\sum_{j=0}^L W_{1j}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \\ Z_2 &= f_2^b(f_2^o(\sum_{j=0}^L W_{2j}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \\ &\vdots \\ Z_M &= f_M^b(f_M^o(\sum_{j=0}^L W_{Mj}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \end{aligned} \quad (10)$$

Substituindo as expressões para as funções $f^a(\cdot), f^b(\cdot), f^o(\cdot), f^h(\cdot)$ obtêm-se a eq. (11)

$$\begin{aligned} Z_1 &= \frac{1}{1 + \exp^{-V_1}} [\text{smax}_1 - \text{smin}_1] + \text{smin}_1 \\ Z_2 &= \frac{1}{1 + \exp^{-V_2}} [\text{smax}_2 - \text{smin}_2] + \text{smin}_2 \\ &\vdots \\ Z_M &= \frac{1}{1 + \exp^{-V_M}} [\text{smax}_M - \text{smin}_M] + \text{smin}_M \end{aligned} \quad (11)$$

onde :

$$V_k = \sum_{j=0}^L W_{kj}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)) \text{ para } k = 1, \dots, M \quad (12)$$

Generalizando a eq. (11), tem-se:

$$Z_k = \frac{1}{1 + \exp^{-V_k}} [\text{smax}_k - \text{smin}_k] + \text{smin}_k \quad (13)$$

para $k = 1, \dots, M$

Os fatores de sensibilidade, correspondente a eq. (8) pode ser calculado como:

$$\frac{\partial Z_k}{\partial U_i} = [\text{smax}_k - \text{smin}_k] \frac{\exp^{-V_k}}{(1 + \exp^{-V_k})^2} \frac{\partial V_k}{\partial U_i} \quad (14)$$

Trabalhando com o termo derivativo (da eq. 14) e considerando a equação (12) teremos:

$$\frac{\partial V_k}{\partial U_i} = \frac{\partial}{\partial U_i} (W_{k0}^o + \sum_{j=1}^L W_{kj}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i))) \quad (15)$$

Diferenciando a eq. (15), introduzindo o resultado na eq. (14), obtêm-se a eq. (16) que permite calcular os fatores de sensibilidade a partir da RNA previamente treinada:

$$\frac{\partial Z_k}{\partial U_i} = \begin{bmatrix} R_1 W_{11}^o & R_1 W_{12}^o & \dots & R_1 W_{1L}^o \\ R_2 W_{21}^o & R_2 W_{22}^o & \dots & R_2 W_{2L}^o \\ \vdots & \vdots & \vdots & \vdots \\ R_M W_{M1}^o & R_M W_{M2}^o & \dots & R_M W_{ML}^o \end{bmatrix} \begin{bmatrix} \frac{Q_1 W_{11}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_1 W_{12}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_1 W_{1N}^h}{\text{emax}_N - \text{emin}_N} \\ \frac{Q_2 W_{21}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_2 W_{22}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_2 W_{2N}^h}{\text{emax}_N - \text{emin}_N} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{Q_L W_{L1}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_L W_{L2}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_L W_{LN}^h}{\text{emax}_N - \text{emin}_N} \end{bmatrix} \quad (16)$$

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

$$R_k = \left(\text{smax}_k - \text{smin}_k\right) \frac{\exp\left(-V_k\right)}{\left(1 + \exp\left(-V_k\right)\right)^2} \quad k = 1, \dots, M$$

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

4. Aplicação na laminação em tandem

Um laminador tandem é formado por "n" cadeiras (normalmente 5) unidas pela tira que passa através delas. A tira é fornecida por uma bobina e quando laminada alimenta uma outra. A espessura da tira é reduzida em passes sequenciais através de uma alta pressão sobre uma pequena área de contato de 6,0 a 25,4 mm de comprimento. Qualquer mudança na espessura de entrada, nas tensões à frente, a ré, na tensão de escoamento e/ou no atrito, causarão mudanças na carga e torque de laminação e correspondentemente, na espessura de saída [5]. Quando uma cadeira de laminação é perturbada por qualquer variação nos parâmetro, seu efeito será sentido tanto nas cadeiras anteriores e quanto posteriores [4].

Em [5] foram obtidas regras de comportamento qualitativas, deduzidas a partir das equações constitutivas do processo. Essas regras descrevem de forma genérica o estado estacionário do processo. Neste trabalho uma análise mais detalhada baseado na sensibilidade será apresentado. Esta análise permite conhecer a maior ou a menor influência de cada parâmetro sobre a carga de laminação para um determinado ponto de operação do processo. Essa informação pode ser de grande utilidade quando desejar-se controlar o processo. Assim uma rápida ação de controle frente a perturbações no processo, pode corresponder a um parâmetro que apresente maior sensibilidade no ponto de operação.

As eqs. (17) e (18) descrevem as equações constitutivas para a carga e o torque de laminação.

$$P = f(y, h_i, h_f, t_r, t_f, \mu, E, D) \quad (17)$$

$$T_q = f(y, h_i, h_f, t_r, t_f, \mu, E, D) \quad (18)$$

Para cada cadeira do laminador tandem, a representação neural do processo de laminação foi expressa através da relação eq. (19). Com seis entradas, duas saídas e 13 neurônios na camada escondida.

$$(h_i, h_f, \mu, t_r, t_f, \bar{y}) \xrightarrow{\text{Rede Neural}} (P, T_q) \quad (19)$$

onde: h_i é a espessura de entrada, h_f é a espessura de saída, μ é o coeficiente de atrito, t_f é a tensão à frente, t_r é a tensão a ré e \bar{y} é a tensão média de escoamento. Como saídas foram consideradas a carga (P) e o torque (T_q) de laminação.

4.1. Dados para treinamento

Para a obtenção dos conjuntos de treinamento foram escolhidos os seguintes pontos de operação para cada cadeira. Ver tabela 1.

Tabela 1: Pontos de operação para cada cadeira

h_i	h_f	μ	t_r	t_f	\bar{y}	Cadeira
5,0	3,6	0,12	0,441	9,098	46,91	1
3,6	2,7	0,10	9,098	9,39	60,65	2
2,7	2,16	0,10	9,393	9,765	67,77	3
2,16	1,84	0,08	9,765	10,23	72,18	4
1,84	1,70	0,08	10,23	2,790	74,67	5

As redes neurais foram treinadas utilizando uma variação média ao redor de cada ponto de operação de 15%.

Os dados do material e das cadeiras do laminador foram escolhidos como:

$E = 204000 \text{ kgf/mm}^2$ (módulo de Young do material)

$\nu = 0,330$ (coefc. De Poisson do material)

$W = 900,0 \text{ mm}$ (largura da tira)

$R = 292,1 \text{ mm}$ (raio dos cilindros de trabalho)

$M = 400000 \text{ kgf/mm}$ (módulo de rigidez da cadeira do laminador)

Os valores da carga e do torque utilizados para treinamento da rede foram obtidos através do modelo de Alexander (1972) [6] considerando as variações nas variáveis de entrada (ver Tabela 2).

Tabela 2: Variação da Carga e Torque de Laminação

Cadeira	1	2	3	4	5
P kgf/mm	1754,353	1822,52	1934,53	1625,86	1449,86
T_q kgfmm/mm	10343,5	11101,25	7875,00	4645,46	3854,58

4.2. Processo de treinamento da rede

Para o processo de treinamento das redes foram considerados valores iniciais aleatórios, para os pesos, na faixa de -1,0 a +1,0. Considerando os 729 conjuntos de treinamento, obtidos pela combinação das variáveis do processo de laminação, mostrados na Tabela 1 e

uma taxa de aprendizado igual a 0,008. A média da soma dos erros quadráticos das saídas, foi igual a 0,033 após uma média de 540.000 passos de treinamento.

Os pesos finais para as camadas escondida e saída com seus pesos de polarização da primeira cadeira são:

$$W_{LxN}^h = \begin{bmatrix} -2.3454 & 0.7340 & -1.6838 & -0.0022 & 0.6619 & -2.6015 \\ 3.9053 & 3.0809 & -5.1249 & -2.8544 & -5.3234 & -5.6773 \\ -8.4711 & 5.1592 & 6.1539 & -1.5900 & -4.3587 & 3.4279 \\ -11.759 & 0.2278 & -0.9995 & -0.3439 & 0.1404 & 6.6675 \\ -8.4249 & -9.2360 & -5.5525 & 1.1392 & 2.4098 & -5.1437 \\ -1.3987 & 1.6646 & 9.0437 & 0.0068 & 5.0952 & -7.2585 \\ 3.4417 & 0.4525 & 8.6002 & -6.6928 & 5.2036 & 1.8066 \\ -2.0856 & 0.6305 & -0.6184 & 0.0003 & 0.8595 & -1.8555 \\ -4.1919 & 0.5245 & -4.9311 & 7.3975 & 1.3536 & 6.6874 \\ 10.5998 & 3.1858 & -4.8274 & 1.8625 & -3.3113 & -2.8462 \\ 3.8174 & 3.3982 & -3.9207 & -1.5036 & -1.7811 & 0.6947 \\ 3.9009 & -2.6003 & 0.5489 & 2.1262 & -5.7297 & -5.7073 \\ 8.5120 & -6.7926 & -2.3504 & 2.8321 & 4.0079 & -3.0902 \end{bmatrix}$$

$$W_{LxM}^o = \begin{bmatrix} -3.1740 & -2.9035 \\ -0.0764 & 0.0828 \\ -0.0657 & -0.0805 \\ 0.1220 & 0.0392 \\ 0.0129 & 0.0412 \\ 0.0697 & -0.0389 \\ 0.0365 & -0.0332 \\ -2.4985 & -2.2298 \\ 0.0431 & -0.0432 \\ -0.0462 & 0.0340 \\ 0.0237 & 0.0011 \\ -0.1453 & 0.1522 \\ -0.0411 & 0.0515 \end{bmatrix} \quad W_{Mx1}^o = \begin{bmatrix} 5.2529 \\ 6.0337 \\ -3.8969 \\ 5.1587 \\ 5.4216 \\ -1.0686 \\ -7.2569 \\ 0.2394 \\ -3.2777 \\ -0.9662 \\ -5.8385 \\ 3.7317 \\ -3.0089 \end{bmatrix} \quad W_{Mx1}^h = \begin{bmatrix} 3.2143 \\ 2.8875 \end{bmatrix}$$

Os pesos da RNA podem ser substituídos na expressão (16) para obter os fatores de sensibilidade para os pontos de operação de cada cadeira, ver Tabela 3.

Tabela 3 - Fatores de Sensibilidade Obtidos da Diferenciação das RNA

CAD	$\frac{\partial P}{\partial h_i}$	$\frac{\partial P}{\partial h_f}$	$\frac{\partial P}{\partial \mu}$	$\frac{\partial P}{\partial t_r}$	$\frac{\partial P}{\partial t_f}$	$\frac{\partial P}{\partial y}$
# 1	368,02	-2011,21	1809,51	-40,40	-0,15	33,09
# 2	929,64	-2034,84	7762,37	-4,75	-16,03	45,34
# 3	1644,75	-5122,16	1425,37	-11,01	-8,00	27,07
# 4	1777,45	-5603,19	10289,22	-10,27	-4,90	13,83
# 5	1859,43	-1380,79	43160,83	-60,40	-5,13	12,38

4.3 Análise dos resultados

O gráfico da Figura 1 mostra as curvas de operação para cada cadeira. A curva superior corresponde à curva de operação da primeira cadeira, e a inferior à curva de operação da última cadeira. Observe que a medida que a espessura final diminui, as curvas do processo apresentam uma grande inclinação, tornando o processo mais sensível às perturbações nas últimas cadeiras.

O comportamento anterior pode ser observado através dos fatores de sensibilidade. Observe na Tabela 3, que a sensibilidade em relação à espessura de entrada $\frac{\partial P}{\partial h_i}$ é maior para as últimas cadeiras; o mesmo efeito

acontece com a sensibilidade no atrito $\frac{\partial P}{\partial \mu}$.

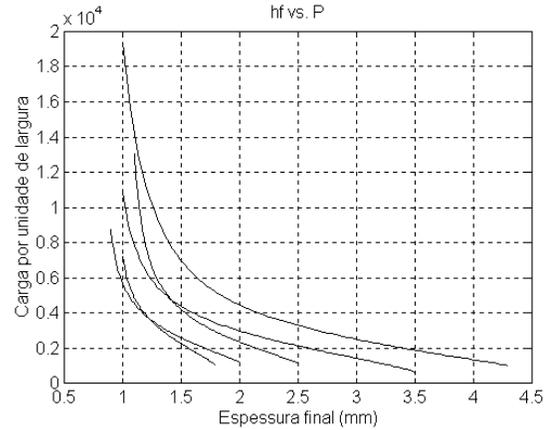


Figura 1 Curvas hf vs. P de operação nominal de cada cadeira

Em relação às tensões à frente ou à ré estas apresentam uma sensibilidade negativa, que é de esperar, pois seus efeitos sobre a carga de laminação são contrários aos efeitos da mudança na espessura de entrada e no atrito. Note que o processo é mais sensível às variações na espessura de entrada, no atrito e menos sensível às variações nas tensões à frente ou à ré.

Se considerado um sistema supervisor para controlar esse processo as informações sobre as sensibilidades pode ser de extrema relevância na escolha dos parâmetros a controlar. E sobre todo sobre quais parâmetros pode-se agir com mais eficiência.

5. Conclusões

Neste trabalho foi apresentado a possibilidade de utilização de Redes Neurais para obter os fatores de sensibilidade para analisar qualitativamente o processo de laminação em tandem. As sensibilidades da Tabela 3 mostram a boa representatividade do processo para os pontos de operação escolhidos.

Embora a nova representação tenha sido testada para modelos de laminação, ela é genérica e pode ser aplicada em outros processos, por exemplo econômicos.

Uma limitação do método proposto é, que embora permita calcular a sensibilidade do processo de laminação em qualquer ponto dentro do universo dos conjuntos para os quais a rede foi treinada, esta precisa de novo processo de treinamento para novos e diferentes pontos de operação.

A representação proposta torna-se útil quando os fatores de sensibilidade obtidos através de modelos complexos tornam-se enviáveis para sistemas de automação "on-line" e simulação qualitativa de processos.

Referências

- [1] Zárate, L.E. Sensitivity analysis of cause-effect relationship using neural networks. 16th International Conference on CAD/CAM, Robotics and Factories of the Future, Cars&Fof2000/IEE. St. Augustine, Trinidad e Tobago, Junho 26-28, 2000.
- [2] Zárate, L.E.. Um Método de Análise para Laminadores Tandem a Frio. Tese de Doutorado, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brazil, 1988.
- [3] Hunt, K.J., Sbarbaro, D., Zbikowski, R. e Gawthrop, P.J. *Automática*, Vol. 28 N° 6, pp.1083-1112 (1992).
- [4] Zárate, L.E.; Helman, H. e Gálvez, J. Representação e Controle de Laminadores Tandem Baseado em Funções de Sensibilidade Obtidos Através de Redes Neurais. XIII CBA, pp. 1314-1321, Florianópolis, SC, Brasil, 2000.
- [5] Zárate, L.E. Análise Qualitativa e Regras de Comportamento para Processos de Laminação a Frio. XIII CBA, pp. 1322-1329, Florianópolis, SC, Brasil, 2000.
- [6] Alexander, J.M., (1972). On the theory of rolling. *Proc. R. Soc. Lond. A.* 326, pp. 535-563.
- [7] Zárate, L.E.; Helman, H. e Gálvez, J. Um Método para Linearização de Modelos Utilizando Redes Neurais e Sua Aplicação em Processos de Laminação., VIII CLCA., XIII CACCA, pp.709-714, Vina del Mar Chile, 1998.
- [8] Zárate, L.E.; Gálvez, J.M. e Helman H. 1998 a. "A Neural Networks Based Controller for Steel Rolling Mills By Using Sensitivity Functions". XII Brazilian Automatic Control Conference, Vol. I, pp.29-34 - Set 14-18, MG, Brasil.
- [9] Zárate, L.E.; Song, M. e Helman H. 1998 b. "Algoritmo para Linearização de Processos via redes neurais e sua análise de comportamento assintótico". V Simpósio Brasileiro de Redes Neurais, Dez. Belo Horizonte, Brasil, pp.199-204
- [10] Zárate, L.E.; Helman H. e Gálvez, J.M. 1998 c. "Um Método para Linearização de Modelos Utilizando Redes Neurais e sua Aplicação em Processos de Laminação". VIII Congreso Latinoamericano de Control Automático", Vol. II, pp.709-714 - Nov. 9-13, Viña del Mar, Chile.
- [11] Zárate, L.E. e Helman H. 1999. "Determination of the Thickness control parameters of the rolling process through the sensitivity method, using neural networks". The Second International Conference on Intelligent Processing and

Manufacturing of Materials, Jul. 10-15, Big Island, Hawaii.

Agradecimentos

Este trabalho recebeu auxílio financeiro do Fundo de Incentivo à Pesquisa da Pontifícia Universidade Católica de Minas Gerais, FIP/PUC Minas, Projeto FIP 2001/46-TLE.