

APLICAÇÃO INDUSTRIAL DAS REDES NEURAIS ADAPTATIVAS: LAMINAÇÃO A FRIO DE CHAPAS¹

Celso Tadeu Bielskis²

Ronald Lesley Plaut³

Vito Marcos Palo⁴

Marcelo Franck Bielskis⁵

Resumo

Ao longo dos anos, muitas pesquisas têm sido conduzidas a fim de se elaborar modelos matemáticos para a determinação do esforço necessário para a conformação da tira metálica durante a laminação a frio. Muitos desses modelos derivam de Tselikov, Orowan, Bland e Ford e são baseados em diferentes suposições a fim de resolver a equação diferencial de Von Karman que expressa a distribuição da pressão ao longo do arco de contato entre os cilindros de laminação e a tira metálica. A grande dificuldade no desenvolvimento dos cálculos através dos modelos apresentados, está em variáveis que compõe as equações e que foram obtidas experimentalmente, como por exemplo, o coeficiente de atrito. Neste trabalho são apresentados os resultados obtidos, através de Redes Neurais Adaptativas (RNA), para a determinação do esforço durante a laminação a frio de tiras de aço SAE 1006. A fase de treinamento da RNA foi feita com dados reais de produção coletados através do sistema supervisorio de um laminador quádruo reversível da Brasmetal Waelzholz. Com a RNA configurada e treinada, o processo de laminação foi simulado, e a partir de uma nova coleta de dados, o esforço necessário para a conformação da tira de aço foi produzido através da RNA. Os resultados da produção através da RNA foram, então, comparados com dados reais de processo e com resultados obtidos através dos modelos matemáticos propostos por Tselikov, Ekelund e Hessemberg e Sims.

Palavras-chave: Laminação a frio; Redes neurais adaptativas; RNA.

INDUSTRIAL USAGE OF ADAPTIVE NEURAL NETWORKS: SHEET COLD ROLLING

Abstract

Throughout the years substantial research work has been carried out in order to obtain mathematical models aimed at the determination of the load required for sheet cold rolling. Several of these models derive from Tselikov, Orowan, Bland and Ford models and are based on different assumptions in order to solve the Von Karman differential equations related to the pressure distribution between the roll and the sheet along the arc of contact. The major difficulty in the development in these models is related to the variables that are part of the equations of these models such as, e.g., the friction coefficient, obtained experimentally. In the present work results are presented, through the Adaptive Neural Networks (ANN), related to the load during sheet cold rolling of a SAE 1006 steel. The net training stage has been performed using actual production data collected via the supervisory system of a four-high reversible stand at Brasmetal Waelzholz. With the ANN duly configured and trained, rolling has been simulated and, from the collection of new data, the load required has been assessed through the ANN. Production results obtained from the ANN have been compared with actual production data and with those obtained from the math models proposed by Tselikov, Ekelund and those of Hessemberg and Sims.

Key words: Cold rolling; Adaptive neural networks.

¹ *Contribuição técnica ao 44º Seminário de Laminação - Processos e Produtos Laminados e Revestidos, 16 a 19 de outubro de 2007, Campos do Jordão – SP, Brasil.*

² *Supervisor de Manutenção da Brasmetal Waelzholz S.A. Ind e Com – cbielskis@brasmetal.com.br*

³ *Prof. Assoc. – Depto. de Engenharia Metalúrgica e de Materiais – EPUSP- rlplaut@usp.br*

⁴ *Tecnólogo Eletrônico da Brasmetal Waelzholz S.A. Ind. E Com – vpalo@brasmetal.com.br*

⁵ *Gerente de Produção da Brasmetal Waelzholz S.A ind. e Com. – mbielskis@brasmetal.com.br*

1 INTRODUÇÃO

Com um mercado consumidor cada vez mais exigente, no que se diz respeito à qualidade e preço, torna-se crescente a corrida das empresas na busca de capacitação para o atendimento dessa demanda. A otimização da manufatura, visando atender aos anseios do mercado consumidor, só é possível se os efeitos e influências de cada etapa do processo são conhecidos. Em um ambiente industrial, em função da necessidade de manter a produção contínua, torna-se muito difícil a disponibilidade de máquinas para a realização de experimentos práticos, visando otimizar o processo e, em muitos casos, os parâmetros de controle do processo são baseados em modelos estatísticos. Porém, se alguma alteração ocorre nas propriedades do produto ou no processo, também deverão ocorrer mudanças no modelo. Para isso é necessária uma nova coleta de dados, que muitas vezes estão inseridos em um universo muito variável de condições operacionais de acordo com as novas especificações.^[1]

No caso da laminação a frio, encontra-se na literatura especializada, um grande número de modelos matemáticos, derivados de Tselikov, Orowan, Bland e Ford, a fim de simular o processo. Esses modelos são baseados em diferentes suposições a fim de resolver a equação diferencial de Von Karman, que expressa a distribuição da pressão ao longo do arco de contato, entre os cilindros de laminação e a tira laminada. Nesses modelos aparecem, de forma explícita, variáveis que foram obtidas através de experimentos, como por exemplo, o coeficiente de atrito.^[2]

Os dados obtidos experimentalmente levam a uma aproximação entre o resultado teórico e o medido no laminador, porém, com a variação de parâmetros do processo, como por exemplo, velocidade, lubrificante, diâmetro e rugosidade dos cilindros, qualidade do material processado, etc., podem ocorrer variações maiores entre os resultados calculados e os medidos. Com isso, surge a necessidade de utilização de ferramentas, que permitam a simulação do processo de laminação a frio de forma confiável e sem impactos na continuidade da produção dos equipamentos envolvidos.

2 OBJETIVO

Apresentar os resultados preliminares obtidos através de redes neurais adaptativas, para a determinação do esforço de laminação de tiras de aço SAE 1006.

Comparar os resultados produzidos através de redes neurais adaptativas com os resultados obtidos com os modelos matemáticos propostos por Ekelund, Tselikov e Hessemberg e Sims.

3 REDES NEURAS ADAPTATIVAS (RNA)

As RNA são programas de computador que podem reconhecer padrões em uma dada coleta de dados e produzir um modelo para esses dados. São ferramentas utilizáveis em diversas áreas de conhecimento, e as suas aplicações já podem ser encontradas em: Modelamento de processo, controle de qualidade, controle de processo, diagnósticos de máquinas etc.^[3,4] e no caso específico da laminação diversos artigos tem sido apresentados, tanto para a laminação a quente como laminação a frio, objetivando desde a otimização do processo até a automação de laminadores.^[1,5-8]

As pesquisas com RNA iniciaram-se em 1943, quando dois pesquisadores, McCULLOUGH (neurofisiologista) e PITTS (matemático) desenvolveram as bases da neurocomputação, desta forma, a RNA foi baseada na estrutura de uma célula nervosa humana, também chamada de neurônio.^[3,4,6,9]

O neurônio biológico pode ser dividido em três partes (Figura 1):

- Dendritos: Conexões pelas quais os sinais de outras células chegam até o neurônio.
- Corpo do neurônio ou soma: é o responsável pelo processamento dos estímulos de entrada provenientes dos dendritos e geração do estímulo de saída no axônio.
- Axônio: Ramificação onde acontece o sinal de saída.
- Sinapse: região entre o axônio de um neurônio e o dendrito de outro onde ocorre a transmissão dos sinais entre as células nervosas.

O neurônio artificial (Figura 2) foi inspirado em uma simplificação do modelo do neurônio biológico. No neurônio artificial os dendritos são representados por x_n terminais de entrada e o axônio como um terminal de saída y . As sinapses são representadas por pesos w_n , responsáveis pela soma ponderada das entradas x_n . Quando a soma dos impulsos recebidos pelo neurônio ultrapassa o seu limiar de excitação, ele dispara. No modelo do neurônio artificial a sua ativação é conseguida através de uma função de ativação.^[3,4,9]

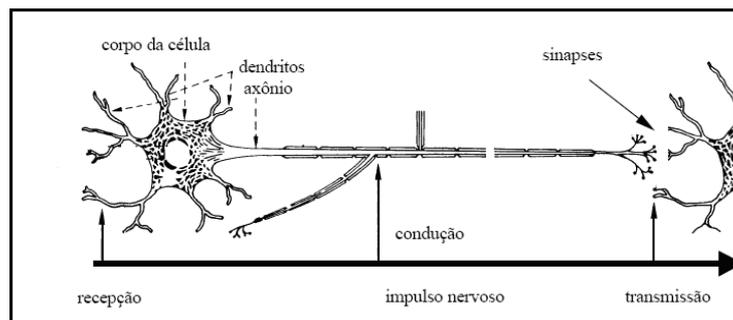


Figura 1 – Modelo de transmissão em neurônios biológicos^[4]

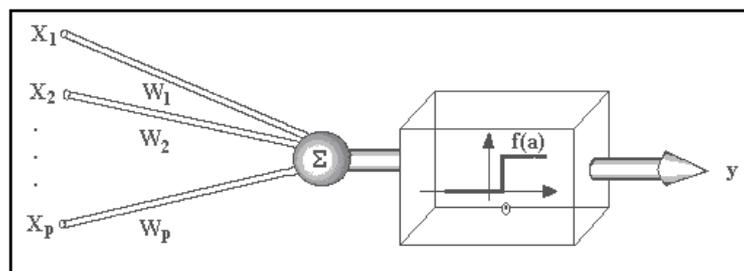


Figura 2 – Modelo do neurônio artificial^[9]

Uma das principais características das redes neurais é a sua capacidade de aprendizado e com isso a possibilidade de melhorar o seu desempenho. A fase de aprendizagem é feita através de um processo iterativo de ajustes aplicados a seus pesos e é realizado junto a um conjunto bem definido de regras denominado algoritmo de aprendizado. Para que a rede tenha uma fase de aprendizado verdadeira, é muito importante que a coleta de dados seja feita de forma criteriosa de modo a serem evitados modelos espúrios.

A RNA deve possuir uma camada de entrada e uma de saída, e sua configuração mais comum é a *Multilayer Perceptron*.^[11] Nessa configuração, as camadas são classificadas em três grupos.^[3,6]

- Camada de entrada: onde são inseridos os padrões na rede
- Camada intermediária ou oculta: nessa camada é feito o processamento
- Camada de saída: nessa camada é obtido o resultado desejado.

No diagrama é apresentada uma rede *Multilayer Perceptron* (Figura 3) com duas camadas ocultas (MLP). Nela, os dados são inseridos na camada da entrada e começam ser multiplicados por pesos da interconexão, enquanto são transferidos da camada de entrada à primeira camada oculta. Dentro da primeira camada oculta, são somados e processados. Enquanto os dados processados saem da primeira camada oculta, são novamente multiplicados por pesos da interconexão, somados e então processados pela segunda camada oculta. Finalmente os dados são multiplicados por pesos da interconexão e processados por uma última vez dentro da camada da saída. [10]

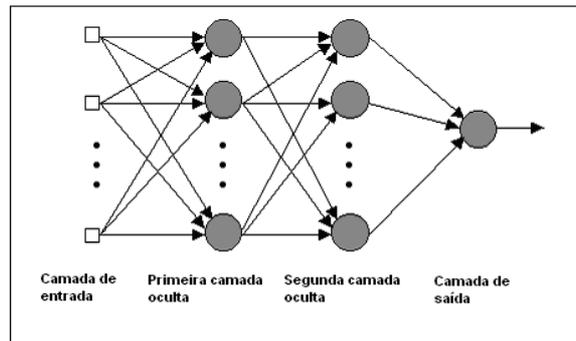


Figura 3 – Esquema de uma rede *Multilayer Perceptron* [10]

Como visto anteriormente, o processo de aprendizado é uma das fases mais importantes da elaboração de uma RNA. Em 1986, foi desenvolvido por Rumelhart e McClelland um algoritmo de treinamento da rede. Este algoritmo foi denominado *Backpropagation* ou retropropagação. Em resumo, pode-se considerar que o algoritmo funciona como um “professor” da rede, controlando os pesos que são aplicados nas interconexões das camadas de uma rede, como por exemplo, do tipo Multilayer. Através de um mecanismo de correção de erros os pesos são ajustados de forma a encontrar uma ligação entre os pares de entrada e de saída. Neste caso o treinamento ocorrerá em duas fases, sendo que cada fase percorre um sentido da rede. As fases são: [1,5-7,12]

- *Forward*: É utilizada para definir a saída da rede para um dado padrão de entrada.

- *Backward*: Utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões a cada iteração.

4 PROCEDIMENTO EXPERIMENTAL

4.1 Coleta de Dados [2]

Para o treinamento da rede neural, através do sistema supervisorio do laminador, efetuou-se uma coleta dos dados operacionais, força, velocidade, torque, tração e espessuras, durante o processo de laminação de tiras de aço SAE 1006. O sistema supervisorio foi desenvolvido utilizando-se o software *Indusoft Web Studio*TM, [13] que possui um conjunto de ferramentas necessárias para a interface homem-máquina e aquisição de dados.

O supervisor está conectado com o Controlador Lógico Programável (CLP) através de uma rede, e faz a coleta e armazenagem dos dados em intervalos de 1 segundo. Os dados, então, podem ser visualizados na forma gráfica ou então através de relatórios gerados em formato *txt.*, que podem ser abertos em planilhas do Excel.

Na Figura 4 é representado, o posicionamento dos instrumentos necessários para coleta de dados. Analisando a figura, primeiramente pela coleta de dados referentes à espessura, verifica-se que, a cada novo rolo que deverá ser processado ou a cada passe de laminação, o operador, através de uma IHM – Interface Homem-Máquina – instalada no púlpito de operação, irá inserir os dados referentes à espessura inicial e desejada da tira a ser laminada. Ao serem inseridos, os dados serão transmitidos, através de uma rede, ao CLP. No CLP, os dados serão processados de acordo com a lógica de programação do laminador, e um sinal será enviado a uma servo - válvula que irá liberar a passagem do óleo hidráulico necessário para a movimentação do cilindro hidráulico, que é responsável pelo posicionamento dos cilindros de laminação e pela força de laminação. Durante o deslocamento do cilindro hidráulico, um transdutor de posicionamento irá monitorar e informar ao CLP a posição e a respectiva abertura entre os cilindros de laminação. O CLP, por sua vez, fará a comparação do valor de posicionamento lido, pelo transdutor, com o valor desejado, inserido pelo operador, e irá indicar o momento em que o movimento dos cilindros hidráulicos deverá ser cessado. Mas, quando os cilindros de laminação encontram a tira de aço que será laminada, surge uma força contrária decorrente da resistência à deformação que é imposta pela tira de aço. Quando os cilindros de laminação se deparam com esta força contrária, ocorrerá uma tendência de parada do movimento antes que seja atingido o posicionamento desejado que satisfaça o valor de espessura inserido pelo operador. Através do transdutor de posicionamento, o CLP é informado o posicionamento dos cilindros. Este, por sua vez, envia um comando para a servo-válvula, que efetuará um controle na pressão hidráulica e proporcionará o esforço de laminação necessário para que a tira metálica seja conformada de acordo com a espessura desejada. Esta pressão hidráulica é monitorada e controlada por um transdutor de pressão que está instalado na linha de alimentação dos cilindros hidráulicos. As informações referentes ao posicionamento dos cilindros de laminação e da pressão hidráulica necessária para o esforço de laminação, são coletadas e armazenadas no sistema de aquisição de dados e, no caso da espessura, são armazenadas em milímetros. No caso da pressão hidráulica, esta é transformada através de cálculos efetuados pelo CLP e armazenada na forma de esforço de laminação, em Newtons.

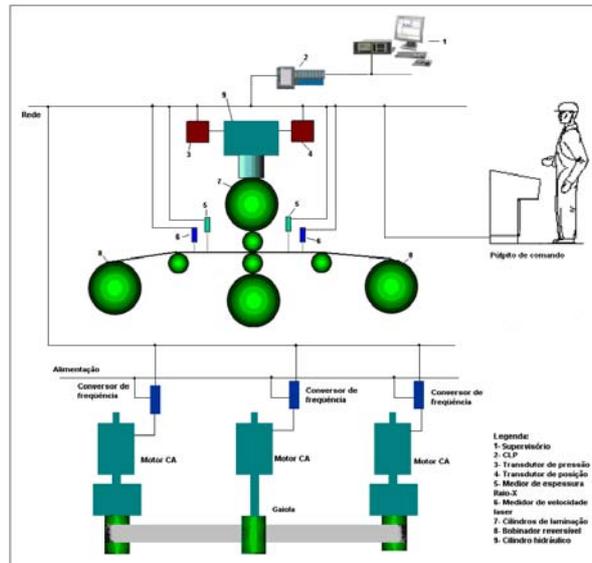


Figura 4 – Posicionamento da instrumentação

Quando a laminação é iniciada, os medidores de espessura podem ser atuados, e se for o caso, irá auxiliar no controle da espessura da tira laminada. Nesta situação, os medidores efetuam a leitura da espessura da tira laminada e, então, os dados referentes à espessura são enviados ao CLP. O CLP, por sua vez, processa os dados e efetua o controle do processo, de forma que a espessura seja obtida dentro das tolerâncias requeridas na operação. Os medidores de espessura trabalham em conjunto com sensores que medem a velocidade de laminação. A indicação da velocidade de laminação irá determinar o tempo de resposta do sistema automático de correção da espessura.

A exemplo da espessura, os valores desejados de velocidade de laminação e força de bobinamento (que irá determinar a tração que será imposta a tira), também são inseridos no púlpito de comando através da interface homem-máquina.

4.2. Configuração da Rede

A RNA foi desenvolvida através do software *NeuroSolutions for Excel (Level Educator)*,^[10] e apresenta a seguinte configuração:

Tipo de rede: Multilayer Perceptron.

Camadas intermediárias: 2 camadas

Função de transferência: TahnAxon

Dados de entrada: Passe, largura e espessura de entrada e saída da tira, velocidade de laminação e força de bobinamento avante e à ré.

Quantidade de dados coletados: 1047, sendo divididos em 75% para treinamento, 12,5% para validação e 12,5% para teste.^[3]

4.3 Elaboração dos Cálculos^[14-17]

Para serem desenvolvidos os cálculos referentes aos modelos matemáticos propostos por Ekelund, Tselikov e Hessemberg e Sims, é necessário o conhecimento da curva de escoamento (fluxo) do material e o coeficiente de atrito.

A curva de escoamento foi obtida através da realização do ensaio de tração de 12 corpos de prova, como mostra o gráfico da Figura 5.

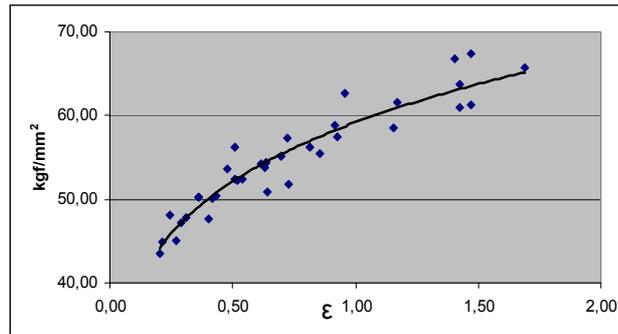


Figura 5 – Curva de escoamento (fluxo)

Para se determinar o coeficiente de atrito, foi efetuada uma coleta de dados, de um grupo de rolos laminados, (foram selecionados rolos que sofreram até quatro passes). Então, os passes de laminação foram analisados e depurados levando-se em conta a tensão efetiva (gráfico da Figura 6), σ , necessária para a sua conformação (eq 1).

$$\sigma = \frac{1000.P}{F_d} \quad (1)$$

$$F_d = (\sqrt{R.(h_f - h_i)}) . b \quad (2)$$

Onde:

b= Largura da tira

R= Raio do cilindro de laminação

h_i = Espessura inicial no passe

P= Esforço de laminação

h_f = Espessura final no passe

Conhecida a tensão efetiva, e com base na curva de escoamento (fluxo) do aço SAE 1006, foram selecionados os passes de laminação e determinado o coeficiente de atrito, μ , de acordo com a equação 3.

$$\mu = \frac{M_d}{P.R} \quad (3)$$

Conhecidos estes valores (a curva de fluxo e o coeficiente de atrito), foram efetuados os cálculos do esforço de laminação, para 155 passes distribuídos em diversos rolos. Os cálculos do esforço de laminação, sem influência da tração, foram elaborados através das equações de Ekelund, equação 4, e através da equação proposta por Tselikov, equação 5.

$$P = b . \sigma_{bi} . \sqrt{R' \Delta h} \left[1 + \frac{1,6 . \mu \sqrt{R' \Delta h} - 1,2 \Delta h}{h_1 + h_2} \right] \quad (4)$$

$$\frac{P_m}{\sigma_{Bi} \Delta h} = \frac{1}{\Delta h} \left\{ \left(1 - \frac{\sigma_{Ré}}{\sigma_{Bi}} \right) \left(\frac{h_i}{\delta - 2} \right) \left[\left(\frac{h_i}{h_N} \right)^{\delta - 2} - 1 \right] + \left(1 - \frac{\sigma_{Av}}{\sigma_{Bi}} \right) \left(\frac{h_f}{\delta + 2} \right) \left[\left(\frac{h_N}{h_f} \right)^{\delta + 2} - 1 \right] \right\} \quad (5)$$

$$\delta = 2\mu \sqrt{\frac{R'}{\Delta h}} \quad (6)$$

$$P = P_m . b . \sqrt{R' \Delta h} \quad (7)$$

O esforço de laminação sob influência da tração foi determinado, para ambos os casos, através da relação de Hessemberg e Sims, equação 7.

$$F = P \left\{ 1 - \frac{1}{3\sigma_{Bi}} (2\sigma_{Ré} + \sigma_{Av}) \right\} \quad (8)$$

Onde:

σ_{Bi} = Tensão de deformação biaxial
 $\sigma_{Ré}$ = Tensão à ré aplicada na tira

σ_{AV} = Tensão avante aplicada na tira
 R' = Raio achatado do cilindro

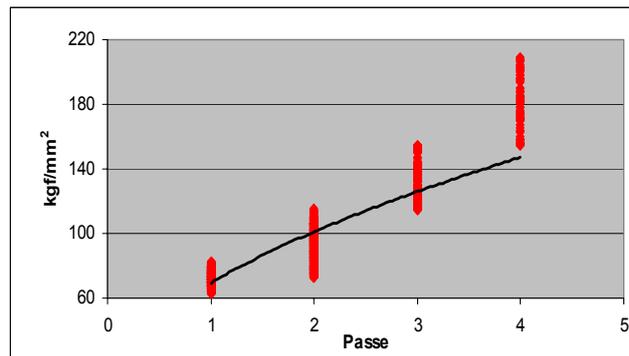


Figura 6 – Análise da tensão efetiva

5 RESULTADOS OBTIDOS

5.1 Treinamento da RNA

No gráfico da Figura 7 é observada a capacidade de aprendizado da rede. No eixo das abscissas é apresentado o número de iterações feitas durante o treinamento. A forma da curva indica que houve um rápido aprendizado da rede, visto que, abaixo de 100 iterações a margem de erro converge para uma faixa muito baixa de aproximadamente 1%, enquanto que ao término das 1000 iterações o erro está em torno de 0,6%.

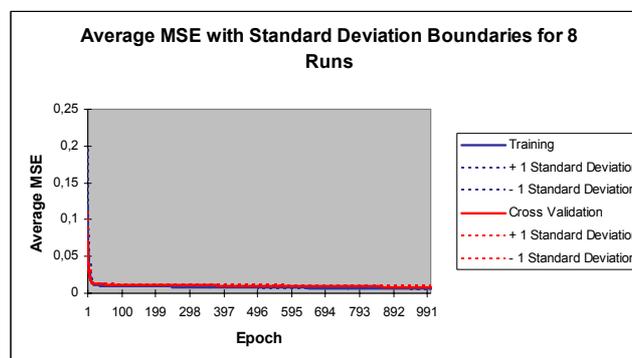


Figura 7 – Erro médio durante o treinamento da RNA

A aderência entre os dados produzidos pela RNA e os inseridos (práticos) pode ser verificada no gráfico da Figura 8. Neste verifica-se a existência de uma boa correlação entre os valores produzidos pela RNA e os valores inseridos, resultando em um coeficiente $r \approx 0,93$.

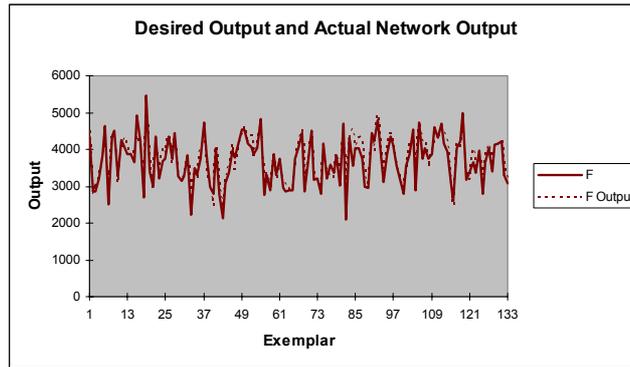


Figura 8 – Relação entre dados obtidos e o desejado

No gráfico da Figura 9 é apresentada a relevância dos dados de entrada sobre o dado de saída desejado, o esforço de laminação. Analisado as variáveis que apresentaram maior relevância (espessura de entrada, espessura de saída, passe de laminação e largura), verifica-se que todas aparecem de forma explícita nas equações de Ekelund e de Tselikov para o cálculo do esforço de laminação. No caso específico do passe de laminação, este representa o encruamento que a tira sofre no decorrer da laminação.

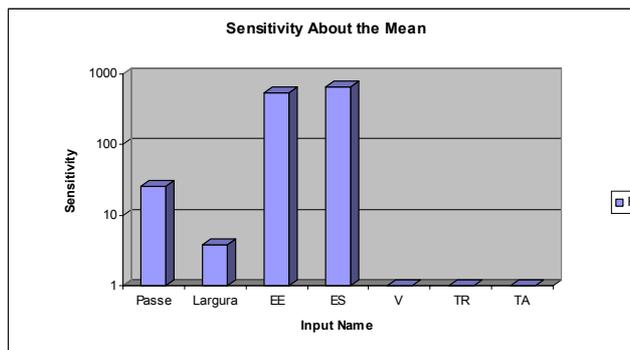


Figura 9 – Relevância dos dados de entrada

Com a rede configurada e treinada, procedeu-se uma nova coleta de dados, isto é, a RNA alimentada com esses dados de entrada. Com isso produziu-se o esforço de laminação a partir de dados que não fizeram parte do processo de treinamento inicial da rede. Os resultados foram comparados com os valores medidos durante a laminação. No gráfico da Figura 10, é apresentada a relação entre o produzido e o medido, então se pode verificar que praticamente todos os pontos apresentam uma margem de inferior a 20%, sendo que a maioria está em uma faixa inferior a 10%.

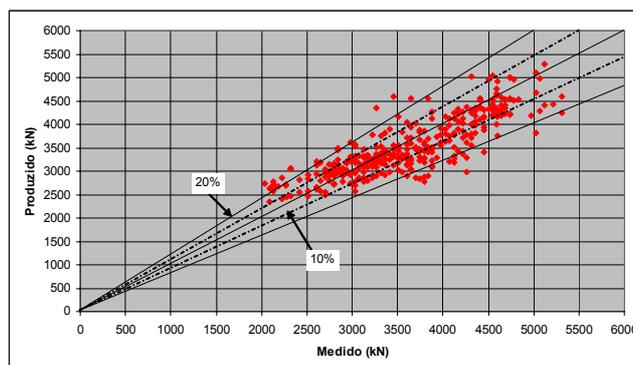


Figura 10 – Relação entre os dados produzidos pela RNA e os medidos

5.2 Resultados Obtidos com RNA e Modelos Matemáticos

Nos gráficos das Figuras 11, 12 e 13, são apresentados os resultados do esforço de laminação obtidos através dos modelos de Ekelund, Tselikov e com a utilização de RNA.

Nos resultados obtidos com os modelos de Ekelund e Tselikov (Figuras 11 e 12), observa-se que existe uma correlação entre os valores medidos e calculados, porém, nos dois casos, os pontos apresentados (plotados) no gráfico se encontram, em sua grande maioria, e de forma sistemática, abaixo dos valores medidos. No caso dos resultados produzidos pela RNA (Figura 13), observa-se que os pontos plotados concentram-se, em sua grande maioria, próximos a linha média, dentro de uma faixa de erro inferior a 10%. A minoria dos pontos encontra-se em uma faixa de erro superior a 20%.

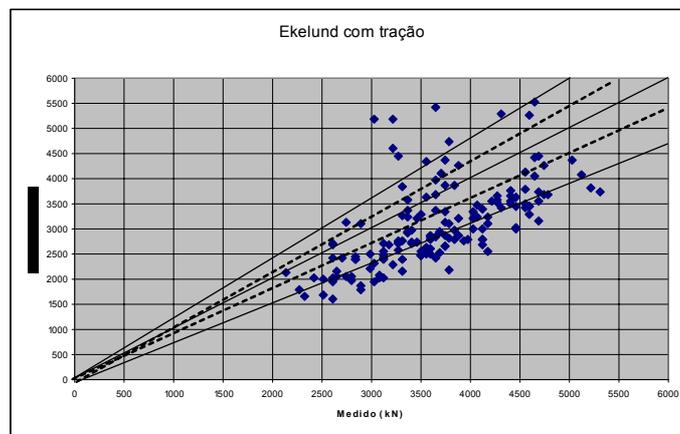


Figura 11 – Relação entre os resultados obtidos pelo modelo de Ekelund e através de RNA

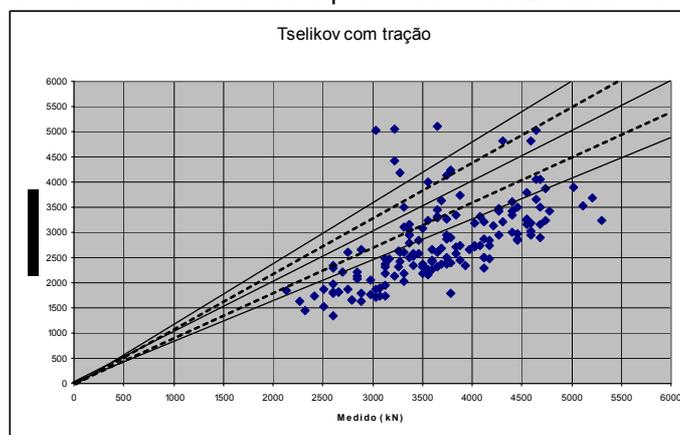


Figura 12 – Relação entre os resultados obtidos pelo modelo de Tselikov e através de RNA

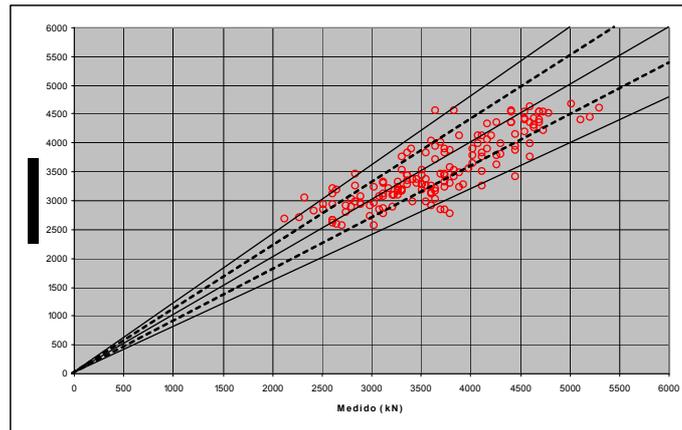
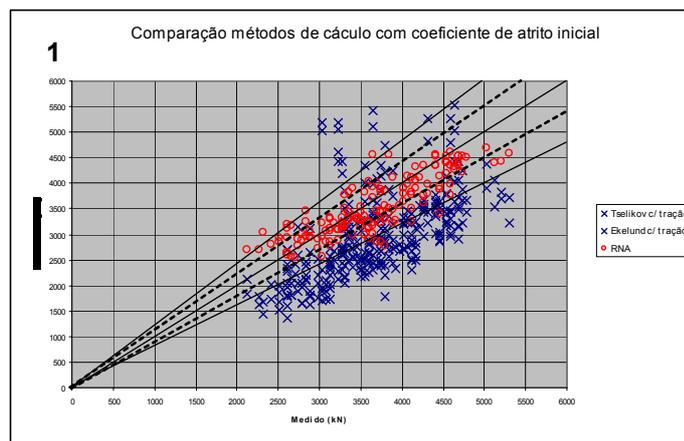


Figura 13 – Resultados obtidos através de RNA

No gráfico 1 da Figura 14, foram plotados todos os resultados obtidos, através dos modelos matemáticos e de RNA, ficando, dessa forma, mais clara a precisão dos resultados obtidos pela RNA em relação aos modelos de Ekelund e Tselikov. Como citado anteriormente, um fator de grande dificuldade no desenvolvimento dos cálculos de laminação a frio está na determinação do valor do coeficiente de atrito. Para a realização dos cálculos apresentados neste trabalho, utilizou-se o coeficiente de atrito calculado a partir da coleta de dados de passes de laminação semelhantes aos simulados e, nesse caso, o coeficiente de atrito variou de 0,04 a 0,11 de acordo com o passe de laminação. Na literatura especializada encontra-se referência ao coeficiente de atrito na faixa de 0,05 a 0,15, conforme a rugosidade dos cilindros e o tipo de lubrificante utilizado.^[2,14-16] Os resultados plotados no gráfico 2 da figura 14 foram obtidos através dos modelos de Ekelund e Tselikov, porém, o coeficiente de atrito foi corrigido em 60% e passou a variar entre 0,07 e 0,18. Com isso, verifica-se que os pontos plotados passam a convergir para uma faixa mais próxima dos valores obtidos através de RNA e dos valores medidos.



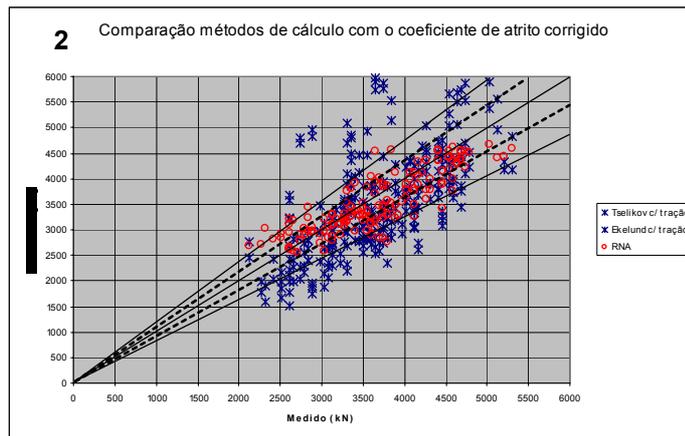


Figura 14 – Influência do coeficiente de atrito nos modelos de Ekelund e Tselikov

6 CONCLUSÕES

1-Os resultados preliminares obtidos neste trabalho demonstram que o uso da RNA, através do *Neurosolutions*, é uma ferramenta adequada para a simulação do esforço de laminação a frio.

2- Os resultados obtidos, com o uso de RNA, foram mais precisos do que os obtidos através dos modelos de Tselikov e Ekelund. Este fato pode ser explicado pela dificuldade de se determinar o coeficiente de atrito durante a laminação a frio, visto que, correções no coeficiente de atrito fizeram com que os resultados obtidos, através dos modelos de Tselikov e Ekelund, convergissem a uma faixa mais próxima dos valores reais medidos no laminador.

3-Para que os dados obtidos na “produção” da RNA relativos ao esforço de laminação a frio, sejam confiáveis (quando são utilizadas diversas qualidades de materiais simultaneamente, durante a fase de treinamento), a rede deve ser alimentada com quantidades representativas de dados para cada qualidade de material.

4-Para que se tenha um processo de treinamento da RNA eficaz, é necessária uma quantidade representativa e confiável de dados. Para isso torna-se indispensável o uso de sistemas automatizados de coleta de dados.

REFRÊNCIAS

- 1 LARKIOLA, J. *et al* . Prediction of rolling force in cold rolling by using physical models and neural computing. **Journal of Materials Processing Technology**. P 381-386, 1996.
- 2 BIELSKIS, C.T **Efeito da tração a ré no torque inicial durante a laminação de tiras a frio**. 2006. 82f. Dissertação (Mestrado em Processos Industriais) – Instituto de Pesquisas Tecnológicas do Estado de São Paulo - IPT, São Paulo, 2006.
- 3 PLAUT, R.L. **Redes Neurais Artificiais aplicadas à laminação a frio**. Notas do treinamento realizado na Brasmetal Waelzholz. Diadema. 2006
- 4 TATIBANA, C.Y;KAETSU, D.Y. **Uma introdução às redes neurais**. Disponível em www.din.uem.br/ia/neurais/ Acesso em fev. 2006.
- 5 LARKIOLA, J. *et al*. The role of neural networks in the optimization of rolling process. **Journal of Materials Processing Technology**. P 80-81, 1998.

- 6 GORNI, A. The application of the neural networks in the modeling of plate rolling process. **The Minerals, Metals e Materials Society**. Disponível em www.tms.org/pubs/journals/jom/9704/gorni/gorni-9704.html , Acesso em Abr. 2007
- 7 PORTMANN, F *et al.* Application of neural networks in rolling mill automation. **Iron and Steel Engineer**, feb. 1995.
- 8 DUKMAN, L.; YONGSUG, L. Application of neural-network for improving accuracy of roll-force model in hot-rolling mill. **Control Engineering Practice**. South Korea, v10. p 473-478, 2002.
- 9 CARDOSO, A. A, **Redes neurais artificiais na avaliação de concentração de tensões em juntas tubulares soldadas**. 1999. 99f. Tese (Tese de doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1999.
- 10 NEUROSOLUTIONS. **What is a Neural Network?** Disponível em www.neurosolutions.com Acesso fev. 2006.
- 11 HORNIK,K., Multilayer feed forward networks. **Neural Networks**. v2, p. 359-366, 1989.
- 12 CAMPANA,R.C.;PLAUT,RL.**Aplicabilidade de redes neurais adaptativas (RNA) na extrusão de ligas de alumínio**. In: III CONGRESSO INTERNACIONAL DO ALUMÍNIO, São Paulo, 2007, **Anais**, 2007.
- 13 INDUSOFT. **InduSoft Web Studio™**. Disponível em www.indusoft.com. Acesso em Abr 2007.
- 14 PLAUT, R.L. **Laminação dos aços: tópicos avançados**. 3ed. São Paulo: Associação Brasileira de Metais, 1984.
- 15 POLUKHIN, P. *et al.* **Rolling Mill Practice**. Tradução de Nicholas Weinstein. Moscow: Peace Publishers.
- 16 TSELIKOV, A. **Stress and strain in metal rolling**. Tradução de W.U. Sirk. Moscow: Mir Publishers, 1964.
- 17 UNDERWOOD, L.R. **The rolling of metals: The theory and experiment**. 2.ed. London: Chapman & Hall Ltd, 1952. v.1.