

APLICAÇÃO DE REDE NEURAL PARA CÁLCULO DA TENSÃO DE ESCOAMENTO NA LAMINAÇÃO DE TIRAS A QUENTE DE AÇOS C-MN¹

Pedro S. S. Vallim²
Antonio Augusto Gorni³
Ronald Lesley Plaut⁴

Resumo

Aplicações de Redes Neurais Artificiais (RNA), também conhecidas como Redes Neurais Adaptativas, usando multicamadas, fluxo de informações direto à frente, algoritmos de treinamento e retro propagação (MFB), foram realizadas para calcular uma importante variável do processo de laminação de tiras no Laminador de Tiras a Quente (LTQ). Esta variável é a tensão de escoamento a quente (TEQ), relacionada ao caso particular da laminação de tiras a quente, de aços C-Mn. Conceitos básicos sobre o passe de laminação são apontados. Fundamentos das redes neurais MFB, sua metodologia, coleta e seleção de dados, arquitetura, treinamento, desempenho e precisão são destacados, objetivando a avaliação dos valores de TEQ para cada cadeira do LTQ. Como uma premissa deste trabalho, as variáveis de entrada são mantidas em um nível simples, sem qualquer cálculo sofisticado ou recursivo, em termos da obtenção de seus valores. Sob estas condições, modelos simplificados foram apresentados para as duas principais variáveis de entrada, respectivamente a temperatura da tira no passe de laminação e o raio achatado dos cilindros de trabalho.

Palavras-Chave: Redes neurais; Laminação de tiras a quente; Tensão de escoamento a quente; Força de laminação a quente.

APPLICATION OF NET NEURAL FOR CALCULATION OF THE FLOW STRESS IN THE HOT ROLLING OF STRIPS OF THE C-Mn STEELS

Abstract

Applications of Artificial Neural Networks (ANN), also known as Adaptive Neural Networks, using multi-layers, feed-forward, training and back-propagation algorithms (MFB), are performed to calculate an important variable of strip rolling process in the Hot Strip Mill (HSM). This variable is the hot flow stress (HFS), related to the particular case of the hot strip rolling of the C-Mn steels. Basic concepts about rolling pass are pointed out. Fundamentals of the neural network MFB, its methodology, data collection and selection, net architecture, training, performance and accuracy are highlighted, aiming at the evaluation of the HFS values for each HSM stand. As a premise of this work, the net input variables are kept at a simple level, without any sophisticated or recursive calculations, in terms of the obtainment of their values. Under these conditions, simplified models are presented for the two main input variables, namely the strip temperature in the rolling pass and the flattened working roll radius.

Key words: Neural networks; Hot strip rolling; Low carbon steels; Hot flow stress; Hot rolling force.

¹ Contribuição técnica ao 46º Seminário de Laminação – Processos e Produtos Laminados e Revestidos, 27 a 30 de outubro de 2009, Santos, SP.

² Membro da ABM, Engenheiro Mecânico, MBA em Siderurgia, CQE, Analista de Operação da Laminação a Quente da Usiminas Cubatão – SP - Brasil. E-Mail: pedro.vallim@usiminas.com

³ Membro da ABM, Doutor em Engenharia de Materiais, Analista de de Operação da Laminação a Quente da Usiminas Cubatão - SP - Brasil. E-Mail: antonio.gorni@usiminas.com

⁴ Membro da ABM, Doutor em Conformação Mecânica e Professor de pós-graduação da Universidade de São Paulo – USP, São Paulo - SP – Brasil. E-Mail: rlplaut@usp.br

1 INTRODUÇÃO

Muitos são os trabalhos e livros elaborados para cálculo de previsão das variáveis de processo da laminação de tiras a quente. Com base nas teorias desenvolvidas, sistemas de controle automático do ajuste das cadeiras do laminador foram e são largamente utilizados. Entretanto, limitações na obtenção de precisão de resultados dos modelos clássicos, devido à complexidade do entendimento físico e controle do real fenômeno no passe de laminação, aliada à expansão da capacidade de desempenho dos atuais computadores são um terreno fértil também para aplicação de redes neurais.

A rede neural artificial é uma ferramenta matemática com inspiração no funcionamento do cérebro humano, que vem atender a necessidade de se conseguir uma alternativa viável na abordagem de um problema complexo, como o da laminação.

O objetivo deste trabalho é mostrar uma aplicação de Rede Neural Artificial (RNA), do tipo multicamada, de fluxo à vante, com correção de erro por retro propagação (*MFB = Multilayer, Feedforward, with Backpropagation*), para cálculo da tensão de escoamento na laminação de tiras a quente (TEQ), de aços planos comuns do tipo Carbono-Manganes (C-Mn).

As RNA's, em número de seis, sendo uma para cada cadeira do LTQ, foram treinadas e validadas a partir de lotes de dados industriais obtidos do processamento desses materiais no Laminador de Tiras a Quente (LTQ) número 1 da Laminação a Quente da Usiminas Unidade de Cubatão.

Nas RNA's desenvolvidas, é mostrada a utilização de variáveis de entrada as mais primárias e imediatas, que não exigem modelos de cálculo complexos ou sofisticados para sua informação.

Para suporte e apoio ao tema central um breve resumo dos fundamentos de RNA's, com foco nas do tipo *MFB*, além de um resumo do processo de laminação de tiras a quente também são abordados.

2 MATERIAIS E MÉTODOS

2.1 Fundamentos de Redes Neurais Artificiais *MFB*

As Redes Neurais Artificiais (RNA's), ou Redes Neurais Adaptativas, modelos matemáticos com inspiração nos cérebros humanos, são um sistema de processamento em malha, paralelo e distribuído, com unidades internas chamadas neurônios, que armazenam o conhecimento experimental, disponibilizando-o para uso. Para tanto, uma adequada quantidade dados de entrada, exemplos ou casos, é utilizada para treinar a rede, em sucessivas etapas, até que a discrepância entre o resultado esperado e o obtido seja satisfatória, para o objetivo visado. Assim, de forma similar ao cérebro humano, o conhecimento é adquirido pela RNA a partir de seu ambiente, através de um processo de aprendizagem, sendo este conhecimento armazenado em parâmetros internos da rede, os pesos e bias, que participam das conexões entre neurônios.

A maior parte dos problemas reais possui soluções não lineares, de difícil modelagem, devido ao desconhecimento da forma de relação entre variáveis de entrada e saída. As RNA's distribuem toda essa não linearidade pela sua malha interna, de forma bem mais simples.

Uma vez tendo sido convenientemente ajustadas, as RNA's passam a ter a habilidade de produzir saídas adequadas para entradas que não estavam presentes

no seu treinamento, desde que tais entradas sejam oriundas do mesmo tipo de população alvo do problema. Esta nada mais é do que a característica de generalização da rede, ou seja, da capacidade de fornecer respostas coerentes a padrões ou casos novos.

Um neurônio artificial, representado na Figura 1 é a unidade básica de processamento de informação de uma rede neural, que recebe um ou mais sinais de entrada e devolve um único sinal de saída, que pode ser distribuído como sinal de rede, ou como sinal de entrada para um ou vários neurônios de camadas posteriores.⁽¹⁾

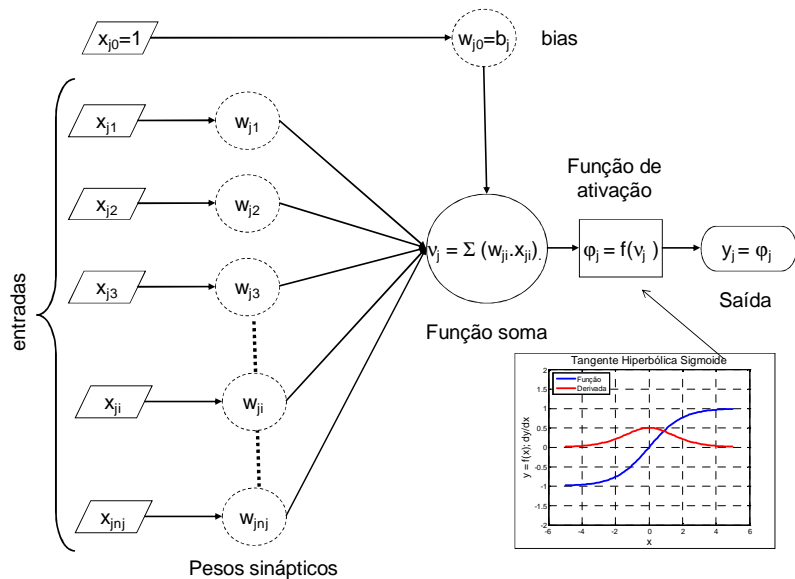


Figura 1. Representação esquemática de um neurônio matemático (j), com n_j informações de entrada ou sinais (x_{ji}), e *bias* b_j , sobre os quais são aplicados n_j pesos (w_{ji}), função soma (v_j), função de ativação (ϕ_j) e uma informação ou sinal de saída (y_j).

Podem ser destacados os seguintes elementos constituintes desse neurônio:⁽²⁾

- Sinapses, que são conexões de entrada do neurônio, caracterizadas por pesos ou forças próprias, nas quais cada sinal de entrada (x_{ji}) é multiplicado por um peso sináptico (w_{ji}).
- Função soma, a qual realiza a adição de cada o valor resultante de cada sinapse, realizando assim a soma ponderada dos sinais de entrada, mais o valor do *bias*, sendo definida por:

$$v_j = \sum_{i=0}^{n_j} (w_{ji} \cdot x_{ji}) = b_j + \sum_{i=1}^{n_j} (w_{ji} \cdot x_{ji}) \dots\dots\dots(1)$$

- Função de ativação é uma função de transferência que define a restrição da amplitude do sinal de saída do neurônio. O seu resultado numérico equivale ao valor do sinal de saída do neurônio:

$$\phi_j(v_j) = y_j \dots\dots\dots(2)$$

A função de transferência é customizável, e pode ser linear ou não, contínua ou não, conferindo ao neurônio grande potencial como ferramenta de análise de problemas reais. Como exemplo, é mostrada a função tangente hiperbólica sigmóide, ilustrada também na Figura 1.

$$\varphi_j(v_j) = \text{taghsig}(v_j) = \frac{1 - e^{-v_j}}{1 + e^{-v_j}} \rightarrow \varphi'_j(v_j) = \frac{2 \cdot e^{-v_j}}{(1 + e^{-v_j})^2} \dots\dots\dots(3)$$

Combinando os neurônios em uma ou mais camadas, cada uma delas com um ou mais neurônios interligados através de sinapses, é obtida a chamada Rede Neural Artificial (RNA), como a exemplificada na Figura 2, e que genericamente possuem:⁽³⁾ uma camada de entrada ou de distribuição, onde não se realiza nenhum tipo de cálculo; uma ou várias camadas ocultas, ou intermediárias, cada uma delas composta de um ou mais neurônios ocultos; uma camada de saída, contendo necessariamente um número de neurônios igual ao número de sinais de saída da rede.

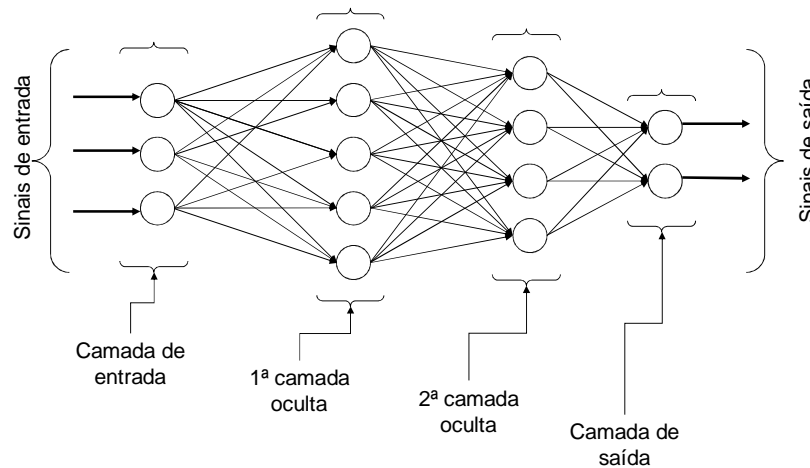


Figura 2. Exemplo de uma cadeia de neurônios interligados em uma RNA multicamadas, com respectivas conexões e sinais de entrada e saída. Neste caso, o fluxo de informações é sempre à vante (*feedforward*), com os neurônios de uma camada inteiramente conectados aos da seguinte (*fully connected*).

Com o progressivo ajuste de valores dos pesos sinápticos, a rede neural pode representar (ou memorizar) as relações entre os dados de entrada e saída, assumindo uma característica de memória associativa. Esse processo de aprendizagem ou treinamento da rede, no caso específico da RNA MFB, é reconhecido com sendo o resultado da retro propagação contínua dos erros.

Uma forma de se abordar esse processo envolve a comparação do sinal de saída y_j , com um correspondente valor objetivado d_j a cada iteração ou apresentação de caso (j), entendendo-se por caso um conjunto completo de dados de entrada. Assim, para cada sinal de saída são gerados erros e_j , e um erro global instantâneo E_t , representativo de todos esses erros. Pode-se optar então, ao final de todo um ciclo (t) de apresentação do conjunto de todos os casos à rede, chamado de época, por se obter um erro global médio E_T , que é de uma forma adequada creditado ponderadamente a cada peso sináptico das conexões internas da rede, que será corrigido de uma quantidade $(\Delta w_{ji})_t$.

Todo esse processo envolvendo a propagação à vante dos sinais de entrada, retro propagação do erro do sinal de saída e aprendizagem das conexões da rede é sugerido pelas expressões mostradas a seguir.

$$(e_j)_t = (d_j - y_j)_t \rightarrow E_t = \left(\frac{1}{2} \cdot \sum_{j=1}^{n_m} (e_j^2) \right)_t \rightarrow \bar{E}_T = \left(\frac{1}{N} \cdot \sum_{t=1}^N E_t \right)_T \rightarrow \boxed{(\Delta w_{ji})_t = \left(-\eta \cdot \frac{\partial E}{\partial w_{ji}} \right)_t} \dots\dots\dots(4)$$

Um critério de parada do ajuste da rede considera a minimização do erro global médio até que ele assuma um valor considerado aceitável para o objetivo visado. Porém, mesmo tendo sido alcançado tal resultado, isso não garante que a rede ajustada funcione com precisão caso seja aplicada a um lote com novos conjuntos de dados de entrada, distintos dos do lote de treino. Adota-se então também um critério que envolva a cada época, uma avaliação paralela da precisão da rede quando aplicada a um lote de validação, com dados distintos dos de lote de treinamento, conforme sugerido na Figura 3. Esse procedimento visa garantir a real precisão da rede para qualquer lote de dados oriundos da população alvo da análise, ou seja, a generalização da RNA.

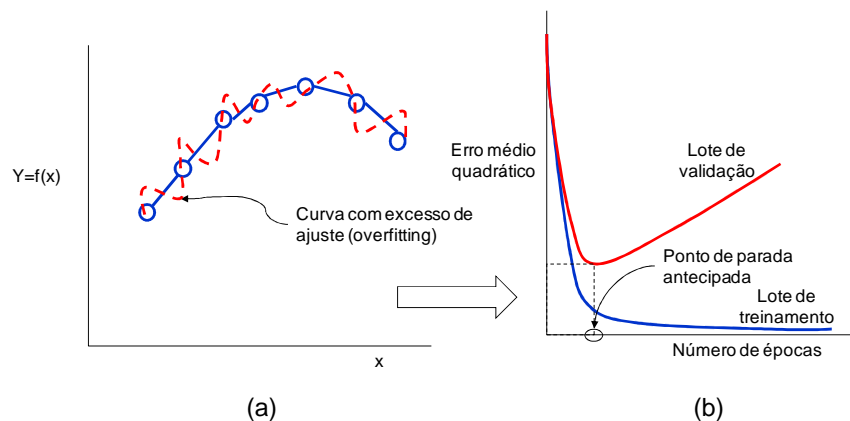


Figura 3. Critério de parada de treinamento da RNA baseado em validação da generalização: (a) RNA com excesso de ajuste, levando à imprecisão do resultado quando aplicada a dados distintos dos de lote de treino; (b) parada antecipada do treinamento da RNA no quando da ocorrência de divergência acentuada de precisão da RNA quando aplicada ao lote de validação.

Variações de algoritmos de treinamento foram desenvolvidos e adotados em pacotes comerciais de software, visando a otimização dos processamentos. Neste trabalho, em particular, foi utilizado o algoritmo de *Levenberg-Marquardt*, bastante veloz e eficiente se aplicado em RNA's *backpropagation* destinadas a ajuste de funções.⁽⁴⁾

2.2 Processos e Variáveis da Laminação de Tiras a Quente

A Figura 4 mostra uma visão dos equipamentos, processos e produtos da Linha de Tiras a Quente 1 da Usiminas Unidade Cubatão.

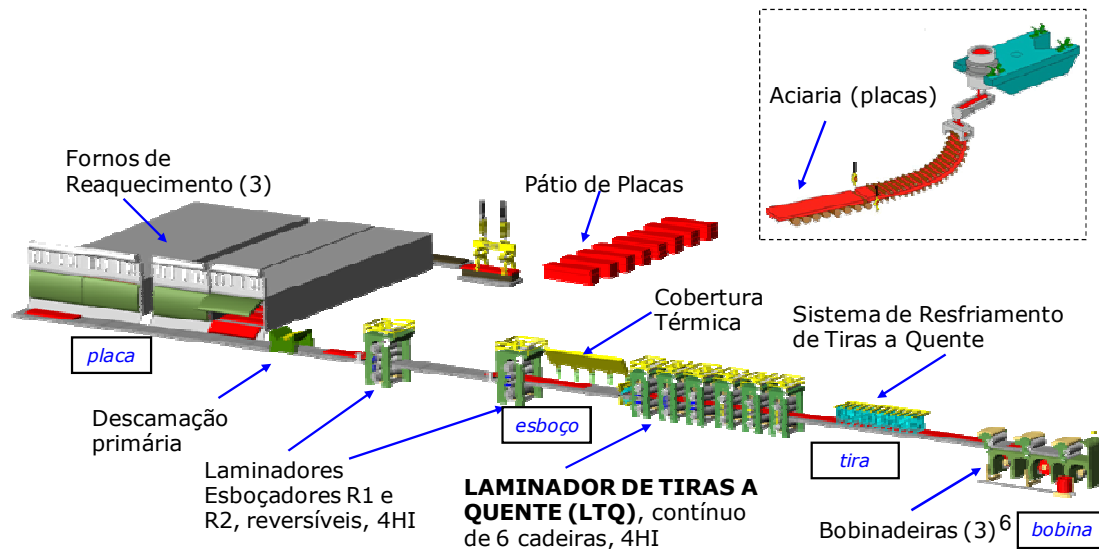


Figura 4. Fluxo de equipamentos, processos e produtos da Laminação de Tiras a Quente 1 da Usiminas Unidade Cubatão.

Placas recebidas do processo anterior da aciaria são aquecidas em fornos de reaquecimento sendo então descarregadas para uma laminação de desbaste ou esboçamento, preparatória para a laminação de tiras a quente, num LTQ de 6 cadeiras quádruas. A seguir a tira resultante é resfriada e logo a seguir enroladas em bobinadeiras.

O produto resultante são bobinas de tiras a quente, destinadas a várias rotas, desde a de produto já acabado para entrega ao cliente, como também para matéria prima de processos posteriores como os de decapagem, laminação de acabamento e laminação a frio.

É bastante vasta e extensa a bibliografia associada ao processo de laminação de tiras a quente⁽⁵⁻¹¹⁾ e foge ao escopo deste texto o seu detalhamento.

Assim, nesse trabalho, são consideradas de imediato as conhecidas relações de laminação sumarizadas na Figura 5, que mostra a definição da seleção de variáveis do processo de laminação que foram adotadas como variáveis de entrada da rede para cálculo da tensão de escoamento a quente, TEQ.

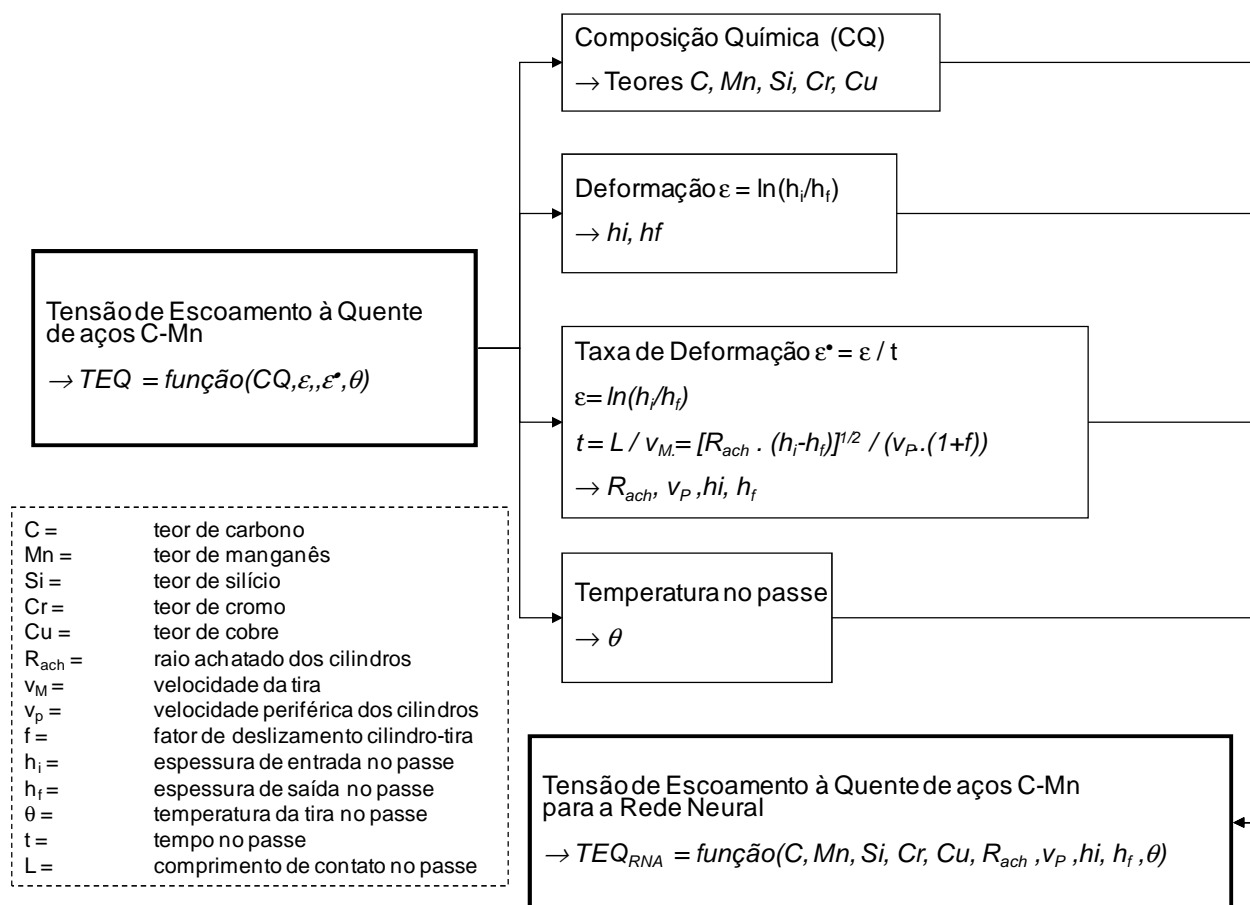


Figura 5. Esquema da seleção das variáveis de entrada (*inputs*) da RNA de TEQ, a partir de conceitos básicos do processo de laminação de tiras a quente.

Com relação à composição química do aço (CQ) deve ser lembrado o fato que na definição do tipo de aço C-Mn, elementos microligantes como o nióbio (Nb), titânio (Ti) e vanádio (V), altamente endurecedores a quente,^(12,13) foram limitados a baixos teores, tornando nula ou muito baixa sua influência. Além disso, aços ULC (*Ultra Low Carbon*), também foram desconsiderados na população alvo da análise.

Finalmente, cabe ressaltar que é visada a TEQ da tira na região de *set-up* (ponta inicial), fundamental para a determinação da previsão da velocidade e abertura entre cilindros de cada cadeira de laminação. Ela é a base para o cálculo da força de laminação, uma das variáveis mais importantes para o correto posicionamento (*gap*) dos cilindros e adequado fluxo de massa na mordida da tira em cada cadeira do LTQ, sendo a sua influência mostrada pela clássica equação: $Força = TEQ \cdot Largura \cdot \sqrt{R_{ach} \cdot (h_i - h_f)} \cdot Q$ (5), onde Q expressa um fator de correção que depende da teoria adotada.

2.3 Rede Neural da Tensão de Escoamento

Conforme mostrado anteriormente, pode-se transformar a relação funcional inicial de TEQ em outra mais conveniente para a definição de entradas da RNA, conforme abaixo mostrado:

$$TEQ = função(CQ, \varepsilon, \varepsilon, \theta) \rightarrow TEQ_{RNA} = função(C, Mn, Si, Cr, Mn, R_{ach}, v_p, h_i, h_f, \theta) \dots(6)$$

Após varias tentativas foi definida arquitetura de rede mostrada na Figura 6, de 10 variáveis de entrada, 49 neurônios, 49 bias, 688 pesos, e uma saída que é a variável de TEQ.

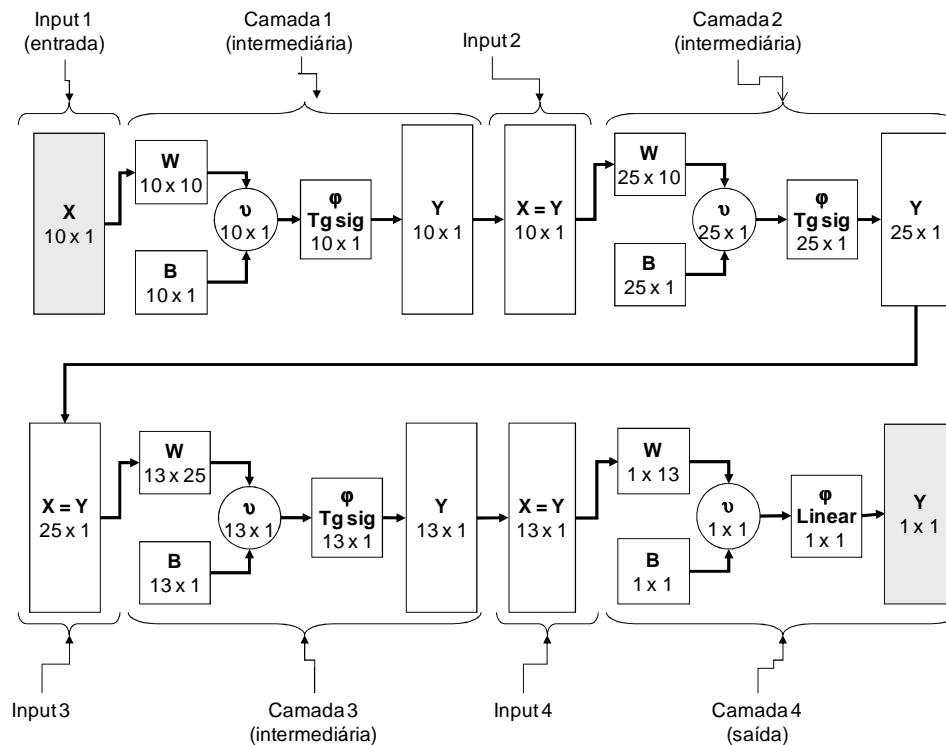


Figura 6. Diagrama de blocos da arquitetura da RNA *MFB* (*Multilayer, Feedforward, Backpropagation*) utilizada para previsão da TEQ

O algoritmo de treinamento utilizado foi o de *Levenberg-Marquadt*, adequado a redes de pequeno a médio porte ⁽³⁾. A TEQ utilizada como real, *target* no treinamento da RNA, foi a TEQ calculada pelo modelo de set-up com base em variáveis medidas como as de força e velocidades reais. A quantidade total de bobinas com laminação avaliada foi de 7472, com dados disponíveis em novembro-2007, logo após a necessária implantação de um novo servidor de banco de dados de processo do laminador.

2.3.1 Obtenção prévia da temperatura do passe e do raio achatado de cilindros

Entre as variáveis de entrada selecionadas, duas são de obtenção mais complexa e sofisticada: a temperatura da tira no passe de laminação e o raio achatado dos cilindros. No caso da temperatura, o cálculo requer prévio conhecimento de mecanismos de transferência de calor mais ou menos complexos, enquanto que o achatamento elástico dos cilindros acaba por ser um procedimento recursivo uma vez que depende da força de laminação que por sua vez depende da TEQ, que afinal é a variável a ser obtida pela RNA.

Assim, para manter a entrada de dados num nível de obtenção simples, para essas duas variáveis foram desenvolvidos modelos empíricos, por regressão múltipla, conforme descritos a seguir.

Para a temperatura no passe ($r = 0.981$; erro padrão = 5.6 °C):

$$[T_{EP}]_{Cad} = \left[k_1 \cdot \left(258.50 - 16.145 \cdot Cad + 3.0524 \cdot Esp + \dots \right. \right. \\ \left. \left. \dots 0.54147 \cdot TE + 017151 \cdot TA + 0.018570 \cdot v_{p6} \right) + k_2 \right]_{Cad} \cong [T_{RP}]_{Cad} \dots(7)$$

$[T_{EP}]_{Cad}$ = temperatura estimada do material no passe de laminação na cadeira Cad (°C)

Cad = 1...6 = número da cadeira do LTQ

Esp = espessura final da tira na saída do laminador (mm)

TE = temperatura do esboço na entrada no laminador (°C)

TA = temperatura da tira na saída do laminador (°C)

v_{p6} = velocidade periférica do cilindro de trabalho da última cadeira (mpm)

k_1, k_2 = parâmetros de ajuste em função da cadeira, conforme abaixo:

Para o raio achatado de cilindros ($r = 0.965$; erro padrão = 11 mm):

$$[X]_{Cad} = \left[\begin{array}{l} a_0 + a_1 \cdot Cad + a_2 \cdot Esp + a_3 \cdot Larg + \dots \\ \dots a_4 \cdot C + a_5 \cdot Mn + a_6 \cdot Si + a_7 \cdot Cu + a_8 \cdot Cr + \dots \\ \dots a_9 \cdot T_{RP} + a_{10} \cdot D_{wr} + a_{11} \cdot h_i + a_{12} \cdot h_f + a_{13} \cdot v_p \end{array} \right]_{Cad} \rightarrow \dots(8)$$

$$\rightarrow [R_{ach}]_{Cad} = [u_0 + u_1 \cdot X + u_2 \cdot X^2]_{Cad} \cong [R_{ach-R}]_{Cad} \dots(9)$$

$[R_{ach}]_{Cad}$ = raio achatado estimado dos cilindros de trabalho da cadeira Cad (mm)

Cad = 1...6 = número da cadeira do LTQ

$[X]_{Cad}$ = parâmetro intermediário do cálculo (mm)

Esp = espessura final da tira na saída do laminador (mm)

Larg = largura final da tira na saída do laminador (mm)

C = teor de carbono do aço da tira laminada (%)

Mn = teor de manganês do aço da tira laminada (%)

Si = teor de silício do aço da tira laminada (%)

Cr = teor de cromo do aço da tira laminada (%)

Cu = teor de cobre do aço da tira laminada (%)

T_{RP} = temperatura real da tira no passe de laminação (°C) (*)

D_{wr} = diâmetro médio dos cilindros de trabalho da cadeira (mm)

3 RESULTADOS DA REDE NEURAL DA TENSÃO DE ESCOAMENTO

Na Figura 7, como exemplos são mostrados os resultados de desvio relativo em relação à TEQ_{REAL} da TEQ_{SU} , calculada pelo atual modelo de set-up do LTQ (FSU), e os respectivos resultados da TEQ_{RNA} obtidas pela RNA MFB.

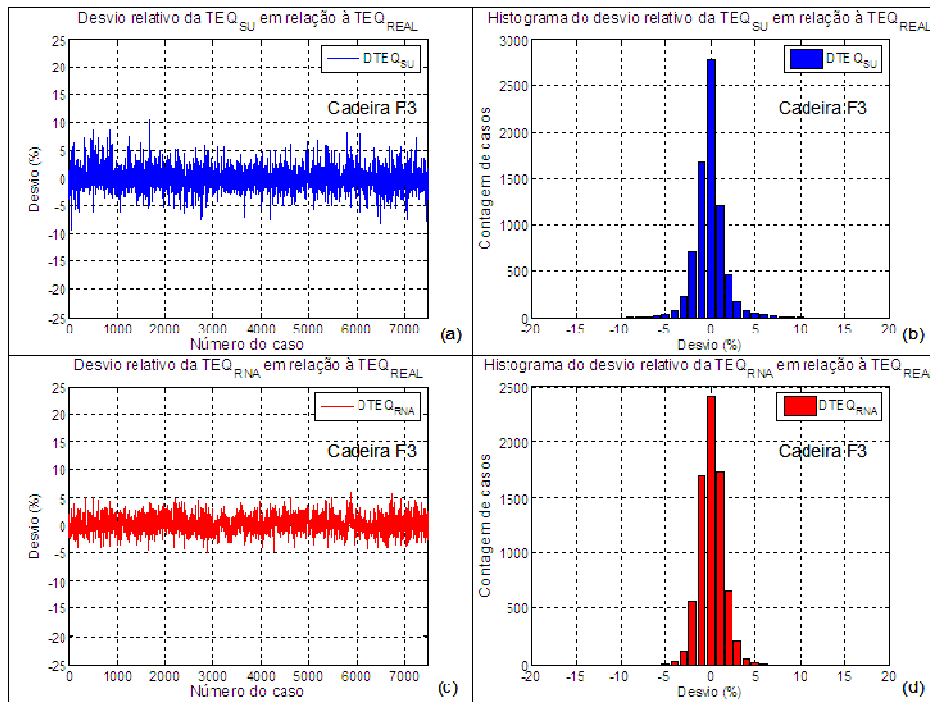


Figura 7. Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F3 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.

A Figura 8 mostra para a mesma cadeira F3 o ajuste entre a TEQ_{REAL} e a TEQ_{RNA}

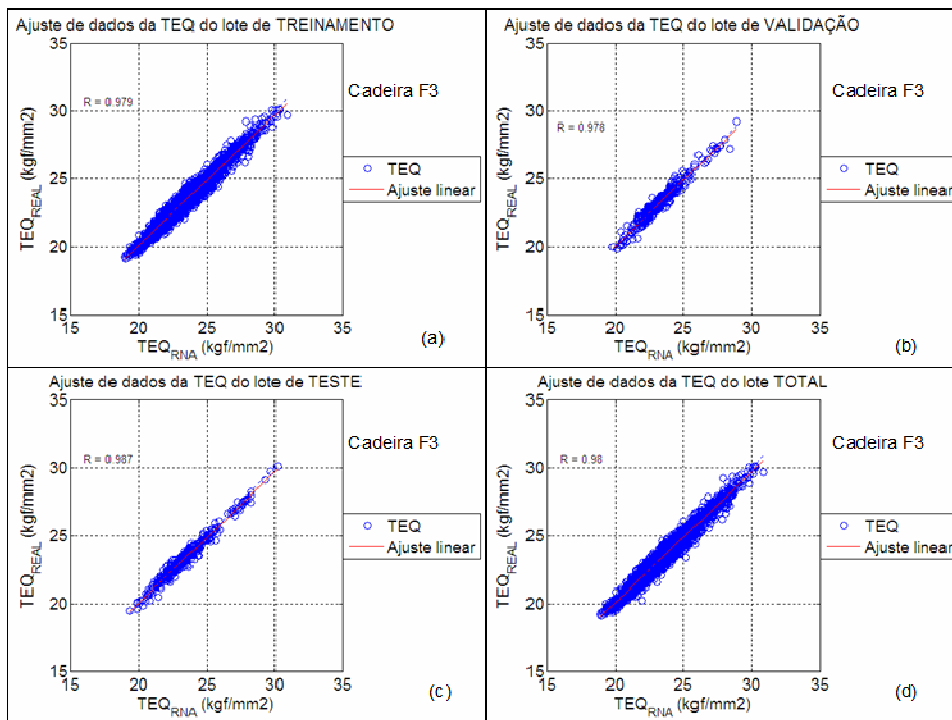


Figura 8. Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento +validação+ teste).

Os procedimentos descritos conduziram a um bom ajuste no resultado das RNA's de TEQ para todas as cadeiras do LTQ, com resultado mais preciso do que o da TEQ calculada pelo atual modelo de *set-up* (FSU) para todas as cadeiras do LTQ. Isto é evidenciado na Tabela 1, que traz o resumo dos dados de precisão tanto da TEQ_{SU} , como da TEQ_{RNA} , além do resultado do ajuste da TEQ_{REAL} em relação à TEQ_{RNA} , para cada cadeira do LTQ.

Tabela 1. Resumo da precisão da TEQ_{SU} e TEQ_{RNA} e do ajuste com a TEQ_{REAL}

TEQ	Parâmetro	F1	F2	F3	F4	F5	F6	Unidade
Modelo de set-up (FSU)	Desvio Médio (FSU)	0.65	0.27	0.14	0.23	0.23	0.40	(%)
	DP (FSU)	1.25	1.38	1.53	1.66	2.02	2.42	(%)
RNA	Desvio Médio (RNA)	0.01	0.04	-0.07	0.00	0.03	0.01	(%)
	DP (RNA)	0.98	1.23	1.29	1.05	1.60	1.85	(%)
Ajuste TEQ Real RNA	Número de épocas	38	28	51	23	48	55	-----
	MSE (erro médio quadrático) (lote de treinamento)	0.032	0.066	0.088	0.109	0.155	0.190	(Kgf/mm ²) ²
	Correlação linear (lote total)	0.984	0.979	0.980	0.977	0.985	0.990	-----
	Erro padrão da estimativa (lote total)	0.186	0.259	0.300	0.344	0.404	0.435	Kgf/mm ²

Notas : DP = desvio padrão dos desvios relativos ; MSE = mean square error; 7472 bobinas

O grau de ajuste pode ser considerado bom, com coeficiente de correlação linear entre a TEQ_{RNA} e a TEQ_{REAL} acima de 0.975 em todas as cadeiras.

Também o desvio ou erro relativo médio da TEQ_{RNA} é menor em todas as cadeiras, comparado ao desvio relativo médio da TEQ_{SU} , sendo em média 99% inferior. A dispersão dos desvios relativos da TEQ_{RNA} em torno do desvio médio também é inferior em todas as cadeiras, sendo na média 22% menor.

4 CONCLUSÕES

O resultado da TEQ obtida pela RNA *MFB*, de 4 camadas de neurônios e 737 parâmetros livres (pesos e *bias*), apresenta para todas as cadeiras uma precisão de acerto superior à do atual modelo de *set-up* do LTQ. A generalização desse resultado é bastante adequada considerando o grau de ajuste obtido para os lotes de treinamento, validação, teste e total.

Foram evitados cálculos complexos e recursivos, como os utilizados pelo modelo de *set-up*, nos modelos alternativos para a estimação da temperatura da tira no passe de laminação (T_{EP}), e do raio achatado de cilindros (R_{ach}), mantendo-se essas variáveis de entrada da RNA de TEQ funções diretas de variáveis primárias, de fácil obtenção.

A partir dos resultados e metodologia empregados, é possível estender a aplicação de RNA's para cálculo da TEQ também para outros tipos de aços além dos C-Mn abordados nesse trabalho.

REFERÊNCIAS

- 1 HAYKIN, SIMON. **Redes Neurais Princípios e Práticas**. Tradução de Paulo Martins Engel. 2ª edição. Porto Alegre: Editora Bookman, 2001, 900 p.
- 2 TAKAHASHI, HIROSHI JORGE. **Predição de Propriedades Mecânicas de Aços de Alta Resistência Microligados Utilizando Técnicas de Inteligência Computacional**. Coronel Fabriciano: Dissertação de Mestrado em Engenharia Industrial, Unileste MG, Dezembro de 2006, 107p.
- 3 LUDWIG JR., OSWALDO; MONTGOMERY, EDUARD. **Redes Neurais Fundamentos e Aplicações em C**. Rio de Janeiro: Editora Ciência Moderna, 2007, 125 p.
- 4 DEMUTH, HOWARD; BEALE, MARK; HAGAN, MARTIN. **Neural Toolbox 5 User's Guide – MatLab**. Editora Mathworks, inc, www.matwoks.com, Setembro de 2007.
- 5 BRANCO, VANESSA PALA VIEIRA **Análise Crítica do Setor de Resfriamento de Chapas Laminadas a Quente do Aço LN28**. São Paulo: Dissertação de Mestrado em Engenharia Metalúrgica, USP – SP, 2004, 128 p.
- 6 GINZBURG, VLADIMIR B. **Steel Rolling Technology**. New York : Editora Marcel Dekker, volume 30 de Manufacturing Engineering and Materials Processing, 1989, 791 p.
- 7 PLAUT, RONALD LESLEY. **Laminação dos Aços – Tópicos Avançados**. São Paulo: Editora da ABM Livros, 1986, 180 p.
- 8 MISAKA, YOSHISUKE; YOSHIMOTO, TOMOSKICHI. **Formularization of Mean Resistance to Deformation of Plain Carbon Steels at Elevated Temperature**. Journal of the Japan Society for Thechnology of Plasticity, 1967, v. 8, no. 79, p. 414.
- 9 SHIDA, SHIGERU. **Empirical Formula of Flow-Stress of Carbon Steels – Resistance to Deformation of Carbon Steels at Elevated Temperature**. Journal of the Japan Society for Thechnology of Plasticity, 1969, v. 10, no. 103, p. 610-617.
- 10 TSELIKOV, A. **Stress and Strain in Metal Rolling**. Moscou: Editora MIR Publishers, 1967, 475 p.
- 11 TSELIKOV, A.; NIKITIN, G. S.; ROKOTYAN, S. E. **The Theory of Lengthwise Rolling**. Editora MIR Publishers, 1980, 342 p.
- 12 GORNI, A. A.; DOLABELA, J. H.; VALLIM, PEDRO S. S.; et al. **Modelamento Matemático do Efeito dos Elementos de Liga dos Aços na Resistência à Deformação a Quente**. Belo Horizonte: 56º Congresso Anual da ABM, Julho de 2001.
- 13 GORNI, A. A.; VALLIM, PEDRO S. S. **Efeito da Composição Química na Resistência à Deformação a Quente de Aços de Baixo Carbono**. São Paulo: 59º Congresso Anual da ABM, Julho de 2004.
- 14 BAPARI, AFSHIN; et al. **Prediction of Hot Flow Stress of CrMoV Steel Using Artificial Neural Network (ANN)**. ISIJ International, v. 47, 2007, no. 8, p. 1126-1130.
- 15 DENTI Fº, JOSÉ; MACHADO, MARCELO LUCAS P. **Modelo Microestrutural de Tamanho de Grão, Cálculo de Tensão de Escoamento Média e Força de Laminação de Aços Carbono e Ligas**. Campos do Jordão: 44º Seminário de Laminação – Processos e Produtos Laminados e Revestidos da ABM, Outubro de 2007.
- 16 GARSON, G. **Intepreting Neural-Network Connection Weighths**. AI Expert, April 1991, p. 47-51.
- 17 HWU, Y. J.; LENARD, J. G. **Application of Neural Networks in the Prediction of Roll Force in Hot Rolling**. Department of Mechanical Engineering of the University of Waterloo, Ontario: Transaction of North American Manufacturing Resarch Institute/Society of Mechanical Engineering, [1995-2002], p. 85-90.
- 18 LU, CHENG; WANG, XIUMEY; et al. **Application of ANN in Combination with Mathematical Models in Prediction Load of the Finishing Stands in HSM**. ISIJ: Proccedings of the 7th International Conference on Steel Rolling, 1998, p. 206-209.