

APLICAÇÃO DE REDES NEURAIS NO MODELAGEM MATEMÁTICA DE PROPRIEDADES MECÂNICAS DE BOBINAS A QUENTE¹

Antonio Augusto Gorni²
Marcos Roberto Soares da Silva³
José Herbert Dolabela da Silveira⁴

Resumo

Foram desenvolvidas neste trabalho redes neurais para o cálculo de propriedades mecânicas de bobinas a quente de aços ao C-Mn e microligados a partir de sua composição química e dos parâmetros de laminação. A precisão desses modelos ficou num nível intermediário entre a conseguida por equações lineares e a de modelos comerciais (VAIQ-Strip), representando portanto uma alternativa balanceada entre precisão preditiva e esforço requerido para seu desenvolvimento.

Palavras-chave: Bobina a quente; Processo; Propriedade mecânica; Rede neural.

APPLICATION OF NEURAL NETWORKS IN THE MATHEMATICAL MODELLING OF MECHANICAL PROPERTIES OF HOT COILS

Abstract

Neural networks were developed in this work to calculate mechanical properties of hot coils of C-Mn and microalloyed steels from their chemical composition and rolling process data. The precision achieved by such models was between that got by linear equations and by commercial models (VAIQ-Strip). So the neural networks approach is a balanced alternative between performance and effort required for model development.

Key words: Hot coil; Process; Mechanical property; Neural network.

¹ Contribuição técnica ao 45º Seminário de Laminação – Processos e Produtos Laminados e Revestidos, 21 a 24 de outubro de 2008, Ipojuca - Porto de Gainhas - PE

² Membro da ABM. Engenheiro de Materiais, M. Eng., Dr. Eng., Analista de Processos da Gerência de Suporte Técnico da Laminação a Quente, Companhia Siderúrgica Paulista – Cosipa, Cubatão SP. E-Mail: gorni@cosipa.com.br.

³ Membro da ABM. Engenheiro Metalurgista, M.B.A., C.Q.E., Analista de Processos da Gerência de Suporte Técnico da Laminação a Quente, Companhia Siderúrgica Paulista – Cosipa, Cubatão SP. E-Mail: marcosilva@cosipa.com.br.

⁴ Membro da ABM. Engenheiro Metalurgista, Mestre em Engenharia, M.B.A. No momento da realização do trabalho: Gerente de Suporte Técnico da Laminação a Quente, Companhia Siderúrgica Paulista – Cosipa, Cubatão SP. E-Mail: herbert.silveira@gerdau.com.br.

1 INTRODUÇÃO

Os trabalhos de pesquisa visando o estabelecimento de correlações entre composição química, microestrutura, parâmetros de processo de laminação a quente e propriedades mecânicas dos laminados vêm sendo feitos há várias décadas. Todo esse esforço embasou o desenvolvimento de diversos modelos matemáticos que podem prever, de forma precisa, microestruturas e propriedades mecânicas de laminados a quente, como é o caso do VAIQ-Strip.⁽¹⁾

Esses cálculos das propriedades mecânicas de laminados a quente geralmente possuem grande complexidade, já que é necessário modelar os fenômenos metalúrgicos que ocorrem no material ao longo da linha de laminação, como o crescimento de tamanho de grão austenítico e solubilização de precipitados no forno de reaquecimento de placas, a evolução do tamanho de grão austenítico ao longo do laminador de tiras a quente e a cinética de transformação austenítica durante a passagem pela mesa de resfriamento e o resfriamento lento da bobina. Uma vez definida a microestrutura final é necessário estabelecer as correlações entre ela e as propriedades mecânicas finais da bobina. Em modelos mais complexos também se modela a evolução de temperatura ao longo da espessura e largura do material. Além disso, devem ser realizadas experiências em laboratório ou mesmo em escala industrial para se determinar parâmetros quantitativos vitais para o ajuste do modelo ou aferição de seus resultados.

Como se pode observar, o desenvolvimento de tais modelos requer um esforço enorme que demanda muitos recursos técnicos e humanos, além de vários anos de desenvolvimento, implicando num custo financeiro que pode se tornar proibitivo. Contudo, é possível adotar abordagens alternativas que permitem o desenvolvimento de modelos preditivos para propriedades mecânicas a custos mais acessíveis, ainda que não sejam tão precisos.

Uma delas é o desenvolvimento de modelos baseados em regressões lineares múltiplas, assumindo-se a premissa de que as relações entre as propriedades mecânicas, composição química do aço e parâmetros do processo de laminação a tiras a quente podem ser consideradas como sendo lineares, uma vez que a amplitude das variáveis envolvidas geralmente é estreita e específica para cada usina.⁽²⁻⁵⁾

Por outro lado, essa premissa pode ser questionada, uma vez que os fenômenos metalúrgicos afetam as propriedades mecânicas da tira durante o processo de laminação são muito complicados devido ao grande número de fatores envolvidos. As relações entre esses fatores podem ser não-lineares, além de haver interações entre variáveis independentes. O modelamento envolvendo massas de dados com essas características pode ser implementado com maior eficiência e precisão usando-se redes neurais artificiais, ou seja, algoritmos matemáticos que simulam o comportamento de sistemas nervosos biológicos. Eles possuem capacidade de “aprender” as conexões entre as variáveis de conjuntos de dados sem conhecer previamente as relações formais entre eles. Em compensação, é necessário muito cuidado na seleção dos dados a serem considerados durante o processo de aprendizado da rede neural, pois esta extrai seu conhecimento somente a partir deles, não dispondo de qualquer modelo prévio para guiar ou criticar sua resposta.

O uso de redes neurais no modelamento de processos de laminação a quente não chega a ser exatamente uma novidade, já que as primeiras tentativas bem sucedidas nesse sentido têm mais de quinze anos.⁽⁶⁾ O modelamento de propriedades mecânicas de bobinas laminadas a quente a partir de sua composição química e parâmetros de processo de laminação usando redes neurais é um tema já abordado

na literatura.⁽⁷⁻⁹⁾ Portanto, o objetivo desse trabalho foi verificar o desempenho dessa metodologia matemática para a previsão das propriedades mecânicas de bobinas a quente a partir de sua composição química e parâmetros de processo da laminação de tiras a quente para as condições específicas da Cosipa.

2 PROCEDIMENTO EXPERIMENTAL

Os dados necessários para este trabalho foram obtidos a partir de materiais processados no laminador de tiras a quente da Cosipa ao longo de um período de dois anos. Os dados relativos a aços C-Mn foram selecionados impondo-se as seguintes limitações nos teores de elementos de liga: $C \leq 0,25\%$; $Mn \leq 1,25\%$; $Si \leq 0,35\%$; $Cu, Cr, Mo, Ni \leq 0,09\%$; e $Nb, Ti, V \leq 0,009\%$. Também foram selecionados dados para aços microligados dentro das seguintes limitações: $C \leq 0,25\%$; $Mn \leq 2,25\%$; $Si \leq 0,50\%$; $Cu, Cr \leq 0,99\%$; $Nb, Ti, V \geq 0,010\%$; $B \leq 0,001\%$; e $Mo \leq 0,09\%$. Essas limitações tiveram como objetivo selecionar materiais exclusivamente com microestrutura ferrítica-perlítica.

Os seguintes dados de processo foram coletados a partir do sistema supervisor do Laminador de Tiras a Quente:

- . Análise Química: no caso dos aços C-Mn, os teores de C, Mn, P, S, Si, Al e N. Já para os aços microligados foram considerados, além desses elementos, Cu, Cr, Nb, Ti e V.
- . Forno: número da fila e tempo de aquecimento da placa.
- . Espessuras: da placa, do esboço na saída da última cadeira de esboçamento (R2) e da bobina a quente.
- . Temperaturas: de entrada no trem acabador, de acabamento (TA) e de bobinamento (TB).
- . Velocidade da tira na saída do última cadeira do trem acabador (F6).

A partir desses dados de processo foram calculados os graus de deformação real total placa-tira (DefTot) e os aplicados nas fases de esboçamento e acabamento, bem como a taxa média de resfriamento entre a saída do trem acabador e o bobinamento do material (VelResf). As propriedades mecânicas de cada bobina a quente (limite de escoamento e de resistência, mais alongamento total) foram obtidos a partir da base de dados corporativa da usina. O ponto de referência para coleta e registro dos dados de processo da laminação de tiras a quente foi o local do esboço onde seria retirada a amostra a partir da qual são usinados os corpos de prova para os ensaios mecânicos. Dessa forma se garante a correta associação entre os valores dos parâmetros de processo e os das propriedades determinadas experimentalmente.

Os dados assim obtidos foram analisados estatisticamente para se detectar bobinas atípicas, seja por condições de processo fora do especificado ou por problemas na instrumentação que levaram a falhas ou erros nos valores medidos. A análise dos chamados *outliers* constou de levantamento de histogramas e *boxplots*, bem como da aplicação dos critérios multidimensionais de Mahalanobis e Cook. Ao final dessa depuração foram definidos os conjuntos finais para as análises de correlação, os quais eram constituídos de 5.456 bobinas a quente para aços C-Mn e 2.847 bobinas a quente para aços microligados.

Optou-se aqui por se usar redes neurais com arquitetura do tipo *feed forward* com camada de entrada, uma camada oculta e camada de saída. A camada de entrada era constituída de neurônios associados às variáveis independentes, enquanto

que a camada de saída era constituída de neurônios associados às variáveis dependentes. O número de neurônios da camada oculta foi calculado conforme o teorema de Hecht-Kolmogorov,⁽¹⁰⁾ ou seja, ele é igual ao dobro do número de neurônios da camada de entrada mais um. A função de ativação usada nos neurônios da camada oculta foi tangente sigmoïdal, enquanto que a da camada de saída foi linear. Todos os neurônios da rede neural estavam ligados a um neurônio de *bias*.

Tentativas preliminares mostraram que se conseguia maior precisão preditiva modelando-se simultaneamente as quatro variáveis dependentes (limite de escoamento, limite de resistência, razão elástica e alongamento total) na mesma rede neural do que quando se criava uma rede específica para cada propriedade mecânica. Essa abordagem, já consagrada na literatura,⁽⁷⁻⁹⁾ é de fato mais eficiente, pois a presença das quatro variáveis dependentes na rede neural intensifica as correlações existentes entre elas e as variáveis independentes.

O algoritmo usado para o aprendizado foi o de Levenberg-Marquardt. Foram reservados 60% dos dados disponíveis, escolhidos aleatoriamente, para serem usados durante a fase de aprendizado da rede neural. A fase de teste periódico da rede neural sob treinamento foi feita usando-se outros 20% dos dados disponíveis. O treinamento da rede terminava quando se atingia valor mínimo de erro na fase de teste. Procedia-se então à fase de validação, calculando-se então o coeficiente de correlação r e o erro padrão da estimativa para a rede treinada usando-se os restantes 20% de dados disponíveis. Todos os procedimentos associados às redes neurais foram feitos usando-se uma versão de demonstração do programa *NeuroSolutions*.

A análise da importância das variáveis independentes selecionadas para as redes neurais treinadas foi feita através do cálculo do nível de relevância estatística e da análise de sensibilidade.

O nível de relevância estatística foi calculado da seguinte forma:⁽¹¹⁾ a variável independente i em questão assume valor constante (por exemplo, seu valor médio) para todos os registros do conjunto de dados, calculando-se então o erro padrão da estimativa ($EPE_{x_i=\bar{x}_i}$) correspondente à execução da rede neural treinada a partir desse conjunto de dados modificado. Quanto maior for o valor do erro padrão da estimativa assim calculado, maior a relevância estatística da variável i em questão, pois constata-se nesse caso que sua neutralização (ou seja, o fato dela assumir valor constante) aumentou o erro da previsão cometido pela rede neural treinada.

É possível quantificar esse nível de relevância estatística REL_i dividindo-se $EPE_{x_i=\bar{x}_i}$ pelo erro padrão da estimativa da rede neural original, EPE :

$$REL_i = \frac{EPE_{x_i=\bar{x}_i}}{EPE} \quad (1)$$

Portanto, quando REL_i for próximo ou inferior a um, a variável pode ser considerada como tendo efeito desprezível, podendo-se propor sua eliminação da rede neural.

A partir daí pode-se calcular o nível de relevância estatística normalizado para a variável independente i , $RELNORM_i$, partindo-se do princípio de que a contribuição relevante para a precisão da rede neural de cada variável independente corresponde ao valor de REL_i menos um. Ou seja:

$$RELNORM_i = \frac{(REL_i - 1)}{\sum_{j=1}^n (REL_j - 1)} \quad (2)$$

onde n é o número total de variáveis independentes na rede neural em análise.

A análise de sensibilidade é feita selecionando-se uma variável independente por vez, duplicando-se então os registros da massa de dados. A variável escolhida assume seu valor original num dos registros e sofre acréscimo de 5% no registro-duplicata.⁽¹⁰⁾ São calculados os valores das variáveis dependentes para esse conjunto de dados modificado usando-se a rede neural treinada e, a seguir, calculada a diferença entre os valores dessas variáveis de cada registro original e do correspondente registro-duplicata onde a variável independente selecionada recebeu acréscimo de 5%. Finalmente, determinou-se a média dessas diferenças ao longo de todo o conjunto de dados, obtendo-se então a sensibilidade média ($SENS_i$) da variável em questão. Quanto maior for essa diferença média, maior o efeito da variável independente considerada. Pode-se também propor o cálculo da sensibilidade média normalizada ($SENSNORM_i$) para a variável independente i , através da seguinte fórmula:

$$SENSNORM_i = \frac{SENS_i}{\sum_{i=1}^n |SENS_i|} \quad (3)$$

Este tipo de análise apresenta a vantagem de mostrar o sentido do efeito da variável independente, ou seja, se sua elevação leva a um aumento ou declínio nas variáveis dependentes.

3 RESULTADOS E DISCUSSÃO

3.1 Aços ao C-Mn

Inicialmente foi proposta uma rede neural onde foram incluídas como variáveis de entrada todos os parâmetros considerados relevantes do ponto de vista metalúrgico, ou seja: teores de C, Mn, P, S, Si e N; DefTot, TA, VelResf e TB. Os tempos de enformamento das placas não apresentaram relevância estatística neste caso⁵. Logo, a camada de entrada da rede neural tinha dez neurônios, implicando, pelo teorema de Hecht-Kolmogorov, numa camada oculta com 21 neurônios. A camada de saída, naturalmente, tinha quatro neurônios, correspondentes ao limite de escoamento, limite de resistência, razão elástica e alongamento total. Foram obtidos os seguintes resultados em termos de precisão do modelo e classificação de variáveis independentes, conforme o nível de significância estatístico normalizado e a análise de sensibilidade:

- **Limite de Escoamento:**

- . Precisão: $r = 0,70$; EPE = 26 MPa.
- . RELNORM: DefTot (26%), Mn (23%), VelResf (22%), Si (13%), TB (10%), Demais (6%).
- . SENSNORM: TA (+3,8%), TB (-3,0%), DefTot (+3,0%), Mn (+1,0%), C (+0,5%).

- **Limite de Resistência:**
 - . Precisão: $r = 0,88$; EPE = 16 MPa.
 - . RELNORM: Mn (37%), C (19%), Si (17%), VelResf (11%), DefTot (9%), Demais (7%).
 - . SENSNORM: TB (-0,8%), C (+0,8%), TA (+0,8%), Mn (+0,7%), DefTot (+0,5%).
- **Razão Elástica:**
 - . Precisão: $r = 0,60$; EPE = 0,05.
 - . RELNORM: DefTot (29%), VelResf (29%), Si (12%), TB (10%), C (10%), Mn (8%), Demais (2%).
 - . SENSNORM: TA (+2,9%), DefTot (+2,4%), TB (-2,1%).
- **Alongamento Total:**
 - . Precisão: $r = 0,56$; EPE = 5%.
 - . RELNORM: DefTot (15%), Si (15%), VelResf (13%), C (13%), Mn (10%), S (8%), TB (8%), Demais (18%).
 - . SENSNORM: DefTot (+2,0%), C (-1,3%), Mn (-0,7%), VelResf (+0,5%).

Como já era esperado, essa rede neural, bem como as demais apresentadas neste trabalho, apresentou desempenho decrescente na seqüência limite de resistência → limite de escoamento → alongamento total, fato que aparentemente reflete os erros experimentais associados à medição dessas propriedades mecânicas⁸. Além disso, não foi possível comparar o desempenho dessa rede neural com o de uma regressão linear múltipla análoga, já que o alto nível de correlação entre as variáveis independentes impede o cálculo dos coeficientes da equação linear em virtude do surgimento de matrizes mal-condicionadas.

A classificação de variáveis de acordo com o nível de significância estatístico normalizado apresentou coerência com a teoria metalúrgica. De acordo com esta rede neural, o endurecimento por refino de grão foi bastante significativo para a definição do limite de escoamento, já que DefTot e VelResf são respectivamente a primeira e terceira variável mais significativas neste caso, com TB ocupando a quinta posição. O endurecimento por solução sólida também é importante, com Mn e Si ocupando respectivamente a segunda e quarta posições. Já no caso do limite de resistência a composição química é mais importante, atuando preponderantemente através de endurecimento por solução sólida, com Mn e Si ocupando primeiro e terceiro lugar, respectivamente; e através da fração de perlita na microestrutura, com C em segundo lugar. Neste caso VelResf e DefTot ocuparam os últimos lugares entre as variáveis significativas. A razão elástica e alongamento total apresentaram situação similar à do limite de escoamento. Note-se a presença do S entre as variáveis significativas para o alongamento total, o que parece refletir o efeito da limpeza inclusonária sobre a ductilidade do aço.

Já a classificação de variáveis de acordo com a análise de sensibilidade confirmou, na maioria dos casos, essas mesmas constatações. Note-se, por exemplo, o efeito negativo de C e Mn sobre o alongamento total, que aparentemente refletem o efeito deletério sobre a ductilidade decorrente de maiores frações de perlita na microestrutura. Contudo, esta metodologia de análise apresentou alguns resultados inesperados. Por exemplo, constatou-se que TA é uma variável significativa para o limite de escoamento, de resistência e razão elástica, e que sua elevação levaria a aumento no valor dessas propriedades. Contudo, conforme a teoria metalúrgica, o aumento na temperatura de acabamento deveria levar a aumento no tamanho de grão e a uma correspondente redução nos limites de escoamento e resistência, bem

como na razão elástica¹². O efeito positivo de DefTot e VelResf sobre o alongamento total parece indicar que o refino de tamanho de grão no material produzido pela elevação desses parâmetros tende a aumentar sua ductilidade, uma relação proposta nas equações de Pickering¹³ mas questionada por Morrison¹⁴. Este ponto somente poderá ser esclarecido através de uma investigação experimental adicional.

Em função desses resultados potencialmente inconsistentes decidiu-se então verificar o desempenho de uma rede neural que incluísse entre suas variáveis de entrada apenas variáveis selecionadas através de regressão múltipla linear *stepwise*⁵. Elas foram C, Mn, S, Si, N^{1/2}, DefTot^{-1/2} e TB. Obteve-se portanto uma rede neural do tipo 7 x 15 x 4, a qual apresentou os seguintes resultados:

- **Limite de Escoamento:**
 - . Precisão: $r = 0,68$; EPE = 27 MPa.
 - . RELNORM: Mn (50%), DefTot^{-1/2} (14%), Si (12%), TB (12%), C (10%), Demais (2%).
 - . SENSNORM: TB (-2,1%), DefTot^{-1/2} (-2,0%), Mn (+0,9%).
- **Limite de Resistência:**
 - . Precisão: $r = 0,87$; EPE = 16 MPa.
 - . RELNORM: Mn (49%), C (20%), Si (11%), DefTot^{-1/2} (9%), TB (7%), Demais (4%).
 - . SENSNORM: DefTot^{-1/2} (-1,0%), Mn (+0,7%), C (+0,7%), TB (-0,5%).
- **Razão Elástica:**
 - . Precisão: $r = 0,57$; EPE = 0,05.
 - . RELNORM: C (31%), Mn (26%), Si (16%), DefTot^{-1/2} (16%), TB (11%).
 - . SENSNORM: TB (-1,6%), DefTot^{-1/2} (-1,0%).
- **Alongamento Total:**
 - . Precisão: $r = 0,50$; EPE = 5%.
 - . RELNORM: Mn (29%), Si (29%), DefTot (21%), C (14%), TB (7%).
 - . SENSNORM: DefTot^{-1/2} (+3,6%), TB (-2,2%), C (-1,5%), Mn (+0,7%).

A eliminação de três variáveis pouco afetou a precisão obtida em relação à rede neural anterior, tendo sido observada ligeira degradação apenas no caso do limite de escoamento. É interessante notar que, ainda assim, esta rede neural apresentou melhor precisão para o cálculo dos limites de escoamento e resistência em relação ao conseguido pela regressão linear múltipla *stepwise* onde se obteve, respectivamente, $r = 0,61$ /EPE = 30 MPa e $r = 0,82$ /EPE = 17 MPa,⁽⁵⁾ conforme já era esperado.⁽⁷⁻⁹⁾ Contudo, verificou-se pouca ou nenhuma melhoria na precisão preditiva para a razão elástica e alongamento total, tendo sido conseguido no caso da regressão linear múltipla *stepwise*, respectivamente, $r = 0,47$ /EPE = 0,05 e $r = 0,50$ /EPE = 5%⁵. Este fato pode ser atribuído aos maiores erros experimentais associados à determinação dessas últimas propriedades mecânicas.

É curioso notar que a análise pelo nível de significância estatística mostrou que, neste caso, a composição química do aço apresentou maior relevância em relação aos parâmetros de processo da laminação a quente. Por outro lado, não se verificou efeito apreciável do N sobre a precisão dos valores calculados das propriedades mecânicas, ao contrário do que havia sido observado na regressão múltipla linear *stepwise*.⁽⁸⁾

Já a análise de sensibilidade das variáveis independentes manteve a mesma situação observada na rede neural anterior, ou seja, maior efeito dos parâmetros de processo da laminação de tiras a quente em relação ao observado para os elementos de liga. Ressalte-se que, neste caso, geralmente os efeitos das variáveis independentes foram metalurgicamente coerentes, fato que confirma a eliminação da

maioria dos efeitos de multicolinearidade. A única exceção foi a relação negativa entre TB e o alongamento total, um ponto passível de verificação experimental no futuro. Por outro lado, é estranho que, neste caso, a rede neural não considerou o teor de S importante para a previsão do alongamento total, ao contrário do verificado na regressão linear múltipla *stepwise*.

Finalmente, note-se que o programa VaiQ-Strip, adotado aqui como referência de *benchmarking*, conseguiu valores de erro padrão da estimativa para os limites de escoamento e resistência de aços C-Mn iguais a, respectivamente, 17 MPa e 9 MPa.⁽¹⁾ A precisão de cálculo das redes neurais aqui apresentadas foi inferior, 27 MPa e 16 MPa, respectivamente, mas seu desenvolvimento sem dúvida foi mais rápido e econômico do que o necessário para um modelo mais abrangente.

3.2 Aços microligados

Da mesma forma como ocorrido com os aços ao C-Mn, inicialmente foi proposta uma rede neural onde foram incluídas como variáveis de entrada todos os parâmetros considerados relevantes do ponto de vista metalúrgico, ou seja: teores de C, Mn, P, S, Si, Cu, Nb, Ti, V e N; DefTot, TA, VelResf e TB. Também aqui as variáveis associadas ao reaquecimento das placas não apresentaram relevância estatística⁵, apesar de seu papel fundamental na solubilização do Nb. Essa rede neural, com configuração 14 x 29 x 4, apresentou os seguintes resultados:

- **Limite de Escoamento:**
 - . Precisão: $r = 0,93$; EPE = 20 MPa.
 - . RELNORM: Nb (39%), Mn (12%), DefTot (12%), VelResf (10%), C (6%), Si (5%), Ti (4%), Cu (4%), TB (4%), Demais (4%).
 - . SENSNORM: TA (+5,4%), DefTot (+2,5%), TB (-1,8%), Mn (+0,6%), Nb (+0,5%).
- **Limite de Resistência:**
 - . Precisão: $r = 0,96$; EPE = 16 MPa.
 - . RELNORM: Nb (26%), Mn (17%), VelResf (14%), C (12%), DefTot (9%), Si (6%), Cu (5%), TB (4%), Ti (3%), Demais (4%).
 - . SENSNORM: TA (+5,7%), DefTot (+1,7%), TB (-1,4%), Mn (+0,6%), C (+0,5%), Nb (+0,3%).
- **Razão Elástica:**
 - . Precisão: $r = 0,65$; EPE = 0,03.
 - . RELNORM: Nb (35%), C (25%), DefTot (8%), Si (6%), Mn (5%), Cu (5%), Ti (5%), VelResf (5%), TB (3%), Demais (3%).
 - . SENSNORM: TA (-1,1%), DefTot (+0,6%), C (-0,5%), TB (-0,4%), Nb (+0,2%).
- **Alongamento Total:**
 - . Precisão: $r = 0,87$; EPE = 5%.
 - . RELNORM: C (30%), DefTot (19%), Mn (16%), VelResf (11%), Si (8%), Cu (8%), TB (4%), S (4%), Demais (18%).
 - . SENSNORM: TB (-4,8%), TA (-1,3%), DefTot (-0,9%), P (-0,6%), Nb (-0,3%).

Também neste caso não foi possível comparar o desempenho desta rede neural com a regressão linear múltipla equivalente em função das significativas correlações entre as variáveis de entrada, fato que impediu o cálculo dos coeficientes da equação de regressão. Curiosamente, o nível de precisão conseguido por esta rede neural para o limite de escoamento foi melhor do que o obtido pela rede neural

correspondente ao aço C-Mn. Talvez isso possa ser explicado pelo maior número de variáveis independentes adotado neste último caso. De toda forma, observou-se pequena melhoria no caso da previsão da razão elástica e praticamente nenhuma no caso do alongamento total.

Também aqui a classificação de variáveis de acordo com o nível de significância estatística normalizado apresentou coerência com a teoria metalúrgica, com o teor de Nb sendo a principal variável independente para o cálculo do limite de escoamento, limite de resistência e razão elástica, conforme já esperado em função de seu intenso efeito de endurecimento por refino de tamanho de grão e precipitação. É curioso notar que o Cu apresenta relevância pequena mas significativa para as quatro propriedades mecânicas aqui escolhidas, pois o motivo primário de sua adição é apenas o aumento da resistência à corrosão atmosférica. Tal situação também se refletiu na regressão linear múltipla *stepwise*.⁽⁵⁾ Por outro lado, deve-se notar que todos os aços ao Cu deste trabalho também contém Cr ($r = +0,99$), tornando impossível dissociar os efeitos decorrentes da ação dessa dupla de elementos de liga.

Da mesma forma como ocorreu para a rede neural relativa aos aços ao C-Mn englobando todas as variáveis relevantes do ponto de vista metalúrgico, a análise de sensibilidade elegeu parâmetros de processo de laminação de tiras a quente como sendo variáveis mais importantes, principalmente TA. Contudo, o efeito desta última variável, em tese, foi o contrário do que se esperava para o limite de escoamento, limite de resistência e alongamento total, já que o aumento no tamanho de grão proporcionado pela elevação de TA deveria reduzir as duas primeiras propriedades e aumentar a terceira. É curioso verificar que também nos aços microligados a TB apresentou efeito negativo sobre o alongamento total, aparentemente sinalizando um efeito benéfico do refino do tamanho de grão sobre essa propriedade. Por outro lado, este tipo de análise elegeu o P como variável relevante no caso da determinação do alongamento total ao invés do S, como seria esperado. A princípio este último efeito pode ser atribuído à multicolinearidade decorrente da correlação entre variáveis independentes e à forma livre com que a rede neural estabelece as correlações entre os dados.

Estes resultados aparentemente incoerentes motivaram o desenvolvimento de uma nova rede neural com variáveis de entrada selecionadas por regressão linear múltipla *stepwise*, ou seja, C, Mn, S, Si, Cu, Nb, DefTot^{-1/2} e TB.⁽⁵⁾ A nova rede neural tinha configuração 8 x 17 x 4, tendo sido obtidos os seguintes resultados:

- **Limite de Escoamento:**
 - . Precisão: $r = 0,93$; EPE = 20 MPa.
 - . RELNORM: Nb (53%), Mn (14%), Cu (8%), DefTot^{-1/2} (8%), C (7%), Si (6%), TB (3%), Demais (1%).
 - . SENSNORM: DefTot^{-1/2} (-2,6%), TB (-2,5%), Mn (+0,6%), Nb (+0,6%).
- **Limite de Resistência:**
 - . Precisão: $r = 0,96$; EPE = 16 MPa.
 - . RELNORM: Nb (35%), Mn (18%), C (17%), Si (10%), Cu (8%), DefTot^{-1/2} (7%), TB (4%), Demais (1%).
 - . SENSNORM: DefTot^{-1/2} (-1,7%), TB (-1,6%), Mn (+0,6%), C (+0,5%), Nb (+0,3%).
- **Razão Elástica:**
 - . Precisão: $r = 0,87$; EPE = 0,03.
 - . RELNORM: Nb (43%), C (23%), Si (12%), DefTot^{-1/2} (7%), Mn (5%), Cu (5%), TB (4%), Demais (1%).
 - . SENSNORM: DefTot^{-1/2} (-1,0%), TB (-1,0%), C (-0,5%), Nb (+0,3%).

- **Alongamento Total:**

- . Precisão: $r = 0,64$; EPE = 5%.
- . RELNORM: Nb (20%), Mn (20%), C (18%), Cu (12%), Si (12%), DefTot^{-1/2} (11%), S (7%).
- . SENSNORM: DefTot^{-1/2} (-2,0%), TB (-1,0%), Mn (-0,6%), S (-0,4%), Nb (-0,2%).

Curiosamente a eliminação de seis variáveis independentes não afetou a precisão da nova rede neural em relação à anterior. Estes resultados também foram bem melhores que os obtidos pela regressão linear múltipla *stepwise* para o caso do limite de escoamento e de resistência, onde se obteve, respectivamente, $r = 0,86$ /EPE = 28 MPa e $r = 0,93$ /EPE = 21 MPa. Por outro lado, as melhorias verificadas no caso da razão elástica e do alongamento total foram insignificantes em relação à regressão linear múltipla *stepwise*, caso em que se obteve, respectivamente, $r = 0,78$ /EPE = 0,04 e $r = 0,54$ /EPE = 5%.⁽⁵⁾

A classificação das variáveis conforme o nível de significância estatística normalizado mostrou que neste caso houve um domínio ainda maior do efeito dos elementos de liga na determinação das propriedades mecânicas, em especial dos teores de Nb, Mn, C, Cu e Si. As variáveis do processo de laminação (DefTot e TB) tiveram sua relevância significativamente reduzida. O S continuou relevante para a determinação do alongamento total, ainda que com importância reduzida.

Já a análise de sensibilidade considerou como sendo mais importantes as variáveis do processo de laminação (DefTot e TB) na determinação de todas as propriedades mecânicas consideradas. Mn, C e Nb, em ordem decrescente de importância, estão num distante segundo escalão. No caso específico do alongamento total notou-se efeito negativo de DefTot^{-1/2} e TB, como também já havia sido observado no caso da regressão linear múltipla *stepwise*.⁽⁵⁾ Uma vez que há informações dúbias sobre o efeito do tamanho de grão sobre a ductilidade do material^(13,14) o ideal seria analisar mais detidamente as alterações na morfologia microestrutural produzidas por variações nesses parâmetros de processo.

No caso dos aços microligados o programa VaiQ-Strip apresentou erros padrão da estimativa de 18 MPa e 13 MPa para os limites de escoamento e resistência, respectivamente.⁽¹⁾ A precisão desta última rede neural para o cálculo do limite de escoamento e de resistência foi de, respectivamente, 20 MPa e 16 MPa. Um desempenho não tão bom quanto o observado para o VaiQ-Strip, mas o trabalho envolvido no desenvolvimento das redes neurais foi bem menor, obtendo-se um nível de precisão apenas ligeiramente inferior.

4 CONCLUSÕES

Este trabalho teve como objetivo o desenvolvimento de redes neurais para cálculo das propriedades mecânicas de bobinas laminadas a quente de aços ao C-Mn e microligados a partir de sua composição química e parâmetros de processo da laminação. Foi verificado que a precisão desses modelos foi melhor do que o obtido por equações equivalentes obtidas por regressão linear múltipla, comprovando a maior capacidade das redes neurais em lidar com relações não-lineares entre as variáveis envolvidas e com interações entre as variáveis independentes. O uso de variáveis independentes selecionadas pela regressão linear múltipla *stepwise* não afetou a precisão das redes neurais obtidas e permitiu suprimir variáveis cujo efeito matemático não era compatível com a teoria metalúrgica. A análise da importância

das variáveis independentes mostrou que a maior parte da precisão de cálculo é proporcionada pelos teores de elementos de liga relevantes, mas que os efeitos da flutuação dos parâmetros de processo de laminação a quente afetam mais fortemente os valores calculados de propriedades mecânicas. O desempenho das redes neurais aqui obtidas foi um pouco inferior ao de programas comerciais consagrados para o cálculo de propriedades mecânicas de bobinas a quente, mas elas constituem uma solução endógena que foi obtida sob custos e prazos muito menores.

REFERÊNCIAS

- 1 ANDORFER, J. et al. VAIQ-Strip, un Nouveau Système de Contrôle de Qualité pour les Bandes Laminées à Chaud. **La Revue de Metallurgie – CIT**, v. 95, n. 7, p. 883-882, Juillet-Août 1998.
- 2 ARTIGAS, A. et al. Predicción de Propiedades Mecánicas y Microestructurales en Aceros Laminados en Caliente. **Revista de Metalurgia – CENIM**, v. 38, p. 339-347, 2002.
- 3 SHA, X.C. et al. Modelling Effect of Hot Rolling Process Variables on Microstructure and Mechanical Properties of Low Carbon Strip Steels. **Ironmaking and Steelmaking**, v. 31, n. 2, p. 169-175, 2004.
- 4 YONGJUN, L.; DIANZHONG, L. & YIYI, L. Prediction of Microstructure and Mechanical Properties of Hot Rolled Steel Strip: Part I – Description of Models. **Steel Research International**, v. 75, n. 7, p. 462-467, July 2004.
- 5 GORNI, A.A.; SILVA, M.R.S. & DOLABELA, J.H.S. Análise Multidimensional dos Parâmetros de Processo e Propriedades Mecânicas de Bobinas a Quente. A ser apresentado neste Seminário.
- 6 GORNI, A.A. The Application of Neural Networks in the Modeling of Plate Rolling Processes. **J.O.M.-e**, vol. 49, n. 4, April 1997.
- 7 DUMORTIER, C. & LEHERT, P. Statistical Modelling of Mechanical Tensile Properties of Steels by Using Neural Networks and Multivariate Data Analysis. **ISIJ International**, v. 39, n. 10, p. 980-985, October 1999.
- 8 JONES, D.M.; WATTON, J. & BROWN, K.J. Comparison of Hot Rolled Steel Mechanical Property Prediction Models Using Linear Multiple Regression, Non-Linear Multiple Regression and Non-Linear Artificial Neural Networks. **Ironmaking and Steelmaking**, v. 32, n. 5, p. 435-442, 2005.
- 9 TAMMINEN, P. et al. System for On/Offline Prediction of Mechanical Properties and Microstructural Evolution in Hot Rolled Steel Strip. **Ironmaking and Steelmaking**, v. 34, n. 2, p. 157-165, 2007.
- 10 HECHT-NIELSEN, R. **Neurocomputing**. Addison-Wesley Publishing Company, Reading, 1989, 433 p.
- 11 ANDERS, U. **Statistische neuronale Netze**. Verlag Franz Vahlen, München, 1997, 214 p.
- 12 GORNI, A.A. et al. Fatores que Afetam a Razão Elástica de Chapas Grossas de Aço Microligado. In: 39º Seminário de Laminação - Processos e Produtos Laminados e Revestidos. **Anais...** Associação Brasileira de Metais, Ouro Preto, Outubro de 2002, p. 207-216.
- 13 PICKERING, F.B. **Physical Metallurgy and the Design of Steels**. Applied Science Publishers, London, 1978, 275 p.
- 14 MORRISON, W. The Effect of Grain Size on the Stress-Strain-Relationship in Low-Carbon Steel. **Transactions of the ASM**, v. 59, 1966, p. 824-845.