

PREVISÃO DE PROPRIEDADES MECÂNICAS DE BOBINAS LAMINADAS A QUENTE ATRAVÉS DE REDES NEURAIIS

Antonio Augusto Gorni ¹
Marcos Roberto Soares da Silva ²
José Herbert Dolabela da Silveira ³

Resumo

Este trabalho apresenta o desenvolvimento de 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 destes modelos ficou num nível intermediário entre a obtida por equações lineares e a de modelos comerciais (VAIQ-Strip), representando, portanto, uma alternativa balanceada entre precisão preditiva e esforço requerido para seu desenvolvimento. Também são determinados, de forma quantitativa, os graus de contribuição e de relevância associados a cada variável independente para os resultados previstos, de acordo com diversos critérios estatísticos. Este procedimento mostra que o processo de laminação de tiras a quente exerce menor efeito sobre as propriedades mecânicas da bobina do que o verificado para a composição química do aço.

Palavras-chave: Bobina a quente; Processos; Propriedades mecânicas; Redes neurais.

PREDICTION OF MECHANICAL PROPERTIES OF HOT COILS USING NEURAL NETWORKS

Abstract

Neural networks are 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 is 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. The quantitative degree of contribution and relevance of each independent variable in the forecast results are also determined according to several statistical criteria. This procedure shows that the hot strip rolling process has a smaller effect over mechanical properties of the coil than that observed from the chemical composition of the steel.

Key words: Hot coil; Processes; Mechanical properties; Neural networks.

1 INTRODUÇÃO

Trabalhos de pesquisa visando o estabelecimento de correlações entre composição química, microestrutura, parâmetros de processo de laminação a quente e propriedades mecânicas dos laminados planos vêm sendo feitos há décadas. Todo esse esforço levou ao desenvolvimento de modelos matemáticos que podem prever, de forma precisa, microestruturas e propriedades mecânicas de laminados a quente, como é o caso, por exemplo, do VAIQ-Strip.⁽¹⁾ Essa tarefa requer um esforço enorme que demanda muitos recursos técnicos e humanos, 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 que a amplitude das variáveis envolvidas é estreita e específica para cada usina.^(2,3) Por outro lado, essa premissa pode ser questionada, uma vez que os fenômenos metalúrgicos que afetam as propriedades mecânicas da tira durante o processo de laminação são muito complicados

¹Membro 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, Estrada de Piaçagüera Km 6, Cep 11573-900, Cubatão SP, Brasil. E-mail: antonio.gorni@usiminas.com

²Membro 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, Estrada de Piaçagüera Km 6, Cep 11573-900, Cubatão SP, Brasil. E-mail: marcos.silva@usiminas.com

³Membro 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. Atual endereço: Gerdau Açominas, Usina Presidente Arthur Bernardes, Rodovia MG 443 Km 7, Cep 36420-000, Ouro Branco, MG, Brasil. E-mail: herbert.silveira@gerdau.com.br

devido ao grande número de fatores envolvidos. As relações entre esses fatores podem ser não-lineares, além de haver interações entre variáveis independentes. Uma abordagem adequada para essa situação está no uso de 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 sua resposta.

As primeiras tentativas bem sucedidas de aplicação de redes neurais na modelagem dos processos de laminação a quente têm mais de quinze anos⁽⁴⁾ e já foram usadas para a previsão de propriedades mecânicas de bobinas laminadas a quente.⁽⁵⁻⁷⁾ O objetivo desse trabalho foi verificar o desempenho dessa metodologia matemática para a previsão das propriedades mecânicas de bobinas a quente para as condições específicas da Cosipa.

2 PROCEDIMENTO EXPERIMENTAL

O procedimento adotado para a coleta e depuração dos dados do processo de laminação e propriedades mecânicas das bobinas laminadas a quente usados neste trabalho está descrito detalhadamente em outro trabalho.⁽³⁾ Foram consideradas aqui, como variáveis independentes, a composição química (C, Mn, P, S, Si e N, para aços ao C-Mn, e mais Nb, Ti, V e Cu, no caso dos aços microligados), deformação total placa-tira (DefTot), temperatura de acabamento (TA), velocidade de resfriamento após laminação (VelResf) e temperatura de bobinamento (TB). As variáveis dependentes são as propriedades mecânicas da bobina a quente, ou seja, limite de escoamento (LE), limite de resistência (LR), razão elástica (RE) e alongamento total (AT). Foram obtidos 5.456 registros para aços C-Mn, e 2.847 para aços microligados.

Opta-se neste trabalho por empregar redes neurais com arquitetura do tipo *feed forward* com camada de entrada, uma camada oculta e camada de saída. A camada de entrada é constituída de neurônios associados às variáveis independentes, enquanto que a camada de saída é constituída de neurônios associados às variáveis dependentes. O número de neurônios da camada oculta é calculado conforme é previsto pelo teorema de Hecht-Kolmogorov,⁽⁸⁾ ou seja, igual ao dobro do número de neurônios da camada de entrada mais um. A função de ativação usada nos neurônios da camada oculta é a tangente sigmoïdal, enquanto que a da camada de saída é linear. Todos os neurônios da rede neural são ligados a um neurônio de *bias*.

Testes preliminares mostraram que se conseguiu maior precisão preditiva ao se incluir simultaneamente as quatro variáveis dependentes (LE, LR, RE e AT) na camada de saída da rede neural do que quando se criava uma rede específica para cada uma delas. A presença simultânea dessas quatro variáveis da rede neural intensifica as correlações existentes entre elas e as variáveis independentes.⁽⁵⁻⁷⁾

O algoritmo de Levenberg-Marquardt é empregado para o aprendizado. 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 o coeficiente de correlação (r) e o erro padrão da estimativa (EPE) para a rede treinada usando-se os restantes 20% de dados disponíveis.

O nível de relevância estatística de cada variável independente (REL_i) é calculado conforme proposto por Anders:⁽⁹⁾ 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 EPE correspondente à execução da rede neural treinada a partir desse conjunto de dados modificado. Quanto maior é o valor do EPE assim calculado, maior a relevância estatística da variável i em questão, pois se constata, nesse caso, que sua neutralização (ou seja, o fato dela assumir valor constante) aumenta o erro da previsão cometido pela rede neural treinada. É possível determinar REL_i dividindo-se o valor de EPE assim calculado pelo valor do EPE associado à rede neural original. Portanto, quando REL_i é próximo ou inferior à unidade 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 ($RELN_i$) por meio da expressão:

$$(REL_i - 1) / \Sigma(REL_i - 1) \quad (1)$$

A análise de sensibilidade para cada variável independente inicia-se com a duplicação dos registros da massa de dados. A variável escolhida assume seu valor original num dos registros e sofre acréscimo de 5% no registro-duplicata.⁽⁸⁾ São calculados os valores das variáveis dependentes para esse conjunto de dados modificado usando-se a rede neural treinada e, a seguir, calcula-se a diferença entre os valores dessas variáveis de cada registro original e do correspondente registro-duplicata. Finalmente, determina-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 é essa diferença média, maior o efeito da variável independente considerada. Pode-se também propor o cálculo da sensibilidade média normalizada ($SENSN_i$) para a variável independente i , que

é igual a $\text{SENS}/\Sigma|\text{SENS}_i|$. Este parâmetro apresenta a vantagem de mostrar o sentido do efeito da variável independente, ou seja, se sua elevação leva a um aumento ou diminuição no valor das variáveis dependentes.

3 RESULTADOS E DISCUSSÃO

No caso dos 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: C, Mn, P, S, Si e N; DefTot, TA, VelResf e TB. Os resultados obtidos para essa topologia (10 x 21 x 4) são:

- **Limite de Escoamento** ($r = 0,70$; EPE = 26 MPa):
 - RELN: DefTot (26%), Mn (23%), VelResf (22%), Si (13%), TB (10%);
 - SENSN: TA (+3,8%), TB (-3,0%), DefTot (+3,0%), Mn (+1,0%), C (+0,5%).
- **Limite de Resistência** ($r = 0,88$; EPE = 16 MPa):
 - RELN: Mn (37%), C (19%), Si (17%), VelResf (11%), DefTot (9%);
 - SENSN: TB (-0,8%), C (+0,8%), TA (+0,8%), Mn (+0,7%), DefTot (+0,5%).
- **Razão Elástica** ($r = 0,60$; EPE = 0,05):
 - RELN: DefTot (29%), VelResf (29%), Si (12%), TB (10%), C (10%), Mn (8%);
 - SENSN: TA (+2,9%), DefTot (+2,4%), TB (-2,1%).
- **Alongamento Total** ($r = 0,56$; EPE = 5%):
 - RELNORM: DefTot (15%), Si (15%), VelResf (13%), C (13%), Mn (10%), S (8%), TB (8%);
 - 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, apresenta desempenho decrescente na sequência LR → LE → RE → AT, fato que aparentemente reflete os erros experimentais associados à medição dessas propriedades mecânicas.⁽⁶⁾ 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 impediu 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 relevância estatística apresenta coerência com a teoria metalúrgica. De acordo com esta rede neural, o endurecimento por refino de grão foi bastante significativo para a definição do LE, já que DefTot e VelResf são, respectivamente, a primeira e terceira variáveis 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 LR a composição química é mais importante, atuando preponderantemente através de endurecimento por solução sólida, com Mn e Si ocupando primeiro e terceiro lugares, respectivamente; pela fração de perlita na microestrutura, com C em segundo lugar. Neste caso VelResf e DefTot ocuparam os últimos

lugares entre as variáveis significativas. Já RE e AT apresentam situação similar à do LE. Note-se a presença do S entre as variáveis significativas para AT, o que parece refletir o efeito da limpeza inclusonária sobre a ductilidade.

Já a classificação de variáveis de acordo com a análise de sensibilidade nem sempre apresenta similaridades com o critério anterior. Por exemplo, esta abordagem revela que TA é uma variável significativa para o LE, LR e RE, 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 um aumento no tamanho de grão e a uma correspondente redução no LE e LR, bem como em RE.⁽¹⁰⁾ O efeito positivo de DefTot e VelResf sobre o AT parece indicar que o refino de tamanho de grão no material produzido pela elevação desses parâmetros tende a aumentar sua ductilidade, relação proposta nas equações de Pickering⁽¹¹⁾, mas questionada por Morrison.⁽¹²⁾

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 por meio de regressão múltipla linear *stepwise*,⁽³⁾ ou seja: 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, com os seguintes resultados:

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

A eliminação de três variáveis pouco afeta a precisão obtida em relação à rede neural anterior, tendo sido observada ligeira degradação apenas no caso do LE. Conforme já era esperado,⁽⁵⁻⁷⁾ esta rede neural apresenta melhor precisão para o cálculo do LE e LR em relação ao conseguido pela regressão linear múltipla *stepwise*, em que são obtidos, respectivamente, $r = 0,61/EPE=30$ Pa e $r = 0,82/EPE=17$ MPa.⁽³⁾ Contudo, verifica-se pouca ou nenhuma melhoria na precisão preditiva para RE e AT, tendo sido conseguido, no caso da regressão linear múltipla *stepwise*, respectivamente, $r=0,47/EPE=0,05$ e $r=0,50/EPE=5\%$.⁽³⁾

É curioso notar que a análise pelo nível de relevância estatística evidencia que aqui a composição química do aço apresenta maior relevância em relação aos parâmetros de laminação. Por outro lado, não se verifica 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*.⁽³⁾

Já a análise de sensibilidade confirma 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 são metalurgicamente coerentes, fato que confirma a minimização dos efeitos de multicolinearidade. A única exceção é a relação negativa entre AT e TB. Por outro lado, é estranho que esta rede neural não tenha considerado o teor de S importante para a previsão do AT, ao contrário do verificado na regressão linear múltipla *stepwise*.⁽³⁾

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

Da mesma forma como ocorrido com os aços ao C-Mn, inicialmente foi proposta para os aços microligados uma rede neural onde foram incluídas como variáveis de entrada todos os parâmetros considerados relevantes do ponto de vista metalúrgico: C, Mn, P, S, Si, Cu, Nb, Ti, V e N; DefTot, TA, VelResf e TB. Isso resultou numa rede com topologia $14 \times 29 \times 4$, a qual apresenta o seguinte desempenho:

- **Limite de Escoamento** ($r = 0,93$; EPE = 20 MPa):
 - RELN: Nb (39%), Mn (12%), DefTot (12%), VelResf (10%), C (6%), Si (5%), Ti (4%), Cu (4%), TB (4%).
 - SENSN: TA (+5,4%), DefTot (+2,5%), TB (-1,8%), Mn (+0,6%), Nb (+0,5%).
- **Limite de Resistência** ($r = 0,96$; EPE = 16 MPa):
 - RELN: Nb (26%), Mn (17%), VelResf (14%), C (12%), DefTot (9%), Si (6%), Cu (5%), TB (4%), Ti (3%).
 - SENSN: TA (+5,7%), DefTot (+1,7%), TB (-1,4%), Mn (+0,6%), C (+0,5%), Nb (+0,3%).

- **Razão Elástica** ($r = 0,65$; EPE = 0,03):
 - RELN: Nb (35%), C (25%), DefTot (8%), Si (6%), Mn (5%), Cu (5%), Ti (5%), VelResf (5%), TB (3%).
 - SENSN: TA (-1,1%), DefTot (+0,6%), C (-0,5%), TB (-0,4%), Nb (+0,2%).
- **Alongamento Total** ($r = 0,87$; EPE = 5%):
 - RELN: C (30%), DefTot (19%), Mn (16%), VelResf (11%), Si (8%), Cu (8%), TB (4%), S (4%).
 - SENSN: TB (-4,8%), TA (-1,3%), DefTot (-0,9%), P (-0,6%), Nb (-0,3%).

Também neste caso não é possível comparar o desempenho desta rede neural com a regressão linear múltipla equivalente em função das significativas correlações entre as variáveis independentes, fato que impediu o cálculo dos coeficientes da equação de regressão. Curiosamente, o nível de precisão conseguido por esta rede neural para o LE é 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, observa-se pequena melhoria no caso da previsão de RE e praticamente nenhuma no caso do LR e AT.

Também aqui a classificação de variáveis de acordo com o nível de relevância estatística normalizado apresenta coerência com a teoria metalúrgica, com o teor de Nb sendo a principal variável independente para o cálculo do LE, LR e RE, conforme já esperado em função de seu intenso efeito de endurecimento por refino de tamanho de grão e precipitação. É curioso notar que o efeito do Cu é significativo para as quatro propriedades mecânicas aqui escolhidas, uma vez que o motivo primário de sua presença é o aumento da resistência à corrosão atmosférica que ele proporciona. Tal situação também se reflete na regressão linear múltipla *stepwise*.⁽³⁾ Por outro lado, deve-se notar que todos os aços ao Cu deste trabalho também continham Cr ($r_{Cu-Cr} = +0,99$), tornando impossível dissociar os efeitos decorrentes da ação dessa dupla de elementos de liga.⁽³⁾

Da mesma forma como ocorreu para a primeira rede neural relativa aos aços ao C-Mn, a qual englobava todas as variáveis relevantes do ponto de vista metalúrgico, a análise de sensibilidade considerou os parâmetros do processo de laminação de tiras a quente como sendo mais

importantes no caso dos aços microligados, principalmente TA. Contudo, o efeito desta variável é o contrário do que se esperava no caso do LE, LR e AT, já que o aumento no tamanho de grão proporcionado pela elevação de TA deveria reduzir as duas primeiras propriedades e aumentar a terceira. Também é curioso verificar que, também nos aços microligados, a TB apresenta efeito negativo sobre o AT, aparentemente sinalizando um efeito benéfico do refino do tamanho de grão sobre essa propriedade. Por outro lado, esta análise elegeu o P como variável relevante no caso da determinação do AT, ao invés do S, como seria de se esperar. Em princípio, esse último efeito pode ser atribuído ao elevado grau de multilinearidade existente entre as 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.⁽³⁾ A nova rede neural tinha configuração 8 x 17 x 4, tendo sido obtidos os seguintes resultados:

- **Limite de Escoamento** ($r = 0,93$; EPE = 20 MPa):
 - RELN: Nb (53%), Mn (14%), Cu (8%), DefTot^{-1/2} (8%), C (7%), Si (6%), TB (3%);
 - SENSN: DefTot^{-1/2} (-2,6%), TB (-2,5%), Mn (+0,6%), Nb (+0,6%).
- **Limite de Resistência** ($r = 0,96$; EPE = 16 MPa):
 - RELN: Nb (35%), Mn (18%), C (17%), Si (10%), Cu (8%), DefTot^{-1/2} (7%), TB (4%);
 - SENSN: DefTot^{-1/2} (-1,7%), TB (-1,6%), Mn (+0,6%), C (+0,5%), Nb (+0,3%).
- **Razão Elástica** ($r = 0,87$; EPE = 0,03):
 - RELN: Nb (43%), C (23%), Si (12%), DefTot^{-1/2} (7%), Mn (5%), Cu (5%), TB (4%);
 - SENSN: DefTot^{-1/2} (-1,0%), TB (-1,0%), C (-0,5%), Nb (+0,3%).
- **Alongamento Total** ($r = 0,64$; EPE = 5%):
 - RELN: Nb (20%), Mn (20%), C (18%), Cu (12%), Si (12%), DefTot^{-1/2} (11%), S (7%);
 - SENSN: 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 afeta a precisão da nova rede neural em relação à anterior. Estes resultados também são bem melhores que os obtidos pela regressão linear múltipla *stepwise* para o caso de LE e LR, onde são obtidos $r=0,86$ /EPE=28 MPa e $r=0,93$ /EPE=21 MPa, respectivamente. Por outro lado, as melhorias verificadas no caso de RE e AT são insignificantes em relação ao obtido na regressão linear múltipla *stepwise*: $r=0,78$ /EPE=0,04 e $r=0,54$ /EPE=5%, respectivamente.⁽³⁾

A classificação das variáveis conforme o nível de relevância estatística normalizado mostra que, neste caso, há 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 continua relevante para a determinação do AT, ainda que com importância reduzida.

Já a análise de sensibilidade considera 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 AT nota-se efeito negativo de DefTot^{-1/2} e TB, como também já havia sido observado no caso da regressão linear múltipla *stepwise*.⁽³⁾

No caso dos aços microligados o programa VaiQ-Strip apresenta erros padrão da estimativa de 18 MPa e 13 MPa para LE e LR, respectivamente.⁽¹⁾ As precisões desta última rede neural para o cálculo do LE e LR são de, respectivamente, 20 MPa e 16 MPa. Como já havia sido observado no caso dos aços ao C-Mn, é obtido um desempenho preditivo ligeiramente inferior ao VaiQ-Strip, mas conseguido com um modelo desenvolvido de forma bem mais rápida.

4 CONCLUSÕES

Este trabalho mostra que a modelagem 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 usando-se redes neurais, apresenta melhor precisão de cálculo do que equações obtidas por regressão linear múltipla. Isto comprova a maior capacidade das redes neurais em lidar com relações não-lineares entre as variáveis envolvidas. A seleção de variáveis independentes por regressão linear múltipla *stepwise* não afeta a precisão das redes neurais obtidas e permite suprimir variáveis cujo efeito matemático não é compatível com a teoria metalúrgica. A análise da importância das variáveis independentes mostra 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 acentuadamente os valores calculados de propriedades mecânicas. O desempenho das redes neurais aqui obtidas é um pouco inferior ao de programas comerciais consagrados para o cálculo de propriedades mecânicas de bobinas a quente, mas constituem uma solução endógena obtida sob custos e prazos muito menores.

REFERÊNCIAS

- 1 ANDORFER, J.; AUZINGER, D.; HIRSCH, M.; HUBMER, G.; PICHLER, R. 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. 883-892, juil./août 1998.
- 2 SHA, X.C.; LI, D.Z.; ZHANG, Y.T.; ZHANG, X.G.; LI Y.Y. 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. 169-75, 2004.
- 3 GORNI, A.A.; SILVA, M.R.S.; DOLABELA, J.H.S. Análise multidimensional dos parâmetros de processo e propriedades mecânicas de bobinas a quente. In: SEMINÁRIO DE LAMINAÇÃO - PROCESSOS E PRODUTOS LAMINADOS E REVESTIDOS, 45, 2008, Porto de Galinhas, PE. **Anais...** São Paulo: ABM, 2008. p. 766-77.
- 4 GORNI, A.A. The application of neural networks in the modeling of plate rolling processes. **J.O.M.-e**, v. 49, n. 4, Apr. 1997.
- 5 DUMORTIER, C.; LEHERT, P. statistical modeling of mechanical tensile properties of steels by using neural networks and multivariate data analysis. **ISIJ International**, v. 39, n. 10, p. 980-5, Oct. 1999.
- 6 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. 435-42, 2005.
- 7 TAMMINEN, P.; RUHA, P.; KÖMI, J.I.; KATAJARINNE, T.; KAUPPI, T.A.; MARTTILA, J.P.; KARJALAINEN, L.P. 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, Mar. 2007.
- 8 HECHT-NIELSEN, R. **Neurocomputing**. Reading: Addison-Wesley Publishing Company, Reading, 1989.
- 9 ANDERS, U. **Statistische neuronale Netze**. München: Franz Vahlen, 1997.
- 10 GORNI, A.A.; FREITAS, F.V.; REIS, J.S.S.; SILVEIRA, J.H.D.; CAVALCANTI, C.G. Fatores que afetam a razão elástica de chapas grossas de aço microligado. In: SEMINÁRIO DE LAMINAÇÃO - PROCESSOS E PRODUTOS LAMINADOS E REVESTIDOS, 39, 2002, Ouro Preto, MG. **Anais...** São Paulo: ABM, 2002. p. 207-16.
- 11 PICKERING, F.B. **Physical metallurgy and the design of steels**. London: Applied Science, 1978.
- 12 MORRISON, W. The effect of grain size on the stress-strain-relationship in low-carbon steel. **Transactions of the ASM**, v. 59, p. 824-45, 1966.

Recebido em: 25/11/2008

Aceito em: 18/06/2009

Proveniente de: SEMINÁRIO DE LAMINAÇÃO – PROCESSOS E PRODUTOS LAMINADOS E REVESTIDOS, 2008, Ipojuca, Porto de Galinhas, PE. São Paulo: ABM, 2008.