

PREDIÇÃO DE PROPRIEDADES MECÂNICAS EM AÇOS LAMINADOS A QUENTE UTILIZANDO REDES NEURAIS ADAPTATIVAS¹

Willy Ank de Moraes²
Herbert Christian Borges³
Ronald Lesley Plaut⁴

Resumo

O crescente desenvolvimento tecnológico dos setores consumidores de aço aumenta a competição no setor siderúrgico e obriga os produtores a estreitar cada vez mais as faixas de tolerâncias dimensionais e propriedades mecânicas de seus produtos. Neste sentido, as Redes Neurais Adaptativas (RNA's) constituem uma importante ferramenta a ser explorada na previsão de propriedades mecânicas dos aços, possibilitando: otimização dos processos produtivos, redução no custo de desenvolvimento de novos produtos e flexibilizar as características do aço às necessidades dos usuários. Neste trabalho, foram levantados dados básicos de processo (composição química, temperaturas de laminação e dimensão do produto final) para a construção de uma RNA que preveja o Limite de Escoamento e Limite de Resistência de materiais laminados a quente, processados na forma de bobinas.

Palavras-chave: Laminados a quente; Redes neurais; Propriedades mecânicas; Modelamento.

USING NEURAL NETWORKS TO PREDICT MECHANICAL PROPERTIES IN HOT ROLLED STEEL

Abstract

The constant technological development in the steel consuming sectors increased the competition that forces steel makers to narrow dimensional tolerances and mechanical properties range of their products. In this way, Artificial Neural Networks (ANN's) became an important tool explored to forecast mechanical properties of steels, which enables: optimization of processing, cost reductions during new products development and make steel products more adequate to consumers need. In the present work, basic process data (chemical composition, rolling temperatures, product dimensions) have been used in order to build a ANN relating those to the yield and tensile strength of hot rolled materials, in the form of steel coils.

Key words: Hot rolled; Neural network; Mechanical properties; Modeling.

¹ *Contribuição técnica ao 64º Congresso Anual da ABM, 13 a 17 de julho de 2009, Belo Horizonte, MG, Brasil.*

² *Doutorando, Mestre em Eng^a Met. e de Materiais, Eng^o Metalurgista, Téc. em Metalurgia, Analista da USIMINAS Cubatão, Professor da Faculdade de Engenharia da UNISANTA e Vice-Diretor da divisão técnica "Aplicações de Materiais" da ABM. E-mail: willyank@unisanta.br ou willy.morais@usiminas.com.*

³ *Mestrando em Eng^a Metalúrgica, Eng^o Metalurgista. Analista de Assistência Técnica da USIMINAS Cubatão. E-mail: herbert.borges@usiminas.com.*

⁴ *Doutor, Mestre e Engenheiro Metalurgista. Professor da Escola Politécnica da Universidade de São Paulo. E-mail: rplaut@usp.br.*

1 INTRODUÇÃO

O crescimento no consumo mundial de aço e o crescente desenvolvimento tecnológico dos setores consumidores (indústria automotiva, de equipamentos, setor petrolífero, etc.) aumentam a competição no setor siderúrgico. Isto obriga os produtores de aço a estreitar cada vez mais as faixas de tolerâncias dimensionais e de propriedades mecânicas de seus produtos, bem como torná-los mais flexíveis as suas necessidades.^(1,2)

Assim, é um anseio da siderurgia desenvolver um método que permita prever as características dos materiais após o seu processamento. Tal ferramenta possibilita uma série de vantagens, entre elas:

- redução no custo de desenvolvimento de novos aços;
- redução do volume e tempo de produção experimental em projetos de desenvolvimento de aços; e
- possibilidade de otimização do projeto de liga e parâmetros de processo.

Em 1943, fruto do trabalho de Warren McCulloch e Walter Pitts, surgiram as Redes Neurais Artificiais, hoje chamadas Redes Neurais Adaptativas (RNAs).⁽³⁾ Durante alguns anos, esta ferramenta foi pouco explorada principalmente pela dificuldade de processamento (tecnologia computacional), mas em meados da década de 80 elas ressurgiram.⁽⁴⁾

As RNAs são inspiradas no funcionamento do cérebro humano e a Figura 1 mostra um exemplo de estrutura de uma RNA.

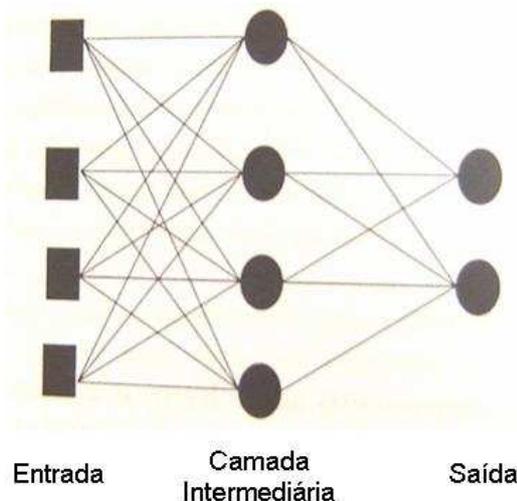


Figura 1 – Esquema de Rede Neural Adaptativa.⁽¹⁾

A utilização de RNAs para previsão de propriedades mecânicas possui alguns complicadores, principalmente pelo grande número de variáveis. No entanto, isto pode ser minimizado, conhecendo-se relações entre variáveis que são claras e compreendidas metalurgicamente.^(3,5) Nestes casos, os modelos de RNAs são muito úteis.⁽⁶⁾ Assim, sua utilização para a predição de propriedades em aços carbono e microligados é bastante atrativa, pois se trata de uma técnica de fácil manuseio para modelamento, estimativa, previsão, diagnóstico e controle adaptativo em sistemas complexos e não lineares.^(3,5,6)

Em particular, neste trabalho, buscou-se desenvolver uma metodologia para aplicação de RNA's na predição de Limite de Escoamento (LE) e Limite de Resistência (LR) de aços carbono e microligados laminados a quente, partindo de

informações básicas como: composição química, esquema de resfriamento, espessura e temperaturas de processo.

2 MATERIAIS E MÉTODOS

2.1 Amostragem para Ensaio Mecânico

As amostras foram retiradas dos materiais processados no Laminador de Tiras a Quente (LTQ) da Usiminas Cubatão foram retiradas após descarte da primeira espira ($\cong 2m$), com dimensão de 450 mm x 450 mm, como mostrado na Figura 2.

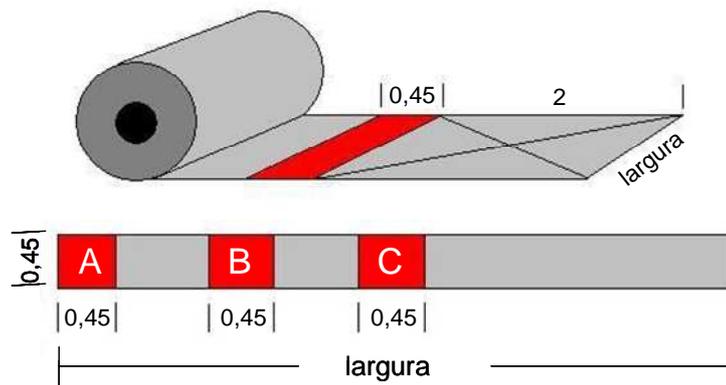


Figura 2 – Esquema ilustrativo da amostragem no LTQ (dimensões em metros).

A posição de retirada das amostras também varia, conforme a norma de qualidade do material amostrado, como descrito na Tabela 1.

Tabela 1 – Posição de amostragem para produtos em bobinas

Norma	Posição
API	C (1/2)
ASTM	A (Borda)
Demais	B (1/4)

2.2 Seleção das Variáveis de Entrada

Para seleção das variáveis de entrada, optou-se por utilizar dados básicos de processo e composição química, como mostra a Tabela 2. As variáveis de saída são: o Limite de Escoamento (LE) e o Limite de Resistência (LR).

Tabela 2 – Variáveis de entrada para a construção das RNA's

Composição Química	Variável	Unidade
	Carbono	% (em peso)
	Manganês	% (em peso)
	Silício	% (em peso)
	Fósforo	% (em peso)
	Enxofre	% (em peso)
	Alumínio	% (em peso)
	Nióbio	% (em peso)
	Titânio	% (em peso)
	Vanádio	% (em peso)
Processo	Temp. Acabamento (TA)	°C
	Temp. Bobinamento (TB)	°C
	Espessura da bobina	mm
	Estratégia de Resfriamento	Código adimensional

2.3 Coleta de Dados

Neste estudo, foram utilizados conjuntos de resultados de várias classes de aços, exceto os aços resistentes a corrosão atmosférica (patináveis) e aços ao Boro. Devido ao maior número de dados disponíveis, optou-se inicialmente por considerar apenas os materiais com ensaios no sentido transversal. Os limites para a RNA proposta são mostrados na Tabela 3.

Tabela 3 – Limite de validade para a RNA proposta

%C	%Mn	%Si	%P	%S	%Al	%ΣMicro	E (mm)	TA (°C)	TB (°C)
0,04	0,40	0,03	0,025	0,020	0,010	0,150	2,65	840	560
0,20	1,50	0,40	Máx.	Máx.	0,080	Máx.	12,70	Mín.	Mín.

2.4 Análise dos Dados

O primeiro passo foi descartar os dados que poderiam gerar algum ruído, tais como amostras provenientes da primeira placa de uma corrida, materiais que apresentaram flutuações durante o processamento no laminador de tiras a quente ou materiais processados com o equipamento apresentando algum tipo de instabilidade. Desta maneira, foram validadas 1327 amostras.

Este conjunto de dados foi subdividido em subconjuntos de:

- treinamento (60%);
- validação (20%); e
- teste (20%).

2.5 Arquitetura

Foi realizada uma série de testes e simulações com o conjunto de dados, utilizando o *software Neurosolutions 5.0*[®] produzido pela NeuroDimension Inc. [7]. As simulações que apresentaram melhor coeficiente de correlação (R^2), utilizaram as

redes *Multilayer Perceptron* e a arquitetura definida como ideal para o presente trabalho, é apresentada na Tabela 4.

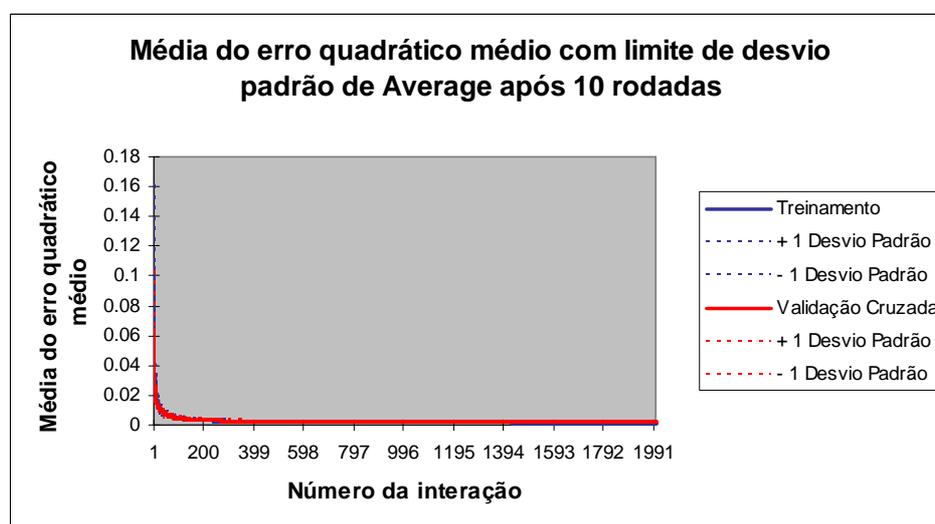
Tabela 4 – Arquitetura da RNA proposta

RNA	Arquitetura
Bobinas	14-7-7-2

Onde o primeiro número significa o número de entradas, o segundo é o número de nodos da primeira camada intermediária, o terceiro é o número de nodos da segunda camada intermediária e, por último, as saídas desejadas.

3 RESULTADOS E DISCUSSÃO

A Figura 3 mostra o resultado do erro médio quadrado após o processamento da rede de bobinas na arquitetura (14-7-7-2) com 10 ciclos de 2.000 iterações.



<i>Todas as rodadas</i>	<i>Mínimos do Treinamento</i>	<i>Desvio Padrão do Treinamento</i>	<i>Mínimos da Validação Cruzada</i>	<i>Desvio Padrão da Validação Cruzada</i>
Média do mínimo EQMs	0.001688449	4.55461E-05	0.002021909	5.0377E-05
Média do EQMs finais	0.001688449	4.55461E-05	0.002021923	5.03771E-05

Figura 3 – Média do erro quadrático médio para as amostras após treinamento em 10 rodadas de 2.000 iterações.

Nota-se que o erro médio para o conjunto de amostras foi muito baixo (erros menores que 1%), tanto para as amostras submetidas ao treinamento da rede como para aquelas submetidas à validação, o que indica uma rede com boa capacidade de generalização.

Os valores de LE e LR obtidos pela rede, após os testes também apresentaram boa aderência como mostram as Figuras 4 e 5.

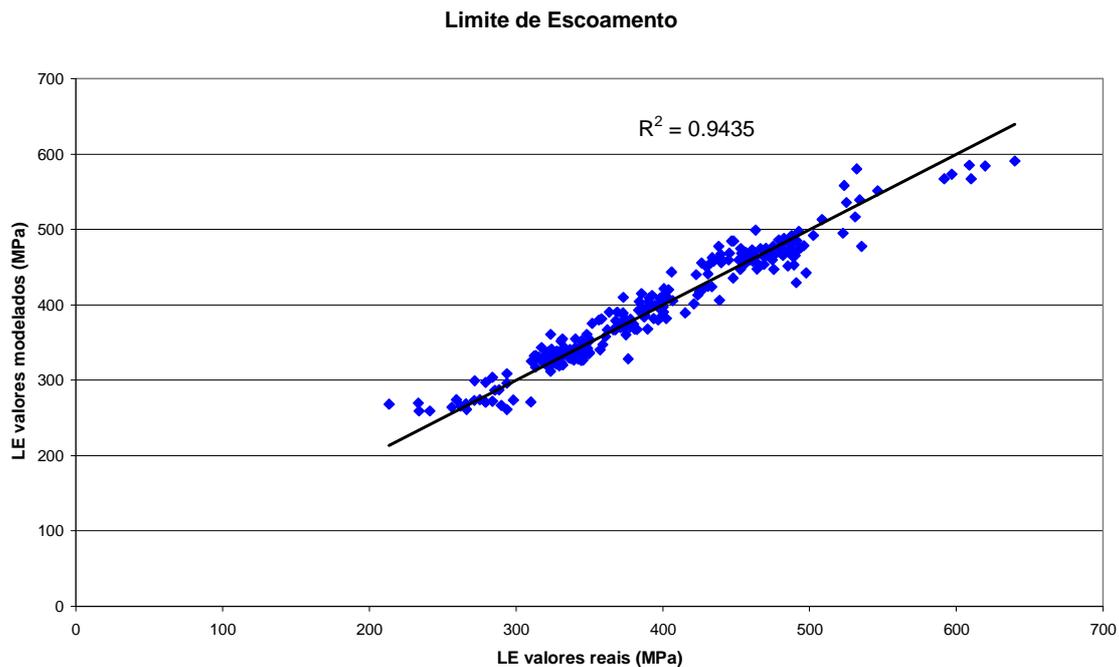


Figura 4 – Correlação entre os valores de LE reais e modelados.

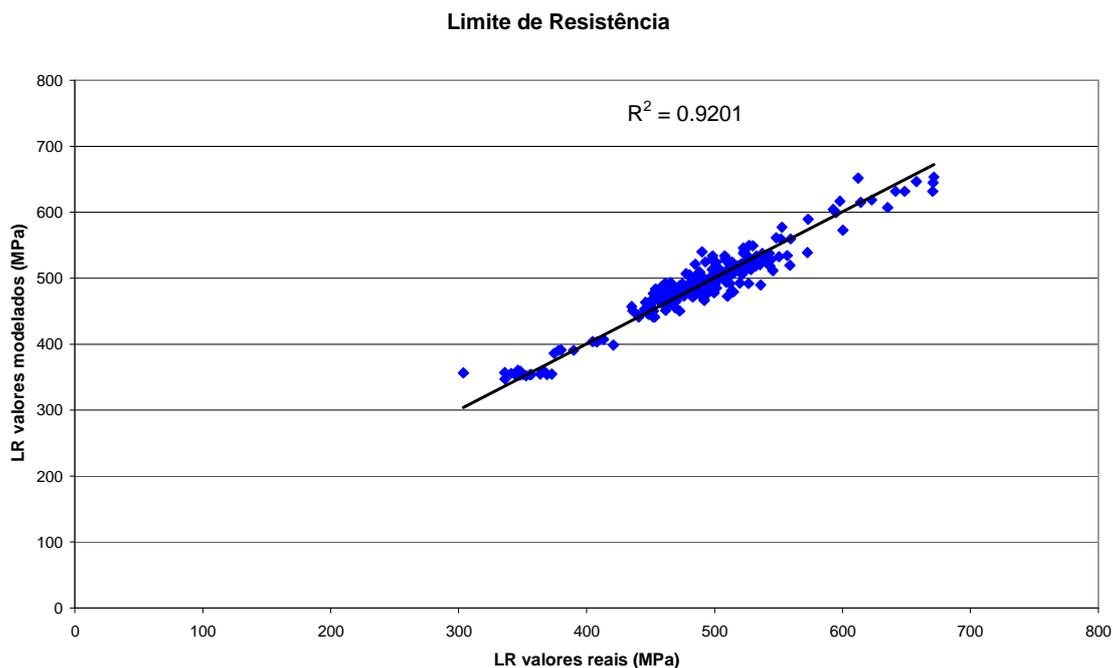


Figura 5 – Correlação entre os valores de LR reais e modelados.

Um conjunto composto de 30 amostras com composições e parâmetros distintos e oriundos de dados reais foi submetido à RNA. Com este conjunto, foi possível mensurar o erro entre os valores obtidos pela RNA e os valores reais obtidos através de ensaio de tração. A Tabela V mostra os resultados obtidos deste teste.

Tabela 5 – Resultados obtidos pela RNA, para um conjunto de dados, com valores de LE e LR obtidos em ensaios de tração

	Limite de Escoamento		Limite de Resistência	
	Valor	Erro	Valor	Erro
Mínimo	0,09MPa	0,02%	0,73MPa	0,14%
Média	17,7MPa	5,5%	13,7MPa	3,2%
Máximo	42,42MPa	13,16%	44,09MPa	11,93%
Desvio Padrão	13,3MPa	4,53%	12,29MPa	3,14%

Os resultados deste conjunto foram bastante satisfatórios, uma vez que a maior diferença encontrada, para o LE, foi de aproximadamente 43 MPa. Se considerarmos que as faixas para esta propriedade, em normas nacionais e internacionais varia entre 150 MPa 200 MPa (a norma API 5L X65 PSL2, por exemplo, especifica uma faixa para o LE de 152 MPa).⁽⁸⁾ Com relação ao LR, o erro médio absoluto em relação ao valor medido através do ensaio de tração, apresentou um valor ligeiramente melhor (3,15%) do que o obtido para o LE (5,50%).

Outro teste que permite verificar se o aprendizado da rede está de acordo com os conceitos metalúrgicos é a análise de sensibilidade. Nesta análise, a RNA mostra quais as variáveis de entrada têm maior influência sobre as saídas, atribuindo um “peso” as variáveis. A Figura 6 mostra o resultado desta análise.

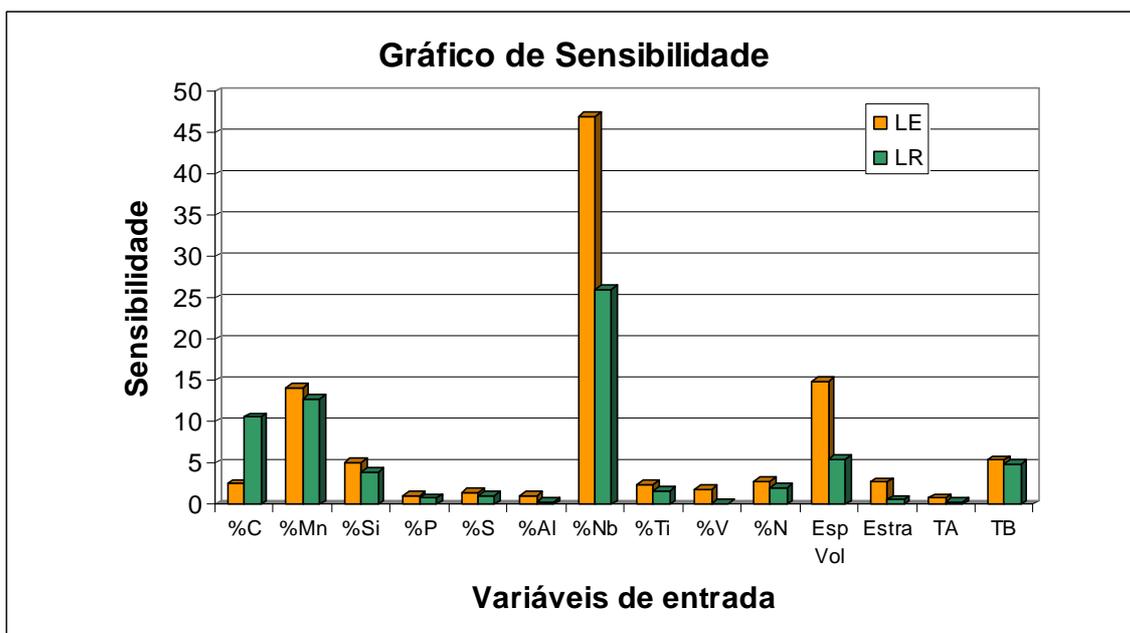


Figura 6 – Análise de sensibilidade realizada a partir dos dados de treinamento da RNA.

Além de conhecer quais as variáveis foram consideradas mais importantes pela RNA, é importante saber de que maneira estas variáveis contribuem para o resultado das saídas desejadas, no caso o LE e LR, conforme mostrado na Figura 7.

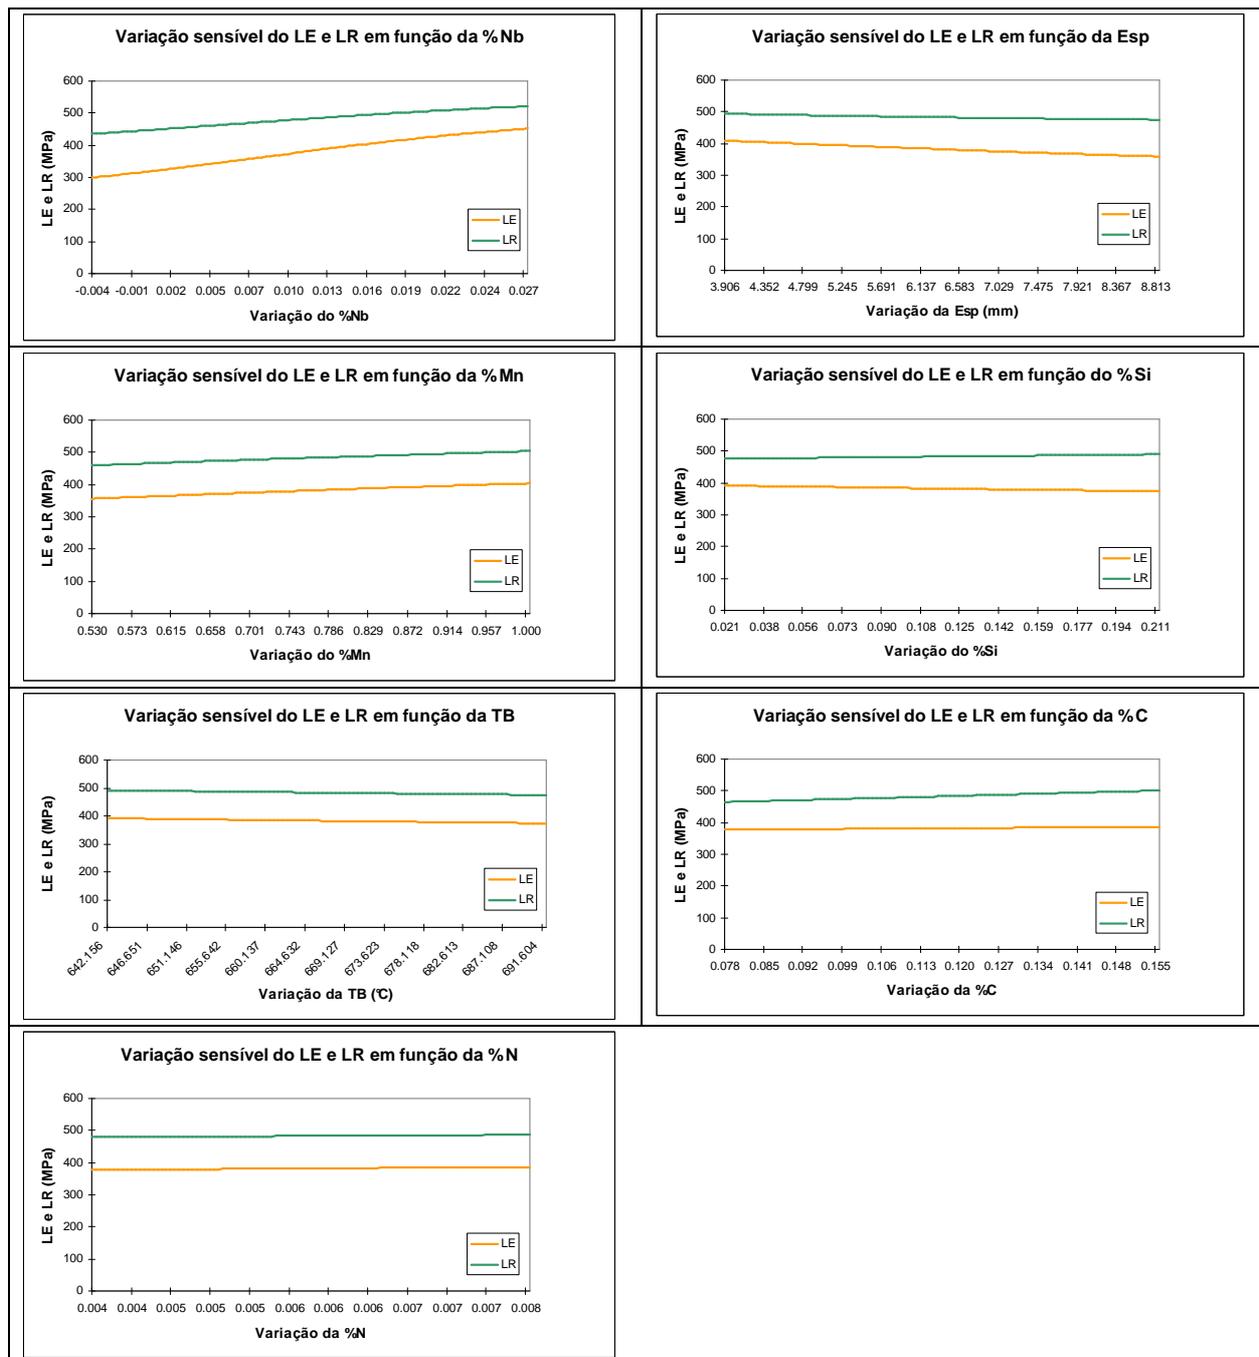


Figura 7 – Variação sensível do LE e LR em função das principais variáveis de entrada da RNA.

A RNA se mostrou capaz de interpretar o comportamento das variáveis conforme esperado.

A literatura apresenta várias equações que permitem o cálculo do LE. Em um trabalho realizado recentemente na USIMINAS Cubatão,⁽⁹⁾ foi possível verificar que, desta variedade de equações para predição das propriedades mecânicas, as equações de Grozier e Bucher (Eq.1)⁽¹⁰⁾ e de Irvine e Pickering (Eq.2),⁽¹⁰⁾ respectivamente, foram as que apresentaram melhores resultados para aços estruturais. Desta forma, foi possível comparar os resultados obtidos pela RNA proposta:

$$\sigma_{ys} = 91,7 + 40,7(\%Mn) + 70,4(\%Si) + 1,5(\%Perlita) + 521,776(1/\sqrt{d}) \quad (\text{Eq.1})$$

$$\sigma_{ys} = 91,7 + 32,4 (\%Mn) + 84,1 (\%Si) + 84,1 (\%Cu) + 13,7 (\%Mo) - 31(\%Cr) + 4,345(\%N_{free}) + 1,5(\%Perlita) + 521,776(1/\sqrt{d}) \quad (\text{Eq.2})$$

Onde d é o tamanho de grão em microns (μm) e %Perlita é a fração volumétrica percentual da 2ª fase. Estas equações apresentam bons resultados para materiais tipicamente estruturais e que apresentam endurecimento por solução sólida, por segunda fase e pelo tamanho de grão ferrítico (TGF).⁽⁹⁾

Utilizando o conjunto de dados utilizado para teste da RNA e o segundo conjunto de produção, foram calculados os valores de LE utilizando a Eq.1 e a Eq.2. Como estas equações utilizam a fração volumétrica de perlita, utilizou-se a equação (Eq.3), proposta por Morais, Perez e Borges⁽⁹⁾ que correlacionam a composição química (através do Ceq) com o percentual de perlita.

$$\%Perlita = Ax(\%Ceq)^n \quad (\text{Eq.3})$$

Onde A e n são constantes e foram obtidas por regressão.

Sabe-se que quanto menor a espessura de um produto laminado a quente maior tende a ser o grau de trabalho termomecânico, ocorrido durante a etapa final da laminação.⁽⁹⁾ Este trabalho induz a um refinamento maior do tamanho de grão final do produto, elevando sua resistência mecânica. Assim quanto menor a espessura do produto final, menor tende a ser o tamanho de grão do aço. Esta dependência foi correlacionada através das equações (Eq.4) e (Eq.5), onde Eq.5 corrige o efeito de espessuras menores que 5 mm.⁽⁹⁾

$$\text{TGF} = A + B \times \text{espessura} + C \times (\text{espessura})^2 \quad (\text{Eq.4})$$

$$\text{Efeito} = D + E \times \exp[F/(\text{espessura})^G] \quad (\text{Eq.5})$$

Onde A , B , C , D , E , F e G são constantes, TGF é o tamanho de grão ferrítico em microns (μm) e a espessura está em milímetros (mm). O valor destas constantes foi determinado conforme descrito no trabalho de Morais, Perez e Borges.⁽⁹⁾

Comparando a aplicação da Eq.1 e da Eq.2 com suas respectivas correções pelas Eq.3, Eq.4 e Eq.5, foi possível observar que os resultados gerados pela RNA apresentaram melhor desempenho, sendo bastante satisfatórios. A Figura 8 mostra a correlação entre o LE Real e o LE obtido pelos modelos.

Nota-se que os valores modelados pelas Eq.1 e Eq.2 (corrigidas) e também pela RNA apresentaram boa correlação com os valores reais para os materiais de baixa e média resistência ($< 350\text{MPa}$). Entretanto, para os aços de alta resistência ($\text{LE} \geq 350\text{MPa}$) as equações apresentam uma dispersão bem superior ao previsto pela RNA.

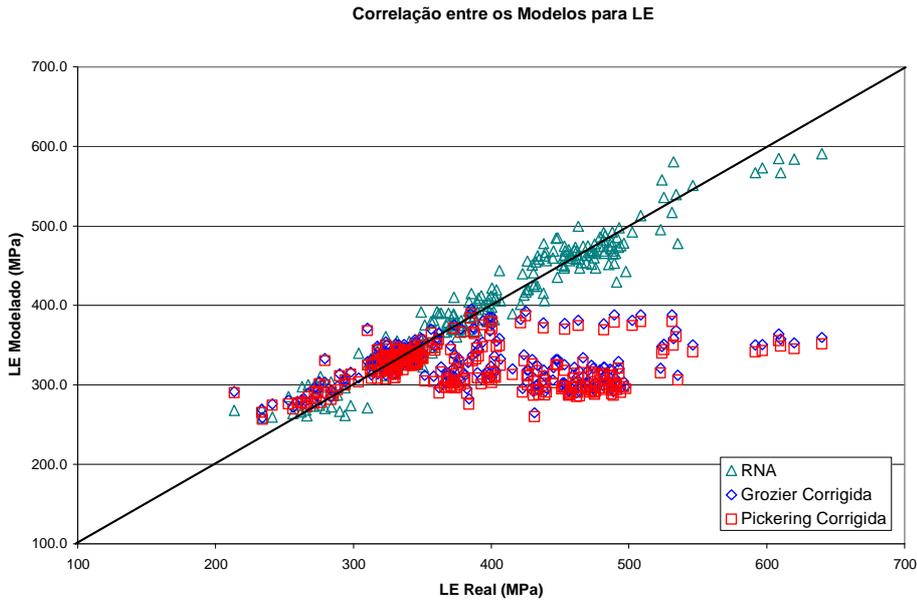


Figura 8 – Correlação entre o Limite de Escoamento real e o modelado pelas Equações corrigidas e a RNA proposta.

Este erro pode ser atribuído ao fato de que estes aços possuem elementos microligantes e que estas equações não contemplam os mecanismos de precipitação de carbonitretos e refino de grão adicional ocasionado pela presença dos microligantes (especialmente Nb, V, Ti). Na Figura 9, está ilustrado que os resultados obtidos pela RNA estão bem correlacionados com os resultados reais, inclusive para os aços microligados, ao contrário do modelo anterior, que não descrevem bem as propriedades dos aços microligados.

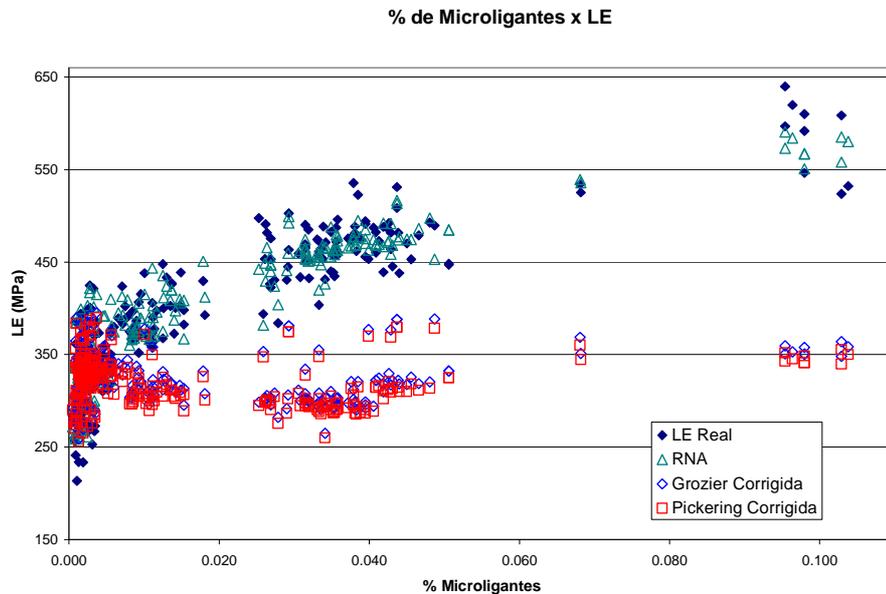


Figura 9 – Relação entre a %microligantes e o LE previsto pela RNA e as equações da literatura corrigidas.

Quanto ao LR, conforme citado por Bodnar, Fletcher e Manohar⁽¹⁰⁾ e comprovado recentemente por Moraes, Perez e Borges,⁽⁹⁾ há a possibilidade de

modelar o limite de resistência através de uma regressão linear em função no carbono equivalente (Ceq), definido pela equação (Eq.6), que inclui o %Si no cálculo:⁽⁵⁾

$$\%Ceq = \%C + (\%Mn + \%Si) / 6 + (\%Mo + \%Cr + \%V) / 5 + (\%Ni + \%Cu) / 15 \quad (\text{Eq.6})$$

Bodnar, Fletcher e Manohar⁽¹⁰⁾ descreveram a aplicação da regressão linear para aços carbono-manganes normalizados, tal como a mostrada abaixo:

$$LR = A + B \times \%Ceq \quad (\text{Eq.7})$$

No trabalho de Moraes, Perez e Borges,⁽⁹⁾ foi introduzida uma correção para oferecer aplicabilidade a esta metodologia para aços carbono manganês laminados a quente, nos quais a temperatura de laminação final está acima da temperatura Ar_3 e cuja temperatura de bobinamento não produz transformações de fase, sendo estes aços de estrutura ferrita-perlita.⁽³⁾ A equação (Eq.8) utilizada, tem a seguinte forma:

$$LR = [A + B \times \%Ceq] \times f(\text{espessura}) \quad (\text{Eq.8})$$

Onde A e B são constantes, a espessura é expressa em milímetros (mm) e o LR é obtido em megapascal (MPa).

Os resultados obtidos com o modelamento pela regressão e a RNA proposta, são mostrados na Figura 10.

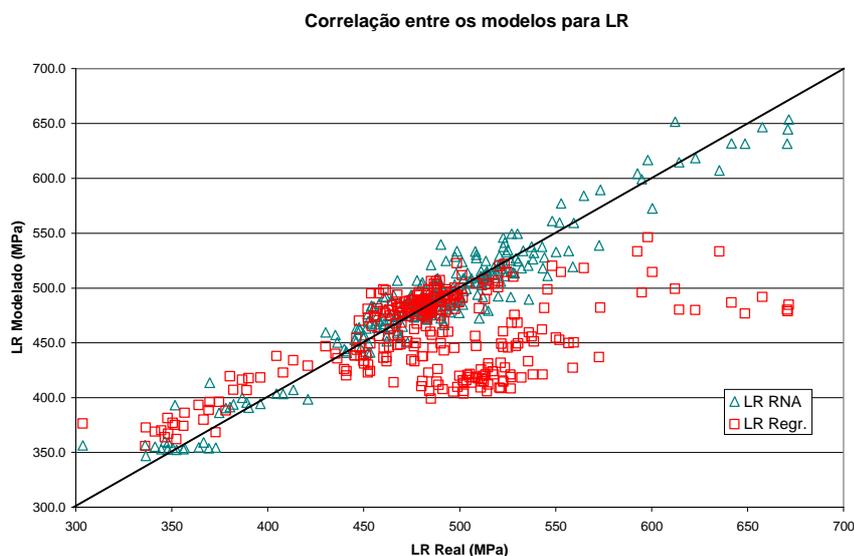


Figura 10 - Correlação entre o Limite de Resistência real e o modelado pela Regressão e a RNA proposta.

Os dois modelos apresentaram boa correlação com os valores de LR obtidos através dos ensaios de tração. No entanto, os valores obtidos pela RNA apresentam melhor correlação e menor dispersão, principalmente para os materiais de maior resistência.

4 CONCLUSÕES

Pode-se concluir que a utilização de RNA's para a previsão de propriedades mecânicas utilizando variáveis básicas de processo mostrou ser viável, uma vez que os resultados de correlação entre os valores reais e modelados foram superiores aos encontrados utilizando equações (submetidas a fatores de correção) descritas na literatura.

A arquitetura proposta para a RNA de materiais em bobina, utilizando variáveis básicas de processo, mostrou boa capacidade de generalização e aprendizado, com valores de coeficientes de correlação de 0,94 para o LE e 0,92 para o LR.

Como em qualquer modelamento, o melhor desempenho da rede se dá entre os limites utilizados para a sua construção, conforme listados na Tabela 3.

REFERÊNCIAS

- 1 ABM, 2º Workshop sobre inovações para o desenvolvimento de aços de elevado valor agregado - Foco Indústria Automotiva. Santos, 2008. Apresentações. (<http://www.abmbrasil.com.br/cim/downloads.asp> - buscar pelo título do evento). ABM. Acesso em: 19 fev. 2009.
- 2 MORAIS, W.A.; BORGES, H.C.; Utilização de aços de elevada resistência mecânica em aplicações de engenharia: implicações técnicas e econômicas práticas. In: 63º CONGRESSO ANUAL DA ABM, Santos-SP, Jul. 28 – Ago.1º, 2008, p. 1 CD.
- 3 BORGES, H.C., Predição de propriedades mecânicas em aços laminados a quente utilizando redes neurais adaptativas. 87p. Monografia (MBA em Siderurgia) – Universidade de São Paulo, São Paulo, 2008.
- 4 BRAGA, A. P.; CARVALHO, A. C. P. L. F; LUDERMIR, T. B. Redes neurais artificiais. Rio de Janeiro: LTC, 2000. p.262.
- 5 TAKAHASHI, H.J.; RABELO, G.B.C.; TEIXEIRA, R.A. Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional. In: ABM. SEMINÁRIO DE AUTOMAÇÃO DE PROCESSOS, 11, 2007, Porto Alegre. Anais. São Paulo: Tec Art Editora. 2007. p. 162-171.
- 6 BHADESHIA, H. K. D. H. Neural Networks in Material Science. ISIJ International, Tokyo, v.39, n.10, p.966-979, 1999.
- 7 NeuroSolutions: Premier Neural Network Development Environment. NeuroDimension, Inc. (<http://www.neurosolutions.com>). Acesso em: 19 fev. 2009.
- 8 COSIPA, Catálogo de produtos laminados (<http://www.cosipa.com.br> – caminho: produtos e serviços - catálogo de produtos - laminados). Acesso em: 19 fev. 2009.
- 9 MORAIS, W. A.; PEREZ, F. A.; BORGES, H. C. Modelamento e Quantificação da Relação Propriedades x Microestrutura nos Aços Estruturais Laminados a Quente da COSIPA. In: 62º CONGRESSO ANUAL DA ABM, Vitória-ES, Jul. 23-27, 2007, p.3285-3296. 1 CD.
- 10 BODNAR, R. L.; FLETCHER, F. B.; MANOHAR, M.; The Physical Metallurgy of Normalized Plate Steels. MS&T Conference Proceedings, New Orleans, pp. 89-109, 2004.
- 11 AWS D 1.1/D 1.1 M:2002 - "Structural Welding Code – Steel", Annex XI.