

MODELO DE PREVISÃO DE PROPRIEDADES MECÂNICAS DE PERFIS ESTRUTURAIS LAMINADOS A QUENTE: UMA ABORDAGEM EM REDES NEURAIS ARTIFICIAIS¹

Alisson Paulo de Oliveira²
Paulo José Modenesi³

Resumo

Este trabalho teve como objetivo a construção de um modelo matemático empírico para previsão das propriedades mecânicas (Limite de Escoamento, Limite de Resistência e Alongamento) de perfis estruturais de aço laminados a quente ASTM A572-50. Este modelo é baseado em variáveis de processo de laminação além da composição química do aço. Escolheu-se a metodologia de Redes Neurais Artificiais, pois esta pode produzir resultados com menor erro se comparada a outras técnicas tradicionais. Várias ferramentas estatísticas foram utilizadas para auxiliar no desenvolvimento do modelo: Análise de Variância, Histogramas, Regressão Linear Múltipla e Gráficos de Dispersão. Estas ferramentas foram fundamentais para a compreensão e interpretação da variabilidade encontrada no banco de dados. Elas também foram utilizadas para definir a arquitetura final das Redes Neurais Artificiais. Observou-se que os resultados obtidos a partir dos modelos concordaram bem com os resultados verificados nas análises de regressão e com as tendências esperadas considerando aspectos metalúrgicos do processo. Os modelos desenvolvidos permitiram avaliar o efeito isolado de diferentes variáveis e seus resultados foram superiores aos obtidos por técnicas estatísticas tradicionais. Verificou-se que a dispersão dos dados é um fator de grande importância para o sucesso de qualquer modelo de previsão. O modelo permitirá que o projeto de composição química seja realizado com maior precisão, menores custos de produção além de melhorar a compreensão do efeito de cada variável de processo nas propriedades mecânicas dos perfis estruturais laminados a quente.

Palavras-chave: Redes neurais artificiais; Perfis estruturais laminados a quente; Análises estatísticas; Dispersão dos dados.

PREDICTION MODEL OF HOT ROLLED STRUCTURAL SECTIONS MECHANICAL PROPERTIES: AN ARTIFICIAL NEURAL NET APPROACH

Abstract

This work aimed to develop an empirical mathematical model for mechanical properties (Yield Strength, Tensile Strength and Elongation) prediction of hot-rolled structural sections of steel grade ASTM A572-50. This model is based in some rolling-mill process variables and the chemical composition of the steel. The methodology of Artificial Neural Net was chosen because it tends to produce results with lower errors than those produced by other traditional techniques. Some statistical tools were used to help model development: ANOVA, Histogram, Regression Analysis and Scatter Plot. These tools were fundamental for the comprehension and interpretation of the variability found in the data bank. They were also used to define the final architecture of the Artificial Neural Nets. It was observed that the results obtained from the models agreed well to results verified from regression analysis and to the expected general behavior deduced from metallurgical principles. The obtained results were superior to that obtained from traditional statistical techniques and it was possible to verify the isolated effect of each variable. As expected, the results of the present work confirm that data dispersion is a key factor for the success of the development and application of any prediction model. This model will improve the accuracy of the chemical composition design of the steel, reduce production costs and improve the comprehension of the effect of each process variable on the mechanical properties of hot-rolled structural sections.

Key words: Artificial neural nets; Hot-rolled structural sections; Statistical analysis; Data dispersion.

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

² *Engenheiro Metalurgista, Mestre em Engenharia Metalúrgica e de Minas, Engenheiro de Desenvolvimento de Produtos e Processos da Gerdau Açominas S/A;*

³ *Ph.D., Professor do Curso de Pós Graduação em Engenharia Metalúrgica e de Minas da UFMG.*

1 INTRODUÇÃO

O processo de laminação de perfis estruturais apresenta como grande desafio o acerto de composição química visando o atendimento das propriedades mecânicas impostas pelas diferentes normas internacionais. Tal desafio se origina na compreensão do efeito das diversas variáveis envolvidas na evolução das propriedades mecânicas ao longo do processo de laminação.

Diferentes técnicas têm sido utilizadas no desenvolvimento de modelos para a previsão de propriedades mecânicas de produtos de aço laminados a quente com destaque para a Análise de Regressão Linear Múltipla e as Redes Neurais Artificiais. A análise de regressão é uma técnica utilizada para modelar a relação entre duas ou mais variáveis baseada no ajuste de uma dada equação a valores conhecidos dessas variáveis através da minimização da soma do quadrado da diferença entre os valores preditos pela equação e a variável dependente do conjunto considerado. Por sua vez, as Redes Neurais Artificiais são modelos computacionais baseados em estudos do funcionamento do cérebro humano, freqüentemente classificados como “Caixa Preta” ou “Caixa Cinza”. Em um estudo comparativo entre a utilização de Regressão Múltipla Linear e Redes Neurais Artificiais (RNA) na previsão das propriedades mecânicas de produtos de aço, concluiu-se que as RNA's forneceram modelos de previsão mais precisos do que aqueles obtidos com o uso de modelos de regressão múltipla linear.⁽¹⁾

O uso de uma ferramenta de simulação com um modelo residente baseado em Redes Neurais Artificiais ou outro método alternativo pode, em princípio, permitir que o projeto de composição química seja realizado com o conhecimento das diversas variáveis operacionais envolvidas implicando, assim, em redução de custos. Neste contexto, quanto mais preciso for o modelo adotado mais eficiente e poderosa se tornará tal ferramenta. Este trabalho tem como objetivo desenvolver um modelo para previsão das seguintes propriedades mecânicas de Perfis Estruturais Laminados a Quente:

- Limite de Escoamento (LE);
- Limite de Resistência (LR);
- Alongamento (A).

1.1 As Redes Neurais Artificiais

As Redes Neurais Artificiais são modelos computacionais que tentam simular o processo que ocorre no cérebro humano e sistema nervoso durante o reconhecimento de padrões, filtragem de informações e controle funcional.⁽²⁻⁴⁾ O uso destas redes com o objetivo de prever as propriedades mecânicas dos materiais é um conceito relativamente novo, mas que tem recebido considerável interesse nos últimos anos.⁽³⁻⁵⁾

A atração das Redes Neurais Artificiais vem da marcante característica de processamento de informações dos sistemas biológicos, tais como não linearidade, alto paralelismo, robustez, tolerância à falha, aprendizado, habilidade em manusear informações imprecisas e sua capacidade de generalizar.^(6,7) A característica mais notável desta técnica é que ela pode ser aplicada a uma vasta variedade de problemas muito dos quais eram considerados como extremamente complexos.⁽⁸⁾

A Figura 1 ilustra o funcionamento de uma Rede Neural Artificial com três camadas construída para prever a probabilidade de um evento (morte por uma doença hipotética) em função de duas variáveis (idade e sexo do paciente).⁽⁶⁾

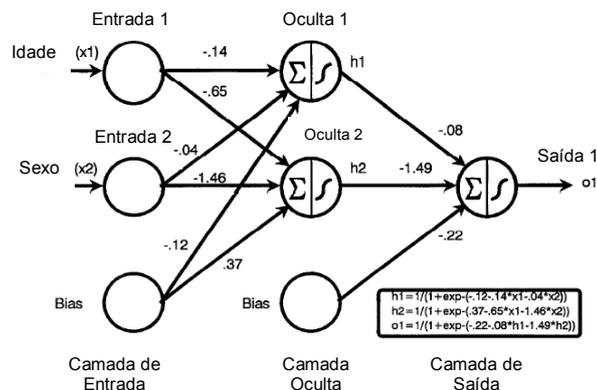


Figura 1: Diagrama de uma rede neural artificial treinada para prever a probabilidade de um paciente morrer de uma doença hipotética com base na sua idade (x_1) e sexo (x_2)⁽⁶⁾

As Redes Neurais podem ter múltiplas saídas.⁽⁶⁾ Os Nodos na camada oculta (neurônios) contêm valores intermediários os quais são calculados pela Rede. Cada um dos nodos ocultos e de saída contém uma função denominada “Função de Ativação”. Os nodos ocultos permitem à Rede modelar relações não lineares complexas entre as variáveis de entrada e as de saída.

Usualmente, cada nodo na camada de entrada é conectado a cada nodo na camada oculta e cada nodo na camada oculta é conectado a cada nodo na camada de saída.⁽⁶⁾ Na Figura 1, há dois Nodos de entrada onde os valores de Idade, x_1 , e sexo, x_2 , são inseridos na rede junto com um peso de ajuste (“bias”) o qual é o equivalente do termo intercepto encontrado em um modelo de regressão.

Em cada nodo da camada oculta, os dados de entrada, multiplicados pelos respectivos pesos de conexão, são somados juntamente com o peso de ajuste. O resultado é usado para calcular a saída do nodo através de uma função de ativação. A ativação de cada nodo oculto, h_1 e h_2 , é então multiplicada por um segundo conjunto de Pesos de Conexão (Exemplo: 0,8, 1,49) e o resultado adicionado ao peso de ajuste (Exemplo: -0,22). Uma transformação das entradas balanceadas aos Nodos de saída é aplicada de modo a se determinar a saída total da Rede.

2 MATERIAIS E MÉTODOS

Escolheu-se um perfil I com espessura nominal igual a 11,0 mm em função de apresentar as seguintes particularidades:

- Amostragem para ensaios mecânicos feita na aba, o que implica em uma menor variabilidade de resultados;
- Perfil I com quantidade elevada de ensaios realizados na norma ASTM A572-50. Para o presente estudo, partiu-se de um total de 461 conjuntos de resultados.

As seguintes informações foram utilizadas na construção do Modelo de Previsão de Propriedades Mecânicas:

- Composição química do aço;
- Temperatura final de laminação na aba;
- Espessura medida do corpo de prova proveniente da aba do perfil (A espessura da aba é a mesma do corpo de prova);

- Limite de Resistência, Limite de Escoamento e Alongamento.

Após análise dos dados disponíveis, observou-se que 11 dos elementos químicos analisados não tinham valores de resultados indicados em todos os registros, sendo assim descartados. Por serem elementos residuais (Ni, Co, Ca, Ti, B, W, Zr, As, Sb, Te e Pb) considera-se não haver impacto para o modelo de previsão.

Para o cálculo da redução percentual durante o processo de laminação utilizou-se como espessura inicial a espessura do Beam Blank na região da aba:

$$\%Redução = \frac{(E_f - E_i)}{E_i} * 100$$

Nesta equação, E_f é a espessura final do perfil laminado no ponto de amostragem e E_i é a espessura inicial da aba do Beam Blank.

2.1 Análises Estatísticas das Variáveis do Banco de Dados

As seguintes análises e ações foram realizadas:

- Análise de Correlação entre as diversas variáveis de entrada e as saídas;
- Caracterização estatística dos dados de entrada;
- Tratamento de Dados: Intervalo +/- 3 desvios padrões;
- Eliminação de pontos discrepantes.

Estas técnicas foram utilizadas visando eliminar a presença de dados que pudessem comprometer a confiabilidade do banco de dados.

2.2 Desenvolvimento do Modelo

O tipo de Rede Neural Artificial mais comumente utilizado tanto em aplicações gerais como na previsão de propriedades mecânicas é o de Propagação Reversa.

Uma Rede Neural Artificial do tipo Propagação Reversa consiste de uma camada de entrada (variáveis de entrada para o problema), uma camada de saída (variáveis dependentes) e uma ou mais camadas ocultas (responsáveis pela interpretação dos dados).

A Tabela 1 mostra os principais parâmetros utilizados para a construção do modelo. O desenvolvimento do modelo seguiu a metodologia citada em Basheer ⁽⁹⁾ e em recomendações do programa MATLAB ⁽¹⁰⁾.

Tabela 1: Resumo das Características das Redes Neurais Artificiais

Característica	Critério	Comando
Tipo de Perfí Estrutural	Espessura, t, = 11,0 mm	-
Partição e Tamanho do Banco de Dados	Conjunto de Treinamento = 75%, Conjunto de Validação = 25%. Número de Dados = 461.	RANPERM
Normalização	-	$x_i = \frac{z_i - z_i^{min}}{z_i^{max} - z_i^{min}}$
Inicialização dos Pesos da Rede	-	INITNW
Taxa de Aprendizado da Rede	-	TRAINDX
Função de Transferência	-	TANSIG
Critério de Convergência	-	$SSE = \frac{1}{N} \sum_{p=1}^N \sum_{i=1}^M (t_{pi} - O_{pi})^2$
Erro Mínimo Objetivado	0,001	-
Número de Ciclos de Treinamento	700	-
Modo de Treinamento	BT	-
Número de Camadas Ocultas	1	-
Tamanho da Camada Oculta, LE	6	-
Tamanho da Camada Oculta, LR	6	-
Tamanho da Camada Oculta, A	10	-
Processo de Treinamento da Rede	-	TRAINBR

A etapa seguinte ao desenvolvimento da RNA foi a simulação dos valores de propriedades mecânicas a partir do conjunto de dados de entrada. Tais resultados foram confrontados com os dados reais das propriedades mecânicas e então calculados os erros percentuais de cada amostra e o erro percentual médio da simulação.

A partir dos valores simulados e erros percentuais calculados, elaboraram-se os seguintes gráficos para análise dos resultados da validação da RNA:

- Gráfico de correlação linear: valor medido x valor previsto;
- Curva “Amostra X Erro Percentual” com indicação do erro médio.

Os resultados obtidos no processo de treinamento foram analisados com base nos valores máximo, mínimo e médio do erro percentual e pela correlação linear entre os valores estimados e medidos. Foram também elaborados modelos de regressão linear múltipla para comparar os seus resultados com os obtidos pelas redes neurais artificiais.

3 RESULTADOS

3.1 Seleção das Variáveis das Redes Neurais Artificiais

Realizou-se análise de correlação entre as variáveis de saída e as variáveis de entrada (composição química e variáveis de laminação). A escolha das variáveis de entrada foi feita com base na análise de correlação entre estas e as variáveis de saída, envolvendo a elaboração da matriz de correlação, a avaliação dos coeficientes de correlação obtidos e a eliminação dos elementos químicos considerados residuais, ou seja, não adicionados intencionalmente no processo de aciaria. As seguintes variáveis foram incluídas no modelo:

- Composição Química: Apenas os elementos C, Mn, Si, S, Cr, Nb e N;
- Variáveis de Processo: Temperatura Final e Redução Total de Laminação.

Após esta etapa e a eliminação dos pontos discrepantes, obteve-se um banco de dados com 444 ocorrências com as variáveis indicadas na Tabela 2.

Tabela 2: Variáveis de entrada e de saída incluídas nos modelos.

Variável	Descrição	Máximo	Mínimo
Y1	LE (MPa)	459,97	378,35
Y2	LR (MPa)	551,99	469,10
Y3	Alongamento (%)	34,50	23,50
X1	C (%)	0,1309	0,0808
X2	Mn (%)	1,4540	1,2020
X3	Si (%)	0,2500	0,1560
X4	S (%)	0,0134	0,0031
X5	Cr (%)	0,0470	0,0130
X6	Nb (%)	0,0360	0,0200
X7	N ₂ (%)	0,0069	0,0019
X8	Temperatura Final de Laminação (TFL) (°C)	1007,05	939,84
X9	% Redução na Espessura (%)	86,49	84,73

3.2 Definição da Arquitetura das Redes Neurais Artificiais

No desenvolvimento dos modelos de rede neural artificial, utilizou-se uma arquitetura com duas camadas (camada oculta e de saída). Foram desenvolvidas três redes, uma para cada variável de saída (limites de resistência e de escoamento e alongamento).

A variação dos parâmetros de desempenho da rede (Erros e Correlação Linear) observada durante o treinamento criou dificuldades para se definir o número ótimo de neurônios na camada oculta. Assim utilizou-se uma abordagem estatística com a realização de 10 simulações por configuração de rede (número de neurônio na camada oculta), avaliando-se a variação dos valores máximo, mínimo e médio do erro percentual na validação de LE, LR e A e a correlação entre os valores estimados e medidos destas variáveis. A Tabela 3 mostra o resultado desta análise.

Tabela 3: Avaliação do efeito do tamanho da camada oculta no desempenho dos modelos.

Propriedade Mecânica	Número de Neurônios	Erro Mínimo			Erro Máximo			Erro Médio			Correlação			
		n	Média	Desvio Padrão	p-valor	Média	Desvio Padrão	p-valor	Média	Desvio Padrão	p-valor	Média	Desvio Padrão	p-valor
LE	4	10	0,04	0,0359	0,327	7,377	0,712	0,803	2,241	0,1369	0,711	65,74	3,442	0,278
	5	10	0,035	0,0255	0,327	7,485	1,316	0,803	2,222	0,1707	0,711	66,8	4,171	
	6	10	0,027	0,0183	0,327	7,26	0,521	0,803	2,257	0,1047	0,711	67,37	2,932	
	7	10	0,282	0,7208	0,327	7,904	2,199	0,803	2,268	0,1051	0,711	64	4,067	
	8	10	0,028	0,0346	0,327	7,379	0,57	0,803	2,307	0,1596	0,711	64,81	4,286	
LR	4	10	0,023	0,02058	0,748	6,108	0,795	0,216	1,678	0,0802	0,032	71,22	4,93	0,095
	5	10	0,021	0,02234	0,748	5,799	0,556	0,216	1,606	0,1293	0,032	73,78	3,005	
	6	10	0,018	0,01229	0,748	5,969	0,768	0,216	1,566	0,1149	0,032	75,07	2,384	
	7	10	0,025	0,0324	0,748	6,726	1,08	0,216	1,679	0,127	0,032	71,58	4,594	
A	4	10	0,045	0,05523	0,444	22,508	4,275	0,416	4,907	0,2176	0,883	31,34	9,455	0,287
	5	10	0,037	0,03057	0,444	20,226	4,224	0,416	4,879	0,2566	0,883	32,54	4,155	
	6	10	0,039	0,04433	0,444	22,238	4,617	0,416	4,955	0,4831	0,883	31,55	6,686	
	7	10	0,049	0,03348	0,444	20,289	4,809	0,416	4,889	0,2125	0,883	32,33	5,27	
	8	10	0,04	0,04619	0,444	20,092	2,243	0,416	4,922	0,3531	0,883	36,45	3,808	
	9	10	0,052	0,04022	0,444	18,953	4,035	0,416	4,803	0,4016	0,883	36,25	3,983	
	10	10	0,078	0,05731	0,444	20,398	2,533	0,416	4,763	0,3856	0,883	35,03	7,765	

As configurações escolhidas e os critérios utilizados para esta escolha foram:

- Limite de Escoamento: Seis neurônios: Coeficiente de Correlação;
- Limite de Resistência: Seis neurônios: Erro médio e Coeficiente de Correlação;
- Alongamento: Dez neurônios: Erro médio.

3.3 Treinamento das Redes Neurais Artificiais – LR

A Figura 2 mostra a evolução da Soma Quadrática dos Erros (SSE) para os dados de treinamento da Rede Neural para previsão do Limite de Resistência (LR). A Figura 3 compara os valores medidos e modelados do limite de resistência para as 111 amostras (25% do banco de dados) utilizadas nos testes de validação da RNA e a figura 3 mostra o erro na avaliação de cada amostra nesta etapa.

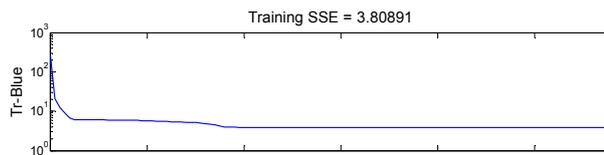


Figura 2: Treinamento da RNA para previsão de LR. n épocas: 116.

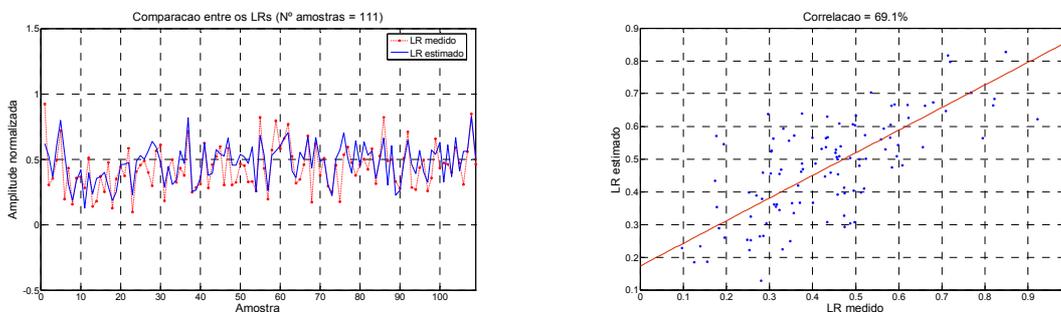


Figura 3: Resultados da Validação da RNA para previsão de LR.

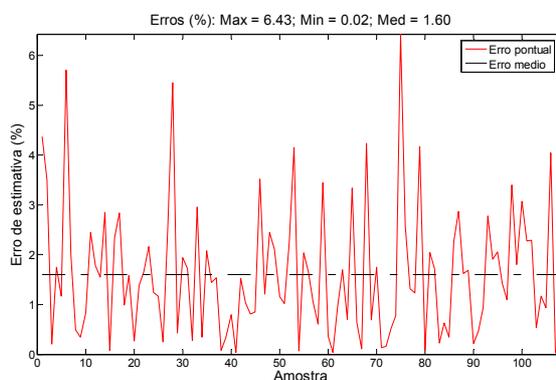


Figura 4: Erro de estimativa de LR para cada amostra.

3.4 Simulação das Propriedades Mecânicas

Nesta etapa foi verificado se o modelamento por RNA é coerente com alguns dos aspectos metalúrgicos do processo de laminação.

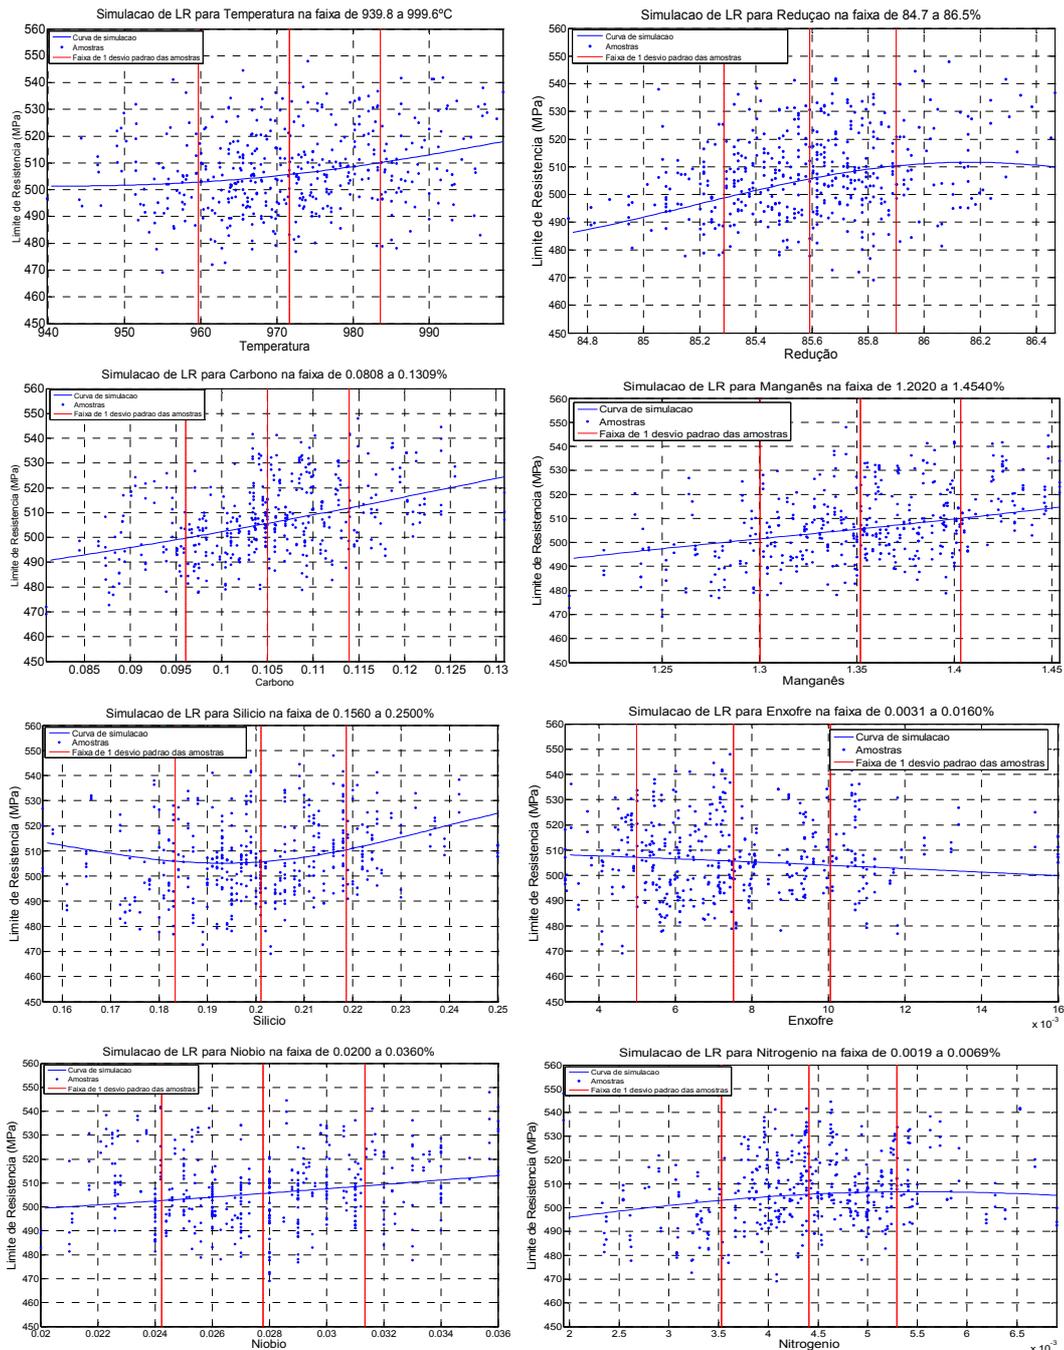


Figura 5: Limite de Resistência em função das variáveis de entrada

4 DISCUSSÃO

Para o Limite de Resistência, os resultados obtidos no processo de simulação nas faixas de validade também foram coerentes com as tendências inicialmente observadas nas análises gráficas inicialmente realizadas. A dispersão verificada é devida em parte à origem industrial dos dados, a faixa relativamente estreita de variação das variáveis e pela presença de regiões onde a quantidade de dados é menor, o que torna o aprendizado da Rede Neural Artificial menos eficiente.

A simulação dos resultados de LR traz alguns pontos importantes:

a) LR em função da Temperatura Final de Laminação (°C): Observa-se tendência de aumento de LR com o aumento da temperatura, o que não é usualmente esperado. Tal fato é possivelmente causado pela variação relativamente estreita de

temperatura e a elevada variabilidade dos dados usados. Além disto, ele pode estar ligado à alta temperatura final de laminação, em torno de 950°C a 1.000°C,⁽¹¹⁾ fora da faixa ideal, em torno de 700°C e 850°C, para um maior refino da microestrutura;^(11,12)

b) LR em função da Redução (%): Observa-se o efeito esperado, com um aumento de 10MPa para cada aumento de um ponto percentual na redução total utilizada. Encontram-se resultados similares em Singh.⁽¹³⁾

c) LR em função do teor de carbono (%): O comportamento previsto pelo modelo é o esperado. Observa-se, na faixa de teor de carbono utilizada, entre 0,08% e 0,13%, que o aumento em 0,01% no teor de carbono ocasiona acréscimo de 10MPa no limite de resistência;

d) LR em função do teor de manganês (%): O limite de resistência aumenta com o aumento do percentual de manganês, conforme esperado.⁽¹¹⁾ O aumento de 0,10% no teor de manganês ocasiona aumento aproximado de 10MPa neste limite.

e) LR em função do teor de silício (%): Como esperado, o limite de resistência aumenta com o teor de silício. O efeito não é menos pronunciado do que caso do carbono e manganês (um aumento de aproximadamente 5MPa para cada 0,1% de adição de Si);

f) LR em função do teor de enxofre (%): Não se observa uma relação definida entre o limite de resistência e o teor de S;

g) LR em função do teor de nióbio (%): Observa-se um aumento de LR com aumento do teor de Nióbio em torno de 6MPa para cada adição de 0,01% de Nb;

h) LR em função do teor de nitrogênio (%): O modelo sugere um aumento muito fraco do limite de resistência com o teor de nitrogênio do aço.

Resultados similares, embora com uma maior dispersão, foram obtidos para as outras propriedades mecânicas estudadas.

4.1 Modelagem em Regressão Múltipla Linear

Os resultados para LE, LR e A são mostrados na Tabela 4.

Tabela 4: Análise de Variância – Resultados

	Limite de Escoamento		Limite de Resistência		Alongamento	
	Regressão	RNA - 6 Neurônios	Regressão	RNA - 6 Neurônios	Regressão	RNA - 10 Neurônios
Correlação	0,65	0,67	0,71	0,75	0,33	0,35
Erro mínimo (%)	0,00	0,03	0,00	0,02	0,00	0,08
Erro médio (%)	2,27	2,26	1,73	1,57	4,86	4,76
máximo (%)	7,77	7,26	6,66	5,97	27,00	20,40

Observa-se que a Rede Neural Artificial apresenta desempenho melhor se comparada ao modelo em Regressão Linear Múltipla. Os erros médios e máximos obtidos em RNA são inferiores aos obtidos em Regressão Múltipla Linear. Estes resultados são análogos aos resultados obtidos por Jones.⁽¹⁾

Em relação à qualidade dos dados de propriedades mecânicas, Jones⁽¹⁾ observa que ações devem ser realizadas visando redução na variabilidade existente no processo com o objetivo de melhorar a capacidade de previsão do modelo.

5 CONCLUSÕES

Foram treinados e testados três modelos em Redes Neurais Artificiais, capazes de prever as Propriedades Mecânicas como função da Composição Química e parâmetros de processo de laminação. Os modelos se mostraram consistentes com os efeitos esperados por considerações metalúrgicas para maioria das variáveis

analisadas e refletiram as tendências previamente verificadas nas análises estatísticas realizadas. Os modelos podem ser utilizados para estudar o efeito de cada variável de maneira isolada.

A utilização de técnicas estatísticas como critério de escolha do número de neurônios na camada de entrada da Rede Neural Artificial se mostrou eficiente, pois foi possível visualizar alguma melhoria de desempenho com a variação do número de neurônios e decidir qual a arquitetura ideal.

A comparação dos resultados obtidos através do modelo em Redes Neurais Artificiais e em Regressão Múltipla Linear indica que as Redes podem produzir modelos com maiores correlações, menores erros médios e menores erros máximos. No caso aqui estudado, os resultados obtidos estiveram, em grande parte, em conformidade com a Literatura pesquisada.

Agradecimentos

Os autores agradecem à Gerdau Açominas S/A, por disponibilizar suas instalações e recursos e também à Reginaldo Rodrigues Braga, Analista de Sistemas Industriais da Gerdau Açominas S/A e ao prof. Antônio de Pádua Braga, do DELT-UFMG, pelo auxílio na implementação das redes neurais artificiais no software MatLab.

REFERÊNCIAS

- 1 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 & Steelmaking*, vol.32, n.5, p435-442, Oct. 2005;
- 2 GRAUPE, D. Principles of Artificial Neural Networks; *Advanced Series on Circuits and Systems*. Singapore: World Scientific Publishing Company, Jul. 1997, 252p, vol.3;
- 3 Z. Y. LIU, W. D. WANG, W. GAO. Prediction of the Mechanical Properties of Hot Rolled C-Mn Steels Using Artificial Neural Networks. *Journal of Materials Processing Technology*, New Zealand, vol.57, p332-336, Nov. 2004;
- 4 STERJOVSKI, Z. NOLAN, D., CARPENTER, K. R., DUNNE, D. P., NORRISH, J. Artificial Neural Networks for Modeling Mechanical Properties of Steels in various Applications. *Journal of Materials Processing Technology*, vol.170, p536-544, May 2005;
- 5 DOBRZÁNSKI, L. A., KOWALSKI, M., MADEJSKI, J. Methodology of the Mechanical Properties prediction for the Metallurgical Products from the Engineering Steels using the Artificial Intelligence Methods. *Journal of Materials Processing Technology*, vol.164-165, pp1500-1509, 2005;
- 6 TU, J. V., Advantages and Disadvantages of Using Artificial Neural Networks versus Logistic Regression for Predicting Medical Outcomes. *Journal of Clinical Epidemiology*, (Ontario), vol.49, n.11, p1125-1231, Sep. 1996;
- 7 JAIN, A.K., MAO, J., MOHIUDDIN, K.M., 1996. *Artificial Neural Networks: A Tutorial*. IEEE Computer Society Press, CA, USA, vol.29, n.3, p31-44, Mar. 1996;
- 8 DYJA H., KORCZAK P. Application of the Thermal-Mechanical-Microestrutural Finite Element Model to the Simulation of Hot Plate Rolling. *Journal of Materials Processing Technology*, Czestochowa, Poland, Vol.92, n.93, p463-467, Aug. 1999;

- 9 I.A. Basheer, M. Hajmeer. Artificial Neural Networks: Fundamentals, Computing, Design and Application, Journal of Microbiological Methods, vol.43, p3-31, 2000;
- 10 THE MATHWORKS, INC. Documentation about Neural Network Toolbox. Disponível em: <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/>. Acesso em Janeiro de 2008;
- 11 LYAKISHEV, N. P., TULIN N. A., L. P YU. Niobium in Steels and Alloys; Metallurgical Aspects of Niobium from Mineral Deposits to Alloy Production and Applications. São Paulo, CBMM, p215-216, 1984;
- 12 BAKKALOGLU, A. Effect of Processing Parameters on the Microstructure and Properties of an Nb Microalloyed Steel. Materials Letters, Vol.56, n.3, p200-209, Oct. 2002;
- 13 S. B. SINGH, H. K. D. H. BHADESHIA, D. J. C. MACKAY, H. CAREY, I. MARTIN. Neural Network Analysis of Steel Plate Processing. Ironmaking and Steelmaking, vol.25, n.5, p355-365, 1998.