

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Curso de Pós-Graduação em Engenharia Metalúrgica e de Minas

Defesa de Dissertação de Mestrado

**“Modelo de Previsão de Propriedades Mecânicas de
Perfis Estruturais Laminados a Quente:
Uma Abordagem em Redes Neurais Artificiais”**

Autor: Alisson Paulo de Oliveira
Orientador: Prof. Paulo José Modenesi

Fevereiro/2008

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Curso de Pós-Graduação em Engenharia Metalúrgica e de Minas

**MODELO DE PREVISÃO DE PROPRIEDADES MECÂNICAS DE PERFIS ESTRUTURAIS
LAMINADOS A QUENTE – UMA ABORDAGEM EM REDES NEURAS ARTIFICIAIS**

Alisson Paulo de Oliveira

Defesa de Dissertação de Mestrado apresentada ao Curso de Pós-Graduação em Engenharia
Metalúrgica e de Minas da Universidade Federal de Minas Gerais

Área de concentração: Metalurgia Física
Orientador: Prof. Paulo José Modenesi

Belo Horizonte
Escola de Engenharia da UFMG
Fevereiro/2008

Aos meus pais.

À minha esposa, Michelle.

AGRADECIMENTOS:

Agradeço a todos aqueles que, direta ou indiretamente, colaboraram para a conclusão deste projeto e, em particular:

A Deus, por tudo que consegui nesta vida.

À minha querida mãe, Neusa Diniz Aguiar, pelo eterno incentivo aos meus estudos, desde a mais tenra idade.

À minha amada esposa, Michelle de Oliveira Gonçalves, pela especial compreensão em todos os momentos e etapas deste projeto.

Ao meu orientador, Paulo José Modenesi, pela colaboração e critério ao longo de todo o curso de Mestrado.

À professora Berenice Mendonça Gonzalez, por despertar em mim o gosto pela disciplina Metalurgia Física e pela co-orientação neste trabalho.

Ao colega Reginaldo Rodrigues Braga, Analista de Sistemas Industriais da Gerdau Açominas S/A, e ao professor Antônio de Pádua Braga, do Departamento de Engenharia Eletrônica da Universidade Federal de Minas Gerais, pelo inestimável trabalho realizado na implementação das Redes Neurais Artificiais no Software MatLab.

À Gerdau Açominas S/A, por disponibilizar suas instalações e imprescindíveis recursos.

À Aços Villares S/A e Villares Metals S/A pelo importante aprendizado em técnicas estatísticas e modelagem matemática aplicadas a processos siderúrgicos.

À Universidade Federal de Minas Gerais (Em especial ao Departamento de Engenharia Metalúrgica e de Materiais) e ao Colégio Estadual Central, pela valiosíssima colaboração em minha formação acadêmica.

RESUMO

Este trabalho tem como objetivo a elaboração de um modelo matemático empírico para previsão das propriedades mecânicas de perfis estruturais de aço laminados a quente.

Tal modelo é baseado em diversas variáveis de processo de produção, incluindo o processo de laminação e a composição química do aço, utilizando dados de origem industrial. Adotou-se a metodologia de Redes Neurais Artificiais (RNA's) a qual se mostra a mais apta a produzir resultados mais precisos além de possuir a importante capacidade de aprendizado e atualização de sua estrutura interna. Esta última característica permite que o modelo sempre reflita quaisquer alterações ocorridas no processo em estudo.

Várias técnicas estatísticas foram utilizadas visando auxiliar no desenvolvimento do modelo, entre as quais se destacam: Análise de Variância, Análise de Regressão Linear, Análises de Regressão Múltipla Linear e Análise de Dispersão. As mesmas se mostraram fundamentais para a compreensão e interpretação da variabilidade encontrada no banco de dados, além de servirem como ferramenta de definição da arquitetura das Redes Neurais Artificiais.

Observou-se que o modelo obtido apresentou resultados dentro do esperado e de acordo com as tendências metalúrgicas estabelecidas em teoria. Os resultados obtidos foram superiores aos obtidos via técnicas estatísticas tradicionais. É possível verificar o efeito de cada variável de maneira isolada. Verificou-se que a dispersão dos dados é um fator de grande importância para o sucesso de qualquer modelo de previsão. Quanto menor a variabilidade dos dados melhor o desempenho do modelo.

O modelo permitirá que o projeto de composição química seja realizado com maior precisão, visando menores custos de produção além de melhorar a compreensão do efeito de cada variável de processo nas propriedades mecânicas dos perfis laminados. Com o desenvolvimento do Sistema Simulador será possível visualizar o efeito simultâneo de duas variáveis de processo nas propriedades mecânicas dos perfis laminados.

ABSTRACT

The main objective of this work is to develop an empirical mathematical model used to predict the mechanical properties of hot rolled steel sections.

This model is based in some production variables, including the rolling process and the steel chemical composition, using, as source, the production data bank. The methodology chosen is the Artificial Neural Net (ANN's) which is capable to predict results with good accuracy and has the important characteristic of learning and updating of its internal structure. The last characteristic allows the model to reflect any change occurred in the studied process.

Some statistics tools were used aiming to help the model development: Variance Analyses, Linear Regression Analyses, Multiple Linear Regression Analyses and Scatter Plot. These tools helped to comprehend and interpret the data variability. They were used to define the ANN Architecture.

It was observed that the results from final model were according to the expected and consistent with the metallurgical trends. The results were superior to that obtained from traditional statistical methods. It is possible to verify the effect of each variable in isolation. It was verified that the data dispersion is an important aspect for the success of any prediction model. The lower the data variability, the better the model prediction performance.

The model will allow that the chemical composition design will be performed with high accuracy, aiming reduced production costs and it will improve the comprehension of the effect of each process variable on the steel products mechanical properties. With the development of the Simulator System it will be possible to visualise the simultaneous effect of two variable process on the steel products mechanical properties.

LISTA DE FIGURAS	iv
LISTA DE TABELAS	vii
LISTA DE FÓRMULAS	ix
NOTAÇÕES	x
CAPÍTULO 1 – INTRODUÇÃO	1
CAPITULO 2 – OBJETIVO DA PESQUISA	6
CAPITULO 3 – REVISÃO BIBLIOGRÁFICA	7
3.1 – Modelagem Matemática	7
3.1.1 – Aspectos Gerais	7
3.1.2 – Histórico	7
3.2 – Considerações Gerais sobre as Redes Neurais Artificiais	9
3.3 – A lógica das Redes Neurais Artificiais	14
3.4 – Técnicas de modelamento X Redes Neurais Artificiais	18
3.5 – Aplicações das Redes Neurais Artificiais em Processos Siderúrgicos e Metalúrgicos	20
3.6 – Fundamentos tecnológicos	22
3.6.1 – Perfis I, H: Utilização, Características, etc;	22
3.6.2 – Normas Internacionais utilizadas em Perfis Estruturais	24
a) <i>Normas ASTM (American Society for Testing Materials)</i>	24
b) <i>Euronorma EN 10025-2</i>	25
c) <i>U500-503 (Argentina)</i>	25
3.6.3 – Composições Químicas por norma atendida, aços ao Nióbio	25
3.6.4 – Composições Químicas por norma atendida, aços ao Vanádio	27
3.6.5 – Amostragem	30
3.7 – Fundamentos Metalúrgicos	30
3.7.1 – Composição Química	31
a) <i>Concentração de Carbono</i>	31
b) <i>Concentração de Manganês</i>	31
c) <i>Concentração de Cromo</i>	32
d) <i>Concentração de Nitrogênio</i>	32
e) <i>Concentração de Silício</i>	32
f) <i>Concentração de Enxofre</i>	33
3.7.2 – Parâmetros de Laminação	33
a) <i>Efeito da Temperatura de Laminação</i>	33

b) <i>Efeito da Redução durante a Laminação</i>	35
c) <i>Efeito da Taxa de Resfriamento</i>	36
d) <i>Microestrutura X Parâmetros de Laminação</i>	37
e) <i>Mudanças estruturais do aço durante Laminação Controlada</i>	39
CAPITULO 4 – METODOLOGIA	42
4.1 – Escolha do tipo de Perfil Estrutural para modelamento das propriedades mecânicas	42
4.2 – O Banco de Dados	43
4.2.1 – Dados Gerais	44
4.2.2 – Redução percentual durante o Processo de Laminação	45
4.3 – Análise Estatística das Variáveis do Banco de Dados	46
4.4 – Análise Gráfica dos Dados	47
4.5 – Desenvolvimento do Modelo	48
4.5.1 – Definição do Tipo de Rede Neural Artificial	48
4.5.2 – Partição e Tamanho do Banco de Dados	49
4.5.3 – Normalização dos dados	50
4.5.4 – Inicialização dos Pesos da Rede	51
4.5.5 – Taxa de aprendizado da Rede de Propagação Reversa	52
4.5.6 – Função de Transferência	52
4.5.7 – Critério de Convergência	53
4.5.8 – Número de Ciclos de Treinamento	54
4.5.9 – Modos de Treinamento	55
4.5.10 – Tamanho da Camada Oculta	56
4.5.11 – Processo de Treinamento da Rede Neural Artificial	58
4.6 – Simulação das Propriedades Mecânicas a partir dos dados de entrada	59
4.7 – Modelamento em Regressão Múltipla Linear	61
CAPITULO 5 – RESULTADOS E DISCUSSÕES	62
5.1 – Análise gráfica do Banco de Dados	62
5.1.1 – Análise de Correlação: Limite de Escoamento X Variáveis de Entrada	62
5.1.2 – Análise de Correlação: Limite de Resistência X Variáveis de Entrada	64
5.1.3 – Análise de Correlação: Alongamento X Variáveis de Entrada	66
5.2 – Resumo do Banco de Dados sem Tratamento Estatístico	68
5.3 – Escolha das Variáveis de Entrada	69
5.4 – Avaliação dos Gráficos de Dispersão	71
5.5 – Resumo do Banco de Dados com Tratamento Estatístico	73
5.6 – Ajuste da Rede Neural Artificial	73
5.6.1 – Ajuste da Rede Neural Artificial para o Limite de Escoamento	74
5.6.2 – Ajuste da Rede Neural Artificial para o Limite de Resistência	80
5.6.3 – Ajuste da Rede Neural Artificial para Alongamento	84

5.7 – Treinamento e Validação	90
5.7.1 – Limite de Escoamento	90
5.7.2 – Limite de Resistência	94
5.7.3 – Alongamento	98
5.8 – Simulação das Propriedades Mecânicas nas faixas de validade	101
5.8.1 – Limite de Escoamento	101
5.8.2 – Limite de Resistência	106
5.8.3 – Alongamento	112
5.9 – Discussão dos Resultados Obtidos	117
5.9.1 – Limite de Escoamento	117
5.9.2 – Limite de Resistência	120
5.9.3 – Alongamento	122
5.10 – Modelamento em Regressão Múltipla Linear	125
5.10.1 - Limite de Escoamento	125
5.10.2 - Limite de Resistência	126
5.10.3 - Alongamento	127
5.11 - Comparação entre os resultados obtidos: RNA x Regressão Múltipla Linear	127
CAPITULO 6 – CONCLUSÕES	129
CAPITULO 7 – ETAPAS FUTURAS	131
7.1 – Projeto Green Belt	131
7.2 – Aprimoramento do Modelo a partir da inclusão de novas variáveis	131
7.3 – Implantação da Rede Neural Artificial em Sistema	132
7.3.1 - Implementação do Sistema Simulador	132
REFERÊNCIAS BIBLIOGRÁFICAS	135

LISTA DE FIGURAS

Figura 3.1	(a) Esquema de um neurônio biológico; (b) Mecanismo de transferência de sinais entre dois neurônios biológicos	13
Figura 3.2	Interações de sinais a partir de n neurônios e analogia à soma de sinais em um neurônio artificial de uma única camada	14
Figura 3.3	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)	15
Figura 3.4	Diagrama mostrando uma típica relação entre a quantidade de erro nos conjuntos de dados de treinamento e de teste e a duração total do treinamento da rede neural	18
Figura 3.5	Seção transversal de um perfil I ou H	22
Figura 3.6	Efeito do Carbetto de Nióbio no Limite de Escoamento para vários tamanhos de Carbetos de Nióbio	26
Figura 3.7	Efeito da taxa de resfriamento no aumento do limite de escoamento devido a aumento de resistência por precipitação em um aço com 0,15% de Vanádio	28
Figura 3.8	Corpo de Prova padrão ASTM para ensaio de tração	30
Figura 3.9	Efeito da temperatura final de laminação nas propriedades mecânicas de placas de aço	34
Figura 3.10	Efeito da temperatura final de laminação no tamanho de grão ferrítico	34
Figura 3.11	Efeito da Redução na laminação nas propriedades mecânicas de placas de aço	35
Figura 3.12	Efeito da Redução na laminação no tamanho de grão da placa de aço	35
Figura 3.13	Efeito da taxa de resfriamento nas propriedades mecânicas de placas de aço	37
Figura 3.14	Efeito da taxa de resfriamento no tamanho de grão ferrítico	37
Figura 3.15	Efeito da temperatura final de laminação na microestrutura final da placa de aço laminada, conforme esquema de laminação 2	38
Figura 3.16	Efeito da redução de laminação na microestrutura final da placa de aço laminada, conforme esquema de laminação 2	39
Figura 3.17	Ilustração Esquemática das mudanças na microestrutura com deformação durante a Laminação Controlada	40
Figura 4.1	Beam Blank do Perfil W200X46,1 com espessura da aba	45
Figura 4.2	Dados Agrupados (a) X Dados não Agrupados (b) para o teor de Carbono	48
Figura 4.3	Critério para interrupção do treinamento e seleção da arquitetura ótima da rede	54

Figura 4.4	Efeito do tamanho da camada oculta na generalização da rede	57
Figura 5.1	Curvas de Tendência: Limite de Escoamento em função das diversas variáveis de processo disponíveis	62
Figura 5.2	Curvas de Tendência: Limite de Resistência em função das diversas variáveis de processo disponíveis	64
Figura 5.3	Curvas de Tendência: Alongamento em função das diversas variáveis de processo disponíveis	66
Figura 5.4	Treinamento da RNA, utilizando o MATLAB, para previsão de LE	90
Figura 5.5	Resultado da Validação da RNA, para previsão de LE	91
Figura 5.6	Histograma dos valores reais do Limite de Escoamento	92
Figura 5.7	Correlação entre LE medido e LE estimado	93
Figura 5.8	Erro de estimativa de LE para cada amostra	94
Figura 5.9	Treinamento da RNA, utilizando o MATLAB, para previsão de LR	95
Figura 5.10	Resultado da Validação da RNA, para previsão de LR	95
Figura 5.11	Histograma dos valores reais do Limite de Resistência	96
Figura 5.12	Correlação entre LR medido e LR estimado	97
Figura 5.13	Erro de estimativa de LR para cada amostra	97
Figura 5.14	Treinamento da RNA, utilizando o MATLAB, para previsão de A	98
Figura 5.15	Resultado da Validação da RNA, para previsão de A	99
Figura 5.16	Histograma dos valores reais do Alongamento	100
Figura 5.17	Correlação entre A medido e A estimado	100
Figura 5.18	Erro de estimativa de A para cada amostra	101
Figura 5.19	LE em função da Temperatura Final de Laminação (°C)	102
Figura 5.20	LE em função da Redução (%)	103
Figura 5.21	LE em função do teor de Carbono (%)	103
Figura 5.22	LE em função do teor de Manganês (%)	104
Figura 5.23	LE em função do teor de Silício (%)	104

Figura 5.24	LE em função do teor de Enxofre (%)	105
Figura 5.25	LE em função do teor de Cromo (%)	105
Figura 5.26	LE em função do teor de Nióbio (%)	106
Figura 5.27	LE em função do teor de Nitrogênio (%)	106
Figura 5.28	LR em função da Temperatura Final de Laminação (°C)	107
Figura 5.29	LR em função da Redução (%)	108
Figura 5.30	LR em função do teor de Carbono (%)	108
Figura 5.31	LR em função do teor de Manganês (%)	109
Figura 5.32	LR em função do teor de Silício (%)	109
Figura 5.33	LR em função do teor de Enxofre (%)	110
Figura 5.34	LR em função do teor de Cromo (%)	110
Figura 5.35	LR em função do teor de Nióbio (%)	111
Figura 5.36	LR em função do teor de Nitrogênio (%)	111
Figura 5.37	A em função da Temperatura Final de Laminação (°C)	112
Figura 5.38	A em função da Redução (%)	113
Figura 5.39	A em função do teor de Carbono (%)	113
Figura 5.40	A em função do teor de Manganês (%)	114
Figura 5.41	A em função do teor de Silício (%)	114
Figura 5.42	A em função do teor de Enxofre (%)	115
Figura 5.43	A em função do teor de Cromo (%)	115
Figura 5.44	A em função do teor de Nióbio (%)	116
Figura 5.45	A em função do teor de Nitrogênio (%)	116
Figura 7.1	Telas de exemplo mostrando a resposta do Modelo em gráficos 2D e 3D	133
Figura 7.2	Resultado calculados de LR (UTS) e LE (YP) em função da concentração de Nióbio e Carbono	134

LISTA DE TABELAS

Tabela I.1	Custo de matéria prima de Perfis Laminados. Perfil W250X38,5 em aço ASTM A572-50	5
Tabela II.1	Bitolas e normas para desenvolvimento das Redes Neurais Artificiais para previsão de propriedades mecânicas	6
Tabela III.1	Termos comuns no Campo das Redes Neurais e seus equivalentes em Estatística	16
Tabela III.2	Propriedades Mecânicas dos Perfis Laminados ASTM	25
Tabela III.3	Composições químicas por tipo de perfil laminado, aços ao Nióbio	27
Tabela III.4	Efeito do teor de Manganês no Endurecimento por precipitação de um aço micro ligado ao Vanádio com uma composição base de 0,08% de Carbono e 0,30% de Silício	29
Tabela III.5	Composições químicas por tipo de perfil laminado, aços ao Vanádio	30
Tabela V.1	Resumo Estatístico – Banco de Dados Inicial	69
Tabela V.2	Matriz de Correlação – Banco de Dados Inicial	69
Tabela V.3	Resumo Estatístico – Banco de Dados Final	73
Tabela V.4	Rede Neural Artificial com 4 neurônios na camada de entrada, Limite de Escoamento	75
Tabela V.5	Rede Neural Artificial com 5 neurônios na camada de entrada, Limite de Escoamento	75
Tabela V.6	Rede Neural Artificial com 6 neurônios na camada de entrada, Limite de Escoamento	75
Tabela V.7	Rede Neural Artificial com 7 neurônios na camada de entrada, Limite de Escoamento	76
Tabela V.8	Rede Neural Artificial com 8 neurônios na camada de entrada, Limite de Escoamento	76
Tabela V.9	Erro Mínimo (%) versus Número de Neurônios	77
Tabela V.10	Erro Máximo (%) versus Número de Neurônios	77
Tabela V.11	Erro Médio (%) versus Número de Neurônios	78
Tabela V.12	Correlação entre LE's (%) versus Número de Neurônios	78
Tabela V.13	Rede Neural Artificial com 4 neurônios na camada de entrada, Limite de Resistência	80
Tabela V.14	Rede Neural Artificial com 5 neurônios na camada de entrada, Limite de Resistência	80

Tabela V.15	Rede Neural Artificial com 6 neurônios na camada de entrada, Limite de Resistência	80
Tabela V.16	Rede Neural Artificial com 7 neurônios na camada de entrada, Limite de Resistência	81
Tabela V.17	Rede Neural Artificial com 8 neurônios na camada de entrada, Limite de Resistência	81
Tabela V.18	Erro Mínimo (%) versus Número de Neurônios	81
Tabela V.19	Erro Máximo (%) versus Número de Neurônios	82
Tabela V.20	Erro Médio (%) versus Número de Neurônios	82
Tabela V.21	Correlação entre LR's (%) versus Número de Neurônios	83
Tabela V.22	Rede Neural Artificial com 4 neurônios na camada de entrada, Alongamento	84
Tabela V.23	Rede Neural Artificial com 5 neurônios na camada de entrada, Alongamento	84
Tabela V.24	Rede Neural Artificial com 6 neurônios na camada de entrada, Alongamento	84
Tabela V.25	Rede Neural Artificial com 7 neurônios na camada de entrada, Alongamento	85
Tabela V.26	Rede Neural Artificial com 8 neurônios na camada de entrada, Alongamento	85
Tabela V.27	Rede Neural Artificial com 9 neurônios na camada de entrada, Alongamento	85
Tabela V.28	Rede Neural Artificial com 10 neurônios na camada de entrada, Alongamento	86
Tabela V.29	Erro Mínimo (%) versus Número de Neurônios	86
Tabela V.30	Erro Máximo (%) versus Número de Neurônios	87
Tabela V.31	Erro Médio (%) versus Número de Neurônios	87
Tabela V.32	Correlação entre A's (%) versus Número de Neurônios	88
Tabela V.33	Resumo das Características das Redes Neurais Artificiais	89
Tabela V.34	Coeficientes da Equação Linear, Efeitos sobre LE e Estatística de Regressão	125
Tabela V.35	Coeficientes da Equação Linear, Efeitos sobre LR e Estatística de Regressão	126
Tabela V.36	Coeficientes da Equação Linear, Efeitos sobre A e Estatística de Regressão	127
Tabela V.37	Comparação entre os resultados obtidos: RNA x Regressão Múltipla Linear	127
Tabela VII.1	Novas variáveis a serem utilizadas no futuro Banco de Dados	132

LISTA DE FÓRMULAS

1.1	Fórmula de Carbono Equivalente, aços ao Nióbio	1
1.2	Fórmula de Carbono Equivalente, aços ao Vanádio	1
1.3	Equação padrão para Regressão Múltipla Linear	3
3.1	Função Sigmoidal	16
3.2	Função Linear	16
3.3	Função Tangente Hiperbólica	16
4.1	Fórmula para cálculo da redução de laminação	45
4.2	Normalização de dados, fórmula 1	50
4.3	Normalização de dados, fórmula 2	50
4.4	Fórmula para cálculo do erro SSE	53
4.5	Número de nodos ocultos, fórmula 1	57
4.6	Número de nodos ocultos, fórmula 2	57
4.7	Número de nodos ocultos, fórmula 3	57
4.8	Número de nodos ocultos, fórmula 4	57
4.9	Cálculo do erro percentual	60
4.10	Cálculo do Coeficiente de Correlação Linear	60
4.11	Cálculo do Desvio Padrão	60
4.12	Equação padrão para Regressão Múltipla Linear	61
5.1	Equação para Regressão Múltipla Linear, Limite de escoamento	125
5.2	Equação para Regressão Múltipla Linear, Limite de Resistência	126
5.3	Equação para Regressão Múltipla Linear, Alongamento	127

NOTAÇÕES

C c	Teor de Carbono, em peso (%)
Mn c	Teor de Manganês, em peso (%)
P c	Teor de Fósforo, em peso (%)
Si c	Teor de Silício, em peso (%)
S c	Teor de Enxofre, em peso (%)
Cu c	Teor de Cobre, em peso (%)
Cr c	Teor de Cromo, em peso (%)
Nb c	Teor de Nióbio, em peso (%)
Mo c	Teor de Molibdênio, em peso (%)
V c	Teor de Vanádio, em peso (%)
Al-t c	Teor de Alumínio Total, em peso (%)
Sn c	Teor de Estanho, em peso (%)
N₂ c	Teor de Nitrogênio, em peso (%)
T aba f	Temperatura final de laminação na aba (“Flange”)
MPa	Unidade de pressão, Mega Pascal = 10 ⁶ Pascal

DADOS BIOGRÁFICOS DO AUTOR:

Alisson Paulo de Oliveira é natural de Belo Horizonte, Minas Gerais. Filho de Zequias Paulo de Oliveira e Neusa Diniz Aguiar de Oliveira, é casado com sua querida esposa Michelle de Oliveira Gonçalves desde 2005. Finalizou seus estudos básicos na Escola Estadual Governador Milton Campos (Colégio Estadual Central), em 1992, e graduou-se em Engenharia Metalúrgica pela Universidade Federal de Minas Gerais em Agosto de 1999, tendo iniciado o curso em Agosto de 1994. Iniciou sua carreira profissional como Estagiário de Nível Superior da Belgo Bekaert Arames S/A, em 1997, vindo a ser Engenheiro Trainee da Aços Villares S/A e Engenheiro de Produtos da Villares Metals S/A, entre 1999 e 2002. Desde Dezembro de 2002 é Engenheiro de Desenvolvimento de Produtos e Processos com foco na Laminação de Perfis Estruturais da Gerdau Açominas S/A em Ouro Branco, Minas Gerais.

CAPITULO 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, tais como a American Standard for Testing Materials (ASTM) e Euronormas (EN).

Tal desafio se origina na compreensão do efeito das diversas variáveis envolvidas na evolução das Propriedades Mecânicas ao longo do processo de Laminação. Algumas destas variáveis, listadas abaixo, são de difícil controle e não são consideradas no projeto de composição química dos Perfis Estruturais:

- ✓ Temperatura de reaquecimento dos blocos;
- ✓ Comprimento dos blocos;
- ✓ Área da seção transversal dos blocos;
- ✓ Parâmetros do Laminador, tais como abertura por passes de laminação, tempo de espera entre passes e tempo de processo em cada passe.

Atualmente, a definição e otimização da composição química dos diversos perfis laminados se baseiam na análise dos seguintes dados:

- ✓ Histórico de propriedades mecânicas: Limite de Escoamento (LE), Limite de Resistência (LR) e Alongamento (A);
- ✓ Local e espessura do ponto de amostragem (Aba ou alma do Perfil, em função da norma em produção);
- ✓ Elementos químicos utilizados na fórmula de Carbono Equivalente padrão: Carbono (C), Manganês (Mn), Silício (Si), Nióbio (Nb) e Vanádio (V). As equações usadas são:

$$CEQ1 = \%C + \%Mn/5 + 2 \times \%Nb \text{ (para aços ao Nióbio);} \quad (1.1)$$

$$CEQ2 = \%C + \%Mn/6 + \%Si/24 + \%V/14 \text{ (para aços ao Vanádio).} \quad (1.2)$$

- ✓ Dimensões básicas do produto acabado em caso de novos Perfis a serem produzidos.

Uma possível estratégia, visando tornar o projeto de composição química mais preciso, seria o uso de um modelo matemático implementado em sistema especialmente projetado para permitir a simulação das propriedades mecânicas em função das diversas variáveis envolvidas no processo de laminação. Este modelo necessitaria ser dinâmico e confiável o suficiente para se ajustar às características do processo, uma vez que os parâmetros de laminação nunca são exatamente constantes.

O estudo de trabalhos de modelagem de processos de Laminação encontrados na literatura ^(1, 2) e a análise das variáveis disponíveis dentro do processo de laminação de perfis estruturais sugerem que tal modelo de previsão de propriedades mecânicas deve ser baseado nas seguintes variáveis:

- ✓ Composição Química;
- ✓ Temperaturas de Laminação no último passe;
- ✓ Redução Percentual.

Existem algumas técnicas que podem ser utilizadas no desenvolvimento de modelos para a previsão de propriedades mecânicas de produtos de aço laminados a quente ⁽¹⁾:

- ✓ Análise de Regressão Múltipla Linear;
- ✓ 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. Na regressão linear, os coeficientes desta equação são determinados por métodos de álgebra linear.

Na modelagem das propriedades mecânicas de produtos de aço laminados a quente ou a frio existe mais de uma variável independente e, portanto, uma metodologia de regressão múltipla deve ser empregada ⁽¹⁾. A análise de regressão múltipla linear toma a forma de uma equação do tipo:

$$y = b_1 * x_1 + b_2 * x_2 + \dots + b_n * x_n + c \quad (1.3)$$

Onde y é a variável dependente (no presente trabalho, os limites de escoamento, LE, e de resistência, LR, ou o alongamento, A), x_i é a variável independente (temperatura de acabamento, teor de carbono, etc.), b_i é o coeficiente de regressão da variável independente x_i e c é o intercepto ou constante.

Uma outra abordagem possível diz respeito às Redes Neurais Artificiais as quais foram concebidas na década de 40 e tiveram um avanço teórico considerável nos anos 80 em função da maior disponibilidade de recursos computacionais ⁽¹⁾. Tais redes 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 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⁾.

No mesmo estudo comparativo citou-se um problema em relação às técnicas caixa preta, as quais pressupõem nenhum conhecimento prévio do sistema, relativo ao fato de não permitir a compreensão do que acontece com o modelo quando da geração das soluções. Desta maneira exige-se evolução para um modelo caixa cinza, o qual pressupõe algum conhecimento do processo em estudo. De fato, no trabalho realizado por Singh ⁽²⁾ foi possível conhecer a influência das diversas variáveis de entrada no comportamento das variáveis de saída, além de propor abordagens de processo visando modificações nas propriedades mecânicas de produtos de aço ⁽²⁾.

Conforme apresentado no trabalho de Jones ⁽¹⁾, as RNA's apresentam melhores resultados se comparados a outras técnicas. Desta forma o presente trabalho adotará este método.

O uso de uma ferramenta de simulação com um modelo residente baseado em Redes Neurais Artificiais ou qualquer outro método, permitirá que o projeto de composição química seja realizado com o conhecimento das diversas variáveis

operacionais envolvidas. Assim espera-se que seja possível torná-la mais precisa e, com isso, reduzir o custo devido à adição de elementos químicos em teores além dos necessários. Desta forma, quanto mais preciso o modelo adotado mais eficiente e poderosa se tornará tal ferramenta.

Uma outra aplicação deste Sistema seria permitir um melhor controle do processo de laminação, com o conhecimento maior da influência de cada uma das variáveis operacionais envolvidas na obtenção das propriedades mecânicas finais ao longo do processo de laminação. Tal conhecimento poderia ser utilizado visando ações durante a laminação para a obtenção de propriedades mecânicas conforme ocorre nos processos de Laminação Controlada e Laminação Termo Mecânico, além de implicar em redução considerável de custos.

A abordagem citada acima, com uso de ações típicas de Laminação Controlada ou Termo-Mecânica, permitiria a laminação de perfis estruturais em aços de resistência mecânica mais elevada e requisitos de impacto.

Entre estes aços citam-se os utilizados no mercado naval (DNV AH36, AH40, etc). Os benefícios seriam relativos a menor adição de elementos de liga, o que minimizaria o custo final do produto laminado, além de melhorar sua característica de soldabilidade.

A tabela I.1 ilustra os custos percentuais das matérias primas utilizadas no processo de fusão das corridas utilizadas na laminação dos perfis laminados. Verifica-se que os maiores custos são das matérias primas adicionadas com o objetivo de se obter as propriedades mecânicas desejadas, ou seja, Manganês e Nióbio.

Tabela I.1: Custo percentual de matéria prima de Perfis Laminados. Perfil W250X38,5 em aço ASTM A572-50.

Matéria Prima/Etapas	%
Ferro Silício Manganês	9,92
Ferro Silício 75	0,13
Ferro Nióbio	2,50
Alumínio Gotão	1,22
Dolomítica Crua	0,02
Carbonato de Sódio	0,03
Cal Dolomítica	1,41
Coque Beneficiado	0,07
Fluorita Bitolada	0,14
Custo de Transformação	4,97
Gusa	79,59
Total	100,00

CAPITULO 2 – OBJETIVO DA PESQUISA

O presente trabalho tem como objetivo desenvolver um modelo para a previsão das seguintes propriedades mecânicas de Perfis Estruturais Laminados a Quente:

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

O modelo será baseado em diversas variáveis de processo utilizadas na laminação dos perfis estruturais e será futuramente aplicado para produtos que atendem às normas ASTM A572 grau 50, ASTM A992 e EN 10025-2, que apresentam certas similaridades de especificações. Este modelo foi baseado em uma Rede Neural Artificial, desenvolvida a partir dos dados reais de produção para uma bitola (Tabela II.1).

Tabela II.1: Bitolas e normas para desenvolvimento das Redes Neurais Artificiais para previsão de propriedades mecânicas.

Bitola (Norma ASTM A6) Largura de Aba X Peso Linear	Norma de aço
W200X46,1	ASTM A572-50,
	ASTM A992
	EN10025-2

Cita-se também como trabalho seguinte à obtenção do modelo em Redes Neurais Artificiais a implementação em Sistema visando a simulação e modificação das propriedades mecânicas em função das variáveis de entrada. Este trabalho será estendido a outras bitolas e especificações, em função da similaridade de desenvolvimento da Rede Neural Artificial.

CAPITULO 3 – REVISÃO BIBLIOGRÁFICA

3.1 – Modelagem matemática

3.1.1 – Aspectos gerais

Atualmente as ferramentas de modelagem matemática estão sendo cada vez mais usadas no meio industrial. O objetivo é a redução de custos e aumento da produtividade dos processos de produção. O modelo matemático pode permitir a compreensão da estrutura de um sistema, a previsão do seu comportamento em função da alteração de suas variáveis ^(3, 4) e, também, a otimização dos parâmetros de processo de modo a assegurar máximo rendimento e menores custos ⁽¹⁾.

Inúmeras variáveis podem estar envolvidas em processos industriais, freqüentemente apresentando uma elevada correlação entre si, o que pode levar a uma grande dificuldade para se conceber um modelo matemático ⁽⁴⁾. Têm-se várias técnicas de inteligência computacional em uso para realizar o trabalho de modelagem, tais como Redes Neurais Artificiais e Redes Neuro-Fuzzy. Estas abordagens são frequentemente adotadas em processos onde tem se uma base de dados com valores históricos das variáveis de entrada e saída do sistema, como é o caso das propriedades mecânicas de produtos de aço, em função de variáveis de seu processo de produção (Temperatura, Composição Química, Abertura do Laminador, etc.) ^(1, 5).

3.1.2 – Histórico

Huamaní ⁽⁶⁾ apresenta uma revisão histórica do desenvolvimento das Redes Neurais Artificiais. Os principais pontos deste desenvolvimento são resumidos abaixo.

O interesse nos estudos de mecanismos e estruturas que simulam o funcionamento do cérebro humano tem provocado um grande desenvolvimento de modelos computacionais baseados no plano biológico ^(6, 8).

A evolução das Redes Neurais Artificiais passou por um processo iniciado por um período de grande atividade, seguido por anos de estagnação nas pesquisas para,

logo a seguir, permitir um processo de ressurgimento do interesse científico como consequência do desenvolvimento de novas tecnologias e fundamentos teóricos ^(6, 7).

A primeira tentativa de construir um modelo conexionista foi na década de 40 por McCulloch e Pitts ^(6, 9), cujo trabalho fazia uma analogia entre células vivas e o processamento eletrônico, simulando o comportamento do neurônio natural, considerado como uma entidade que possui apenas uma saída dada por uma função da soma ponderada das suas diversas entradas.

Poucos avanços foram feitos até 1949, quando Hebb ^(6, 10) publicou o livro intitulado “The Organization of Behavior”, o qual propõe, pela primeira vez, uma lei de aprendizagem específica para as sinapses dos neurônios: “Se um neurônio A é repetidamente estimulado por outro, B, então enquanto A estiver ativo por qualquer razão, tornar-se-á mais sensível ao estímulo de B. Assim, B estimulará A mais facilmente no futuro, pois a sinapse entre eles será mais eficiente.” ⁽¹⁰⁾.

Anos depois, Rosenblatt ^(6, 11), tendo como base os estudos de McCulloch e Pitts ^(6, 9), mostrou em seu livro “Principles of Neurodynamics” o modelo dos perceptrons. Neste modelo, os neurônios eram organizados em camadas de entrada e saída, onde os pesos das suas conexões eram adaptados a fim de se atingir a maior eficiência nas ligações entre entradas e saídas e os neurônios (Eficiência sináptica).

Em 1960, Widrow e Hoff ^(6, 12) propuseram o modelo Adaline (ADAPTative LINear combiner Element), baseando-se também na proposta de McCulloch.

Em 1969, Minsky e Papert ^(6, 13) realizaram um estudo mais rigoroso do modelo do perceptron (Ou neurônio) proposto por Rosenblatt, enfatizando as suas limitações e provocando uma paralisação de atividades na área.

Na década 1970 e início dos anos 80, surgiram estudos voltados para modelos com memória associativa ^(6, 14, 15). Von der Malsburg e Grossberg desenvolveram idéias de aprendizado competitivo, enquanto Kohonen ^(6, 16) propunha os mapas auto-organizáveis.

O interesse em redes neurais foi renovado quando Hopfield ^(6, 17) publica um importante estudo baseado no princípio físico sobre o armazenamento de informação em configurações dinamicamente estáveis.

Em 1986, Rumelhart e McClelland ^(6, 18) publicam o livro “Parallel Distributed Processing”, divulgando o método para ajuste de parâmetros para redes estáticas multicamadas denominado algoritmo de retro propagação (“*Feed Forward Back Propagation*”), sendo este inicialmente proposto por Werbos ^(6, 19). Este fato originou uma grande “explosão” na área, fazendo com que pesquisadores de diversos campos passassem a visualizar interessantes aplicações para as redes neurais artificiais.

Em 1987, ocorreu em San Francisco a primeira conferência de redes neurais em tempos modernos, “IEEE International Conference on Neural Networks” ⁽⁶⁾, sendo formada a “International Neural Networks Society” (INNS). A partir destes acontecimentos decorreu a publicação do periódico “Neural Networks” da INNS em 1989, seguido do “Neural Computation” e do “IEEE Transactions on Neural Networks”, isto em 1990.

3.2 – Considerações Gerais sobre 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 ^(20, 21, 22). 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 ^(21, 22, 23).

Tais Redes foram primeiramente desenvolvidas várias décadas atrás por pesquisadores que tentavam modelar o processo de aprendizado do cérebro humano. No entanto, foi somente no final dos anos 1980 com a redescoberta do algoritmo de treinamento “*Back Propagation*” que houve maior interesse no desenvolvimento desta técnica dentro da comunidade científica ^(5, 24).

As Redes Neurais Artificiais podem ser definidas como estruturas compreendidas de elementos simples de processamento adaptativos densamente

interconectados (Chamados de Neurônios Artificiais), os quais são capazes de executar cálculos paralelos em massa para processamento de dados e representação de conhecimento ^(5, 23, 24, 25).

Embora as Redes Neurais Artificiais sejam abstrações drásticas de seus similares biológicos, sua idéia básica não é replicar a operação dos sistemas biológicos, mas fazer uso do que é conhecido a respeito da funcionalidade das redes biológicas na resolução de problemas complexos ^(5, 25).

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 ^(24, 26). Sua habilidade em aprender e processar informação a classifica como uma forma de inteligência artificial ⁽⁵⁾. A característica mais notável desta tecnologia é que ela pode ser aplicada a uma vasta variedade de problemas muito dos quais eram considerados como extremamente complexos ou carentes de modelos teóricos mais sofisticados ⁽²⁷⁾.

Modelos possuindo tais características são desejáveis por que ⁽²⁵⁾:

- (i) Não linearidade permite melhor ajuste aos dados;
- (ii) Insensibilidade aos ruídos possibilita predição acurada na presença de dados com incerteza e erros de medida;
- (iii) Alto paralelismo implica em rápido processamento e tolerância a falha de recursos;
- (iv) Aprendizado e capacidade de adaptação permitem ao sistema a atualização (modificação) de sua estrutura interna em resposta às mudanças no ambiente,
- (v) Generalização permite aplicação do modelo a dados ainda não interpretados.

As Redes Neurais Artificiais possuem certas desvantagens as quais são citadas a seguir ⁽²⁴⁾:

- (i) As Redes Neurais Artificiais possuem natureza caixa preta (“*Black Box*”) e possuem habilidade limitada para explicitamente identificar possíveis relações de causa: Pode não ser fácil a determinação de quais variáveis de entrada são as mais importantes para a saída final. Os investigadores têm desenvolvido técnicas para aumentar o entendimento a respeito da lógica interna das RNA’s;
- (ii) O modelamento em RNA’s exige grandes recursos computacionais: Como o desenvolvimento destes modelos é um procedimento computacional intensivo, exige-se grande tempo computacional, além de recursos. Atualmente, com a rápida evolução dos sistemas computacionais esta desvantagem tende a ser minimizada;
- (iii) As RNA’s tendem a superajuste: A habilidade dos modelos em RNA’s para modelar interações e não linearidades implicitamente pode ser uma desvantagem por que pode levar a superajuste nos dados de treinamento com baixo desempenho em dados externos, tais como os dados de validação. No entanto, existem abordagens para se evitar este problema, como, por exemplo, a limitação do número de neurônios ocultos, uso de um termo de penalidade, ou limitando o número de treinamentos (Épocas);
- (iv) O desenvolvimento de modelos em RNA’s é empírico e muitas questões metodológicas permanecem sem solução: O modelamento em RNA’s é uma técnica relativamente nova que tem sua origem em uma variedade de disciplinas, e um número de importantes questões metodológicas ainda devem ser resolvidas. Atualmente o desenvolvimento dos modelos envolve processos empíricos de realizar análise de sensibilidade nos parâmetros de treinamento, tal como o número de nodos (neurônios) ocultos. Com pesquisa adicional, muitas destas questões metodológicas provavelmente serão resolvidas.

O principal objetivo da computação baseada em Redes Neurais Artificiais (Neuro-computação) é desenvolver algoritmos matemáticos que permitirão às Redes Neurais Artificiais aprender por imitar o processamento de informações e aquisição de conhecimento do cérebro humano ⁽²⁵⁾.

O sistema nervoso humano consiste de bilhões de neurônios de vários tipos e tamanhos ⁽²⁵⁾. A figura 3.1 ilustra um esquema de um neurônio biológico simplificado com suas três maiores unidades funcionais: Dendritas, Corpo Celular e Axônio. O corpo celular possui um núcleo que contém informações a respeito das características hereditárias e um plasma no qual reside o equipamento molecular utilizado pelo neurônio no processo de comunicação com outros neurônios. As dendritas recebem sinais de outros neurônios e as transmitem através do corpo celular.

Os axônios, os quais se ramificam em colaterais, recebem sinais a partir do corpo celular e os conduz através da sinapse às dendritas dos neurônios vizinhos ⁽²⁵⁾. Uma ilustração esquemática da transferência de sinal entre dois neurônios através da sinapse é mostrada na figura 3.1 b. Um impulso, na forma de um sinal elétrico, viaja dentro da dendrita e através do corpo celular em direção à membrana pré-sináptica da sinapse.

Uma vez alcançada a membrana, um neuro-transmissor químico é liberado, a partir das vesículas, em quantidades proporcionais à força do sinal recém chegado ⁽²⁵⁾. O neuro-transmissor se difunde dentro da brecha sináptica em direção à membrana pós-sináptica, e eventualmente nas dendritas dos neurônios vizinhos, desta maneira forçando os (Dependendo do mínimo valor requerido para estímulo do neurônio receptor) a gerar um novo sinal elétrico.

O sinal gerado passa através do segundo neurônio de maneira idêntica ao descrito anteriormente ⁽²⁵⁾. A quantidade de sinal que passa através de um neurônio receptor depende da intensidade do sinal que emana de cada um dos neurônios alimentadores (Os que geram os sinais), sua força sináptica e o mínimo valor requerido para estímulo do neurônio receptor. Devido ao fato de um neurônio possuir um grande número de dendritas e sinapses, ele pode receber e transferir muitos sinais simultaneamente. Estes sinais podem excitar ou inibir a atividade do neurônio. Este mecanismo simplificado de transferência de sinais constitui o estágio fundamental do início de desenvolvimento da neuro-computação e da operação das Redes Neurais Artificiais.

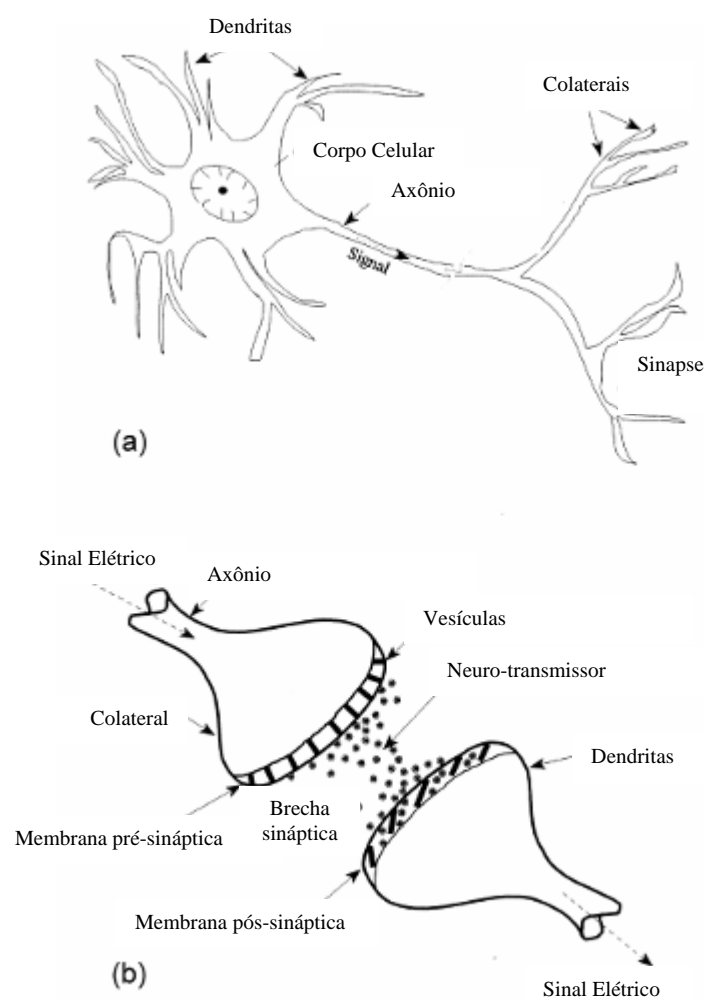


Figura 3.1: (a) Esquema de um neurônio biológico; (b) Mecanismo de transferência de sinais entre dois neurônios biológicos

Uma analogia bastante simplificada entre um neurônio artificial e um biológico se baseia no fato de as conexões entre os neurônios representarem os axônios e dendritas, os pesos das conexões representarem as sinapses (Força sináptica) e o mínimo valor requerido para estímulo representar a atividade no corpo celular ⁽²⁵⁾.

O sistema compreendido por um neurônio artificial e as entradas como mostrado na figura 3.2 é chamado de Perceptron, o qual estabelece um mapeamento entre as atividades de entrada (Estímulo) e o sinal de saída.

A figura 3.2 ilustra n neurônios biológicos com vários sinais de intensidade x e força sináptica w alimentando um neurônio com um mínimo valor requerido para estímulo igual a b , e o sistema de neurônio artificial equivalente ⁽²⁵⁾.




Figura 3.2: Interações de sinais a partir de n neurônios e analogia à soma de sinais em um neurônio artificial de uma única camada

A Rede Neural Artificial e a Rede Biológica aprendem pelo ajuste da magnitude dos pesos ou forças das sinapses ⁽²⁵⁾.

3.3 – A lógica das Redes Neurais Artificiais

O exemplo a seguir ⁽²⁴⁾ ilustra o princípio de funcionamento das Redes Neurais. Embora foque um tema comum na área de saúde os princípios são idênticos aos utilizados em Engenharia.

A figura 3.3 é um diagrama ilustrando uma Rede Neural Artificial que foi treinada para prever a probabilidade de uma pessoa morrer de uma doença hipotética, baseada em apenas duas variáveis: a idade do paciente (x_1 ; faixa, 0 a 100) e o sexo do paciente (x_2 ; macho = 0, fêmea = 1). Os círculos nestes diagramas são conhecidos como “Nodos” (ou Unidades) enquanto as linhas conectando os diferentes “Nodos” são conhecidas como “Pesos de Conexão”. Uma Rede Neural Artificial típica consiste de uma série de Nodos que são arranjadas, em geral, em três camadas (Entrada, Oculta, Saída). Os Nodos de entrada são os valores das variáveis de entrada (Exemplo: x_1 , x_2) enquanto os Nodos de saída representam a resposta (Variável de saída) da rede.

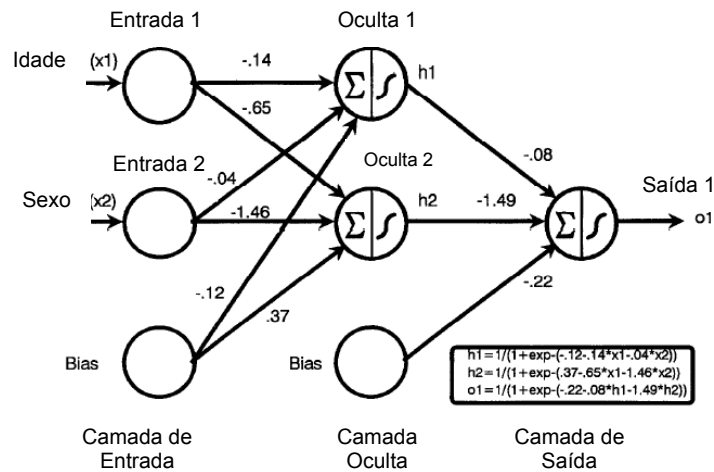


Figura 3.3: Diagrama de uma rede neural artificial treinada para prever a probabilidade de um paciente morrer de uma doença hipotética com base na sua idade (x_1) e sexo (x_2). Cada círculo representa um nodo, enquanto cada linha representa um peso de conexão (Valores reais dos pesos são mostrados). Os nodos da rede estão arranjados em três camadas (Entrada, Oculta e Saída). Uma função de ativação logística é utilizada nas camadas oculta (h_1 e h_2) e de saída (o_1). (h_1 e h_2 representam a ativação dos nodos ocultos 1 e 2; o_1 é a saída prevista da rede). Em cada nodo oculto e de saída uma combinação linear ajustada das entradas é somada e então uma transformação logística é aplicada.

As Redes Neurais podem ter múltiplas saídas ⁽²⁴⁾. Os Nodos na camada oculta (Ou Neurônios) contêm valores intermediários os quais são calculados pela Rede. Cada um dos nodos ocultos e de saída contêm 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. As Redes podem ser construídas com múltiplas camadas ocultas embora não haja vantagens nisso.

Cada Nodo na camada de entrada é usualmente conectado a cada nodo na camada oculta e cada nodo na camada oculta é usualmente conectado a cada nodo na camada de saída ⁽²⁴⁾. Neste exemplo, 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.

Cada nodo de Entrada é conectado a cada Nodo oculto na camada oculta por um Peso de Conexão (Exemplo: -0,14, -0,65, -0,04, -1,46) como mostrado na figura 3.3 ⁽²⁴⁾. Os Pesos de Conexão podem ser pensados como os correspondentes, em uma Rede Neural, aos coeficientes β em um modelo de regressão e contêm o conhecimento adquirido por uma Rede Neural após o treinamento. 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. Esta pode tomar diversas formas como, por exemplo, a função sigmoideal, linear e a função tangente hiperbólica:

$$F(x) = \frac{1}{1 + \exp(-x)} \text{ (Função Sigmoideal)} \quad (3.1)$$

$$F(x) = a * x \text{ (Função Linear)} \quad (3.2)$$

$$F(x) = \tanh\left(\frac{x}{2}\right) = \frac{1 - \exp(-x)}{1 + \exp(x)} \text{ (Função Tangente Hiperbólica)} \quad (3.3)$$

A ativação de cada nodo oculto, $h1$ e $h2$, 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 logística das entradas balanceadas aos Nodos de saída é aplicada de modo a se determinar a saída total da Rede.

A saída da Rede corresponde à predição dos resultados pela Rede e estarão entre 0 e 1 quando a função de ativação é a função logística ⁽²⁴⁾. Existem muitas variações desta arquitetura básica de Rede Neural.

A tabela III.1 mostra os termos comumente usados no campo das Redes Neurais e seus equivalentes em Estatística ⁽²⁴⁾:

Tabela III.1: Termos comuns no Campo das Redes Neurais e seus equivalentes em Estatística.

Redes Neurais Artificiais	Estatística
Entrada	Variável independente (De entrada)
Saída	Variável dependente (Resultado), valor predito
Pesos de Conexão	Coefficientes de Regressão
Peso de Ajuste	Parâmetro Intercepto
Erro	Resíduos
Aprendizado, Treinamento	Parâmetro de Estimacão
Caso de Treinamento, Padrão	Observacão

As Redes de Propagacão Reversa são os tipos mais utilizados ⁽²⁵⁾. O termo “Propagacão Reversa” se refere à maneira como o erro computado na saída é propagado da camada de saída à camada oculta e, finalmente, à camada de entrada.

O algoritmo de aprendizado Propagacão Reversa ⁽²⁵⁾ é o mais conhecido procedimento para se treinar as Redes Neurais Artificiais. Baseia-se na procura, na

função que define o erro em termo dos pesos da rede, de pontos com erro mínimo usando gradientes descendentes desta função estimados numericamente. Cada iteração na Propagação Reversa é constituída de dois passos: Ativação à Frente para produzir uma solução, e uma retro-propagação do erro computado para modificar os pesos. Em uma Rede Neural Artificial (com pesos iniciais assumidos), a varredura à frente envolve a apresentação à Rede de um exemplo de treino. Isto começa na camada de entrada onde cada nodo de entrada transmite o valor recebido à frente para cada nodo oculto na camada oculta.

O mesmo procedimento ⁽²⁵⁾ de calcular o efeito líquido é repetido para cada nodo oculto e para todas as camadas ocultas. A ativação calculada nos nodos de saída representa a solução da Rede Neural Artificial a qual pode desviar consideravelmente da solução alvo devido aos pesos de conexão arbitrariamente selecionados. Na retro-propagação, a diferença (o erro) entre a resposta obtida e a esperada é utilizada para ajustar os pesos de interconexão, começando a partir da camada de saída, através de todas as camadas ocultas, até a camada de entrada. As propagações à frente e as retro-propagações são executadas repetidamente até que a solução da Rede Neural Artificial esteja de acordo com o valor alvo dentro de uma tolerância pré-especificada. O algoritmo de Propagação Reversa fornece o necessário ajuste dos pesos na varredura reversa.

Uma descrição mais detalhada do algoritmo de propagação reversa, incluindo sua fundamentação matemática pode ser encontrada no trabalho de Basheer ⁽²⁵⁾.

A figura 3.4 mostra uma típica relação entre o erro em uma Rede Neural e a duração do treinamento ⁽²⁴⁾. Com o andamento do treinamento, o erro decresce gradualmente até que um mínimo seja alcançado nos Dados de Treinamento (Ponto B). Entretanto, o erro nos Dados de Teste pode decrescer inicialmente até um ponto mínimo (Ponto A) e então começar a crescer no momento em que a Rede Neural começa um processo de super aprendizado nos Dado de Treinamento.

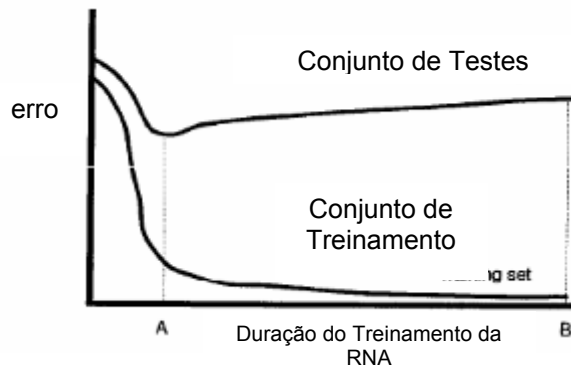


Figura 3.4: Diagrama mostrando uma típica relação entre a quantidade de erro nos conjuntos de dados de treinamento e de teste e a duração total do treinamento da rede neural. (Ponto A representa o ponto no qual o erro é mínimo no conjunto de dados de teste, enquanto o ponto B representa o ponto no qual o erro é mínimo no conjunto de dados de treinamento).

É uma prática comum no desenvolvimento de modelos de Rede Neural ⁽²⁴⁾ fazer uma validação cruzada da Rede nos Dados de Teste periodicamente durante o treinamento e salvar a configuração de pesos da Rede com base em um dos critérios:

- (1) A Rede com o menor erro nos Dados de Treinamento (Ponto B), figura 3.4; ou
- (2) A Rede com o menor erro nos Dados de Teste (Ponto A), figura 3.4.

A última técnica ⁽²⁴⁾ é freqüentemente utilizada para evitar que a Rede Neural entre em super aprendizado (ou treinamento excessivo, que ocorre quando a rede perde capacidade de generalização nos dados de teste) ⁽²⁵⁾ por que as Redes são propensas a superajuste (ou ajuste excessivo aos dados de treinamento, levando a um desempenho ruim em dados externos) ⁽²⁴⁾. A interrupção do treinamento e salvamento da Rede após um número pré-especificado de ciclos de treinamento também é uma opção. Uma Rede treinada usando a abordagem da validação cruzada e salva no ponto A irá provavelmente generalizar melhor a dados externos do que uma rede salva no ponto B.

3.4 – Técnicas de modelamento X Redes Neurais Artificiais

No modelamento caixa preta nenhuma informação sobre o sistema está disponível além dos dados ou, se disponível, não é usada no procedimento de obtenção do modelo. Neste caso, apenas dados de entrada e saída do sistema são

usados durante a identificação. A escolha da representação e da sua estrutura é feita de forma empírica nos casos mais simples ⁽²⁸⁾.

Na identificação caixa-branca ou simplesmente modelagem física, o processo de obtenção do modelo se baseia em leis e princípios físicos. Todos os parâmetros são conhecidos, ou previamente determinados. Dados de entrada e saída do sistema, quando disponíveis são usados apenas para validar o modelo. Na identificação caixa branca, todos os termos da estrutura, e seus parâmetros, possuem significado físico ⁽²⁸⁾.

Como desvantagens da identificação caixa-preta podem-se citar, em geral, o fato de a estrutura do modelo não possuir significado físico, a dificuldade para sua seleção e, em muitos casos, o número excessivo de parâmetros. Como vantagens, em geral, são enumeradas a relativa facilidade de obtenção e a possibilidade de se escolher estruturas mais adequadas para o projeto ⁽²⁸⁾.

Como desvantagem da modelagem caixa-branca, destaca-se a dificuldade de obtenção do modelo. Em geral, as equações físicas envolvidas em um processo, assim como seus parâmetros, não são totalmente conhecidas. Muitas vezes, as relações são por demais complexas e não podem ser determinadas. Como principal vantagem, destaca-se o significado físico do modelo obtido ⁽²⁸⁾.

Essas duas formas de modelagem podem ser interpretadas como os dois extremos de técnicas de modelagem. A rigor, qualquer procedimento que não esteja em nenhum desses extremos pode ser denominada de identificação caixa-cinza. Esta área de conhecimento busca combinar as vantagens dos procedimentos de identificação caixa-preta e caixa-branca. Nesse caso, tanto dados de entrada e saída obtidos no sistema, quanto informação auxiliar são usados na identificação. A identificação caixa-cinza é uma área bastante ampla e por se tratar de um assunto relativamente novo, muitos problemas estão praticamente em aberto. O tipo de conhecimento auxiliar utilizado, assim como o nível de conhecimento, varia de caso para caso ⁽²⁸⁾.

As Redes Neurais Artificiais são técnicas de modelagem tipicamente caixa preta, no entanto podem incorporar informações auxiliares tanto na fase de seleção de

estruturas quanto na estimação de parâmetros o que possibilita desenvolvê-la como um método de modelamento do tipo caixa cinza. Desta forma incorporando maior conhecimento prévio e tornando-a fisicamente mais coerente do que técnicas de modelamento puramente caixa preta.

3.5 – Aplicações das Redes Neurais Artificiais em Processos Siderúrgicos e Metalúrgicos

Encontram-se na literatura inúmeras aplicações para as chamadas Redes Neurais Artificiais. Um campo onde as mesmas encontram grande aplicação são os processos metalúrgicos e siderúrgicos. Nestes processos procura-se relacionar as variáveis de interesse às variáveis de entrada, ou seja, busca-se prever os resultados a partir da análise das variáveis de processo com influência nos resultados finais. Como exemplos destas aplicações têm-se:

- ✓ Determinação das Propriedades Mecânicas de materiais laminados a partir de variáveis de processo;
- ✓ Modelagem do crescimento de grão em processo de reaquecimento contínuo;
- ✓ Modelagem da Microestrutura;
- ✓ Previsão dos Diagramas Tempo Temperatura (CCT) de aços;
- ✓ Modelagem da Temperabilidade dos aços.

Dentre as inúmeras possibilidades das Redes Neurais Artificiais uma das mais interessantes se baseia na determinação das propriedades mecânicas de produtos siderúrgicos por meio da modelagem das variáveis de processo de laminação e características químicas do aço. Singh et al ⁽²⁾ implementaram uma rede neural em um laminador instrumentado visando a determinação dos limites de escoamento e de resistência de placas de aço. Neste trabalho utilizaram-se 108 variáveis de processo entre as quais a composição química, ajustes do laminador, tempo de atraso e tempo de laminação entre os passes e temperaturas de processo. O modelo implementado se mostrou consistente com os conceitos metalúrgicos, permitindo a previsão das propriedades mecânicas além de permitir o estudo de cada variável de processo isoladamente. Outra possibilidade de uso percebida foi no projeto de composição química das placas de aço.

Na modelagem da temperabilidade, visando a determinação da influência da composição química nas propriedades de endurecibilidade dos aços, Dobrzanski et al. ^(29, 30) implementaram três modelos baseados em Redes Neurais Artificiais em determinados grupos de aço de modo a se obter resultados calculados próximos aos obtidos de maneira experimental. Verificou-se a utilidade prática do modelo desenvolvido e que houve significativa conformidade entre os resultados do efeito da composição química obtidos via modelo matemático e os obtidos experimentalmente. Os resultados obtidos confirmaram a viabilidade desta abordagem para o problema e as curvas de temperabilidade obtidas utilizando-se o novo método indicaram que o modelo em Redes Neurais era o método mais satisfatório existente até então.

A determinação de curvas de transformação em resfriamento contínuo, TRC, é uma atividade com alto custo e alto tempo de execução. As mesmas representam um importante papel na descrição da evolução microestrutural dos aços em situações de resfriamento, sendo bastante utilizados no projeto de tratamentos térmicos de produtos siderúrgicos. O tratamento térmico dos aços representa um importante papel na indústria metalúrgica em geral. O sucesso nos tratamentos térmicos requer que as variáveis de operação, em particular aquelas relacionadas com o processo de encharque e temperabilidade do aço sejam cuidadosamente controladas. Desta forma, o conhecimento da temperabilidade e transformações de fase dos aços são essenciais para produzir um aço com as propriedades desejadas. Vermeulen et al ⁽³¹⁾ utilizaram a metodologia das Redes Neurais Artificiais visando prever as linhas de começo e fim de transformação nos diagramas CCT em aços ao Vanádio. Foi observado que o poder de previsão das Redes Neurais Artificiais é mais do que satisfatório e que todas as tendências gerais são bem previstas. Com as Redes Neurais Artificiais treinadas, é possível investigar as relações puras entre os parâmetros de entrada e os diagramas CCT facilmente, algo geralmente impossível de ser realizado na prática.

Em relação à modelagem da microestrutura dos aços, Kuziak et al ⁽³²⁾ desenvolveram uma nova abordagem baseada na previsão da fração volumétrica e tamanho médio das fases constituintes que ocorrem em um aço após processamento termomecânico e resfriamento. Os parâmetros dependentes utilizados foram as frações de ferrita pró-eutetóide, ferrita de Widmanstätten e perlita bem como o tamanho de grão ferrítico. Foi verificado que a abordagem das Redes Neurais Artificiais parece ser uma ferramenta muito poderosa em Engenharia de Materiais.

Seus resultados mostraram que a previsão das propriedades mecânicas e microestrutura está em concordância com os dados experimentalmente obtidos. Características tais como Tamanho de Grão ferrítico e Fração de Perlita foram previstos com boa precisão. As Redes Neurais Artificiais também foram aptas a prever os limites de escoamento e resistência. A precisão dos valores avaliados via Redes Neurais Artificiais foi muito superior àqueles obtidos utilizando-se modelos experimentais clássicos, o que significa que uma rede bem treinada em condições de Laboratório é apta a prever os valores dos parâmetros de saída em um processo industrial ⁽³²⁾ com bom nível de acerto.

A previsão do crescimento de grão também pode ser modelada através do uso das Redes Neurais. Yang ⁽³³⁾ desenvolveu um modelo de Rede Neural capaz de calcular, de maneira acurada, o tamanho de grão ao final de um processo de reaquecimento contínuo. Foi utilizado um conjunto de dados contendo informações críticas a respeito do crescimento de grão. O modelo de rede neural apresentou resultados satisfatórios na previsão dos dados.

3.6 – Fundamentos tecnológicos

3.6.1 – Perfis I, H: Utilização, Características, etc;

Os Perfis I e H são perfis laminados a partir de um bloco de seção quadrada ou retangular. Dependendo de sua altura possuem a forma de uma letra I (Na posição vertical) ou de uma letra H (Na posição horizontal). Têm uso no setor de construção civil, plataformas marítimas, transportes, etc. A figura 3.5 ilustra sua seção transversal, com suas dimensões principais.




Figura 3.5: Seção transversal de um perfil I ou H.

A construção metálica vem sendo utilizada no mundo desde o início do século 19, como um processo construtivo rápido, preciso e de excelente retorno. O emprego de estruturas metálicas, a princípio, estava restrito a pontes. Mais tarde com a revolução industrial iniciou-se o uso generalizado do aço, principalmente para projetos estruturais de grande porte.

O uso do aço estrutural na construção civil no Brasil, embora mais recente e em pequeno volume quando comparado ao que ocorre nos Estados Unidos, Japão e países da Europa, vem crescendo de forma consistente.

O consumo brasileiro anual de aço estrutural per capita está em torno de 3 quilos, considerando o Brasil com 169 milhões de habitantes, segundo dados mais recentes do IBGE, Instituto Brasileiro de Geografia e Estatística, enquanto nas nações mais desenvolvidas consomem-se cerca de 90 quilos por habitante. Isso ocorre por uma série de razões, sendo uma delas a desinformação de construtores e técnicos sobre o uso do aço. Outro aspecto relevante é o fato de até a década de 80 a produção siderúrgica brasileira ser insuficiente para atender o mercado. Porém, esse panorama está mudando. Há uma abundante oferta de aço e as grandes empresas do setor estão investindo na divulgação das diferentes aplicações e formas de utilização do aço estrutural, além de desenvolverem tecnologias e serviços que facilitam as atividades dos usuários. Projetos de grande porte têm ajudado a difundir a qualidade, a rapidez de construção, a funcionalidade e a beleza das estruturas metálicas.

Embora não existam ainda estatísticas consistentes e sistemáticas sobre o uso no Brasil do aço estrutural na construção civil, os estudos já efetuados, principalmente no exterior, são bastante positivos, demonstrando um acentuado crescimento da utilização de estruturas metálicas.

O conceito de construção racionalizada resume-se em obter a melhor solução construtiva para o empreendedor. E é exatamente isso o que a estrutura metálica se propõe a fazer. Combinando-se o uso da estrutura metálica com modernos componentes e materiais de fechamento e cobertura, o prazo de construção torna-se extremamente reduzido.

3.6.2 – Normas Internacionais utilizadas em Perfis Estruturais

Os perfis produzidos a partir das normas citadas abaixo apresentam possibilidades de redução de custos e otimização de processos, conforme citado em 1.

a) ASTM (American Society for Testing Materials) ⁽³⁴⁾

Dentre as inúmeras normas utilizadas mundialmente no processo de laminação de perfis estruturais, citam-se as normas ASTM, de origem americana. Os principais tipos são:

- ✓ Aço ASTM A572 grau 50: Esta especificação é referente a um aço de Alta Resistência e de Baixa Liga (ARBL), tendo como elementos de micro liga, dentre outros, nióbio ou vanádio. É utilizado na construção de pontes e estruturas. Pode ser soldado, parafusado ou rebitado. O grau 50 possui limite de escoamento mínimo igual a 50ksi (345MPa);
- ✓ Aço A992: Aço estrutural para uso na construção de edifícios ou pontes, além de aplicações estruturais diversas. Este aço possui a característica de ser utilizado em regiões propensas a terremotos uma vez que o valor de sua razão elástica (Limite de Escoamento / Limite de Resistência $\leq 0,85$) o torna apto a absorver choques e com isso resistir ao colapso em situações extremas. É um aço ARBL ligado ao nióbio ou vanádio;
- ✓ Aço A36: Aço carbono estrutural para uso em construções. Sua composição química prevê o uso de Carbono e Manganês. Possui baixo limite de escoamento, no mínimo igual a 36ksi (250MPa);
- ✓ Aço AH36 (ASTM A131): Aço estrutural de alta Resistência e Baixa Liga para uso em construções navais. Este aço apresenta requisito de impacto a baixas temperaturas (0°C);

- ✓ Aço AH40 (ASTM A131): Aço estrutural de alta Resistência e Baixa Liga para uso em construções navais. Este aço apresenta requisito de impacto a baixas temperaturas (0°C);

A tabela III.2 ilustra as propriedades mecânicas requeridas para cada um destes aços.

Tabela III.2: Propriedades Mecânicas dos Perfis Laminados ASTM.

Característica	A572-50	A992	A36	AH36	AH40
Limite de Escoamento (MPa)	≥345	345≤LE≤450	≥250	355	390
Limite de Resistência (MPa)	≥450	≥450	400≤LR≤550	490<LR<620	510≤LR≤650
Alongamento (%)	≥18	≥18	≥20	≥18	≥16
Razão Elástica	-	≤0,85	-	-	-
Impacto (S/N)	Não	Não	Não	Sim	Sim

b) Euronorma EN 10025-2 ⁽³⁵⁾

Tal norma possui aços similares aos aços ASTM. A diferença básica se baseia na diferença de nomenclatura e o mercado consumidor, basicamente países da Comunidade Econômica Européia (CEE).

c) U500-503 (Argentina) ⁽³⁶⁾

Tal norma também apresenta aços similares aos aços ASTM, sendo os aços F36 e F26, similares aos ASTM A572-50 e A36 respectivamente. Seu único diferencial é um requisito de ensaio de dobramento a 180° com uso de cutelo com espessuras variáveis as quais dependem da espessura da amostra em teste. É uma norma adotada pela Argentina.

3.6.3 – Composições Químicas por norma atendida, aços ao Nióbio ⁽³⁷⁾

Como o Vanádio, o Nióbio aumenta o Limite de Escoamento através do endurecimento por precipitação. A magnitude deste aumento depende do tamanho e quantidade dos carbeto de nióbio precipitados (Figura 3.6). Entretanto, o Nióbio é refinador de grãos mais efetivo que o Vanádio. Desta maneira, o efeito combinando do

aumento de resistência por precipitação e refinamento do grão ferrítico faz do nióbio um agente mais efetivo para aumento de resistência do que o Vanádio.




Figura 3.6: Efeito do Carbeto de Nióbio no Limite de Escoamento para vários tamanhos de Carbeto de Nióbio (37).

O aumento da resistência devido ao Nióbio é de 35 a 40MPa para cada 0,01% de adição. Este aumento de resistência foi acompanhado por considerável piora na resistência ao impacto até que procedimentos especiais de laminação fossem desenvolvidos e os níveis de carbono reduzidos para evitar a formação de bainita superior. De maneira geral, altas temperaturas de acabamento e passes leves de deformação devem ser evitadas com Aços ao Nióbio já que pode resultar em grãos de vários tamanhos misturados e ferrita do tipo Widmanstätten os quais pioram a resistência ao impacto.

Estes aços são produzidos por laminação controlada, Laminação de Recristalização e Resfriamento Acelerado. A Laminação Controlada de Recristalização de aços ao Nióbio pode ser efetiva sem a adição de Titânio enquanto a Laminação de Recristalização de aços ao Vanádio requer Titânio para refino de grão. Também, muito menos Nióbio é necessário e aços ao Nióbio-Titânio podem ser submetidos a Laminação Controlada de Recristalização a altas temperaturas.

A tabela III.3 ilustra composições químicas de aços de alta resistência e baixa liga utilizadas em perfis estruturais.

Tabela III.3: Composições químicas por tipo de perfil laminado, aços ao Nióbio.

Aço	Faixas	C	Mn	Si	P	S	Al	Nb	Ni	Cr	Ti	Cu	N (ppm)
ASTM A572-50	Mínimo	0,08	0,70	0,10				0,005	-	-	-	-	-
	Máximo	0,20	1,30	0,30	0,045	0,035	0,025	0,050	-	-	-	-	90
ASTM A36	Mínimo	0,10	0,80	0,10			0,010	-	-	-	-	-	-
	Máximo	0,20	1,30	0,30	0,045	0,035	0,050	-	-	-	-	-	90
ASTM A992	Mínimo	0,08	1,20	0,17			0,010	0,005	-	-	-	-	-
	Máximo	0,20	1,50	0,25	0,030	0,035	0,050	0,050	-	-	-	-	90
ASTM A131	Mínimo	0,08	0,88	0,15			0,010	0,015	-	-	-	-	-
	Máximo	0,17	1,49	0,25	0,025	0,020	0,050	0,050	-	-	-	-	90

3.6.4 – Composições Químicas por norma atendida, aços ao Vanádio ⁽³⁷⁾

O Vanádio contribui com o aumento de resistência através da formação de pequenas partículas de precipitado (5 a 100nm de diâmetro) de V(CN) na ferrita, durante o resfriamento após a laminação a quente. Estes precipitados de Vanádio, não tão estáveis como os precipitados de Nióbio, permanecem em solução em toda a faixa de temperaturas normalmente utilizadas em laminação e, desta maneira, são muito dependentes da taxa de resfriamento para sua formação. Por outro lado, os precipitados de Nióbio são estáveis em altas temperaturas o que favorece a obtenção de grãos mais finos de ferrita ⁽³⁷⁾.

O aumento de resistência devido ao Vanádio está entre 5 e 15MPa para cada adição de 0,01% em peso, dependendo do teor de carbono e da taxa de resfriamento a partir da laminação a quente (e desta maneira da espessura da seção). A taxa de resfriamento, a qual é determinada pela temperatura final de laminação e pela espessura da seção afeta o nível de aumento de resistência de um aço com 0,15% de Vanádio como mostrado na figura 3.7 ⁽³⁷⁾.




Figura 3.7: Efeito da taxa de resfriamento no aumento do limite de escoamento devido a aumento de resistência por precipitação em um aço com 0,15% de Vanádio (37).

Um ótimo nível de aumento de resistência ocorre a uma taxa de resfriamento de aproximadamente 170°C/min. Em taxas inferiores a esta, o V(CN) precipitado é grosso e é menos efetivo no aumento de resistência. À taxas superiores mais V(CN) permanece em solução e, desta maneira, uma pequena fração de partículas de V(CN) precipita e o aumento de resistência é reduzido. Para uma dada espessura de seção e meio de resfriamento as taxas de resfriamento podem ser aumentadas ou diminuídas por aumento, respectivamente, da temperatura de início do resfriamento. O aumento desta temperatura resulta em grãos de austenita maiores, enquanto a diminuição da temperatura torna a laminação mais difícil, devido ao aumento da carga de laminação (37).

O teor de Manganês também afeta o aumento de resistência dos aços micro-ligados ao Vanádio (37). O efeito do Manganês em um aço ao Vanádio laminado a quente é mostrado na tabela III.4.

Tabela III.4: Efeito do teor de Manganês no Endurecimento por precipitação de um aço micro ligado ao Vanádio com uma composição base de 0,08% de Carbono e 0,30% de Silício.

% Vanádio	Limite de Escoamento	
	MPa	Mudança no Limite de Escoamento MPa
0,3% Mn		
0	297	0
0,08	352	55
0,14	380	83
1,2% Mn		
0	331	0
0,08	462	131
0,14	552	221

O aumento de 0,90% no teor de Manganês elevou a resistência em 34MPa devido ao efeito de endurecimento por solução sólida ⁽³⁷⁾. O endurecimento por precipitação devido ao Vanádio também foi aumentado devido ao fato de o Manganês ter reduzido a temperatura de transformação da austenita para ferrita, o que resultou em dispersão de precipitados mais finos. Este efeito do Manganês no endurecimento por precipitação é maior do que seu efeito em aços ao Nióbio. Entretanto, a resistência absoluta em um aço ao Nióbio com 1,20% de Manganês é de apenas aproximadamente 50MPa menor que de um aço ao Vanádio, mas com uma menor adição de Nb (0,06% de Nióbio contra 0,14% de Vanádio) ⁽³⁷⁾.

O terceiro fator que afeta a resistência dos aços ao Vanádio é o tamanho de grão ferrítico produzido após o resfriamento a partir da temperatura final de laminação. Grãos ferríticos mais finos (os quais não somente aumentam o limite de escoamento, mas também melhoram a tenacidade e a ductilidade) podem ser produzidos por temperaturas mais baixas de transformação da austenita para ferrita ou pela formação de finos tamanhos de grão austeníticos antes da transformação ⁽³⁷⁾.

O tamanho de grão austenítico de aços laminados a quente é determinado pela recristalização e crescimento de grão da austenita durante a laminação. Os aços ao Vanádio laminados a quente normalmente são submetidos à laminação convencional, mas também são produzidos por laminação de recristalização. Com laminação convencional os aços ao Vanádio apresentam moderado aumento de resistência ⁽³⁷⁾.

A tabela III.5 ilustra composições químicas de aços de alta resistência e baixa liga utilizadas em perfis estruturais

Tabela III.5: Composições químicas por tipo de perfil laminado, aços ao Vanádio.

Aço	Faixas	C	Mn	Si	P	S	Al	V	Ni	Cr	Cu	N (ppm)
ASTM A572-50	Mínimo	0,08	0,55	0,10	-	-	0,010	0,010	-	-	-	-
	Máximo	0,15	1,50	0,30	0,025	0,012	0,050	0,040	-	-	-	90
ASTM A992	Mínimo	0,08	0,60	0,10	-	-	0,010	0,010	-	-	-	-
	Máximo	0,15	1,50	0,30	0,025	0,012	0,050	0,040	-	-	-	90

3.6.5 – Amostragem ⁽³⁴⁾

A norma ASTM A6 define o ponto de retirada das amostras que serão submetidas a ensaio de tração (figura 3.8). Em função da largura da aba do perfil (bf, figura 3.5) retira-se a amostra em dois pontos diferentes do perfil laminado. O critério é o seguinte:

- ✓ Largura de aba < 150mm: Retirada de amostra na alma;
- ✓ Largura de aba \geq 150mm: Retirada de amostra na aba.




Figura 3.8: Corpo de Prova padrão ASTM para ensaio de tração.

3.7 – Fundamentos Metalúrgicos

Os principais fatores que influenciam os resultados de propriedades mecânicas dos perfis estruturais são:

- ✓ Composição Química (Teores de Carbono, Manganês, Nióbio e Vanádio) e no caso dos aços patináveis os citados anteriormente além de Cromo, Níquel e Cobre;
- ✓ Temperaturas finais de deformação;
- ✓ Reduções realizadas no laminador;

- ✓ Temperatura de saída do forno.

3.7.1 – Composição Química

a) Concentração de Carbono

O Carbono forma uma solução sólida intersticial no Ferro, levando a um intenso endurecimento por solução sólida. O efeito é mais pronunciado no caso da Ferrita devido ao fato de os átomos de Carbono, diferentemente do que ocorre na Austenita, causarem uma distorção tetragonal do reticulado resultando em fortes interações com todos os tipos de deslocações ⁽²⁾. No entanto, a solubilidade do carbono na ferrita é extremamente pequena, de maneira que o principal efeito, em aços perlítico-ferríticos, é aumentar a fração do constituinte perlita (Mistura lamelar de ferrita e cementita). Há também um refino da microestrutura desde que a temperatura na qual a ferrita se forma é reduzida. O limite de escoamento e o limite de resistência devem, portanto, aumentar com a concentração de carbono.

O efeito do Carbono ⁽³⁸⁾ é praticamente nulo para altas temperaturas e baixas velocidades de deformação. A situação se inverte para teores de carbono iguais ou menores que 0,40%, temperaturas abaixo de 900°C e velocidades de deformação acima de 20s⁻¹, quando seu aumento concorre para elevar a resistência à deformação a quente durante processos de laminação.

b) Concentração de Manganês

O Manganês é um dos principais elementos de liga adicionados em aços de baixa liga ⁽³⁹⁾. Este elemento entra em solução sólida (substitucional) no Ferro o que aumenta a resistência do aço, em torno de 33MPa por ponto percentual de adição ⁽³⁹⁾. Elevados ganhos de resistência podem ser obtidos a custas de adições excessivas (mais de 2%), entretanto isto pode ocasionar uma piora em outras propriedades importantes do aço, tais como tenacidade ao impacto (Tenacidade) e soldabilidade.

O Manganês não somente oferece endurecimento por solução sólida, mas também tem um forte efeito na estabilidade da austenita. Este elemento diminui a

temperatura de transformação da ferrita e leva a um refino da microestrutura ⁽²⁾. O Manganês também muda o ponto eutetóide para menores concentrações de carbono e dessa maneira leva a um aumento na fração volumétrica da perlita.

c) Concentração de Cromo

Os principais elementos de liga utilizados em aços baixa-liga são o Manganês e o Silício e, menos frequentemente, o Cromo e o Níquel ⁽³⁹⁾.

O Cromo interage com o Ferro para formar uma solução sólida substitucional que resulta em relativamente baixo aumento de resistência do aço em torno de 33MPa por ponto percentual de adição ⁽³⁹⁾. Elevado ganho de resistência pode ser obtido a custa de maior adição (mais de 2%), entretanto isto pode ocasionar uma piora em outras propriedades importantes do aço, tais como resistência ao impacto (tenacidade) e soldabilidade. Sua adição também melhora as propriedades de resistência à corrosão dos aços.

d) Concentração de Nitrogênio

Trata-se de um elemento intersticial no aço. Devido ao seu pequeno teor nos aços comerciais não provoca grandes alterações na deformação a quente ⁽³⁸⁾. Por outro lado, ele poderia exercer um efeito indireto através da precipitação de carbonitreto de nióbio ⁽³⁹⁾ os quais provocam o endurecimento do aço. Tais carbonitreto atuam como obstáculos ao movimento das discordâncias provocando, assim, o aumento do limite de escoamento e de resistência.

e) Concentração de Silício

O Silício é um dos principais elementos de liga que são adicionados em aços de baixa liga ⁽³⁹⁾. Este elemento forma no Ferro soluções sólidas substitucionais que resultam em aumento de resistência do aço, em torno de 90MPa por ponto percentual de adição ⁽³⁹⁾.

f) Concentração do Enxofre

As principais inclusões não-metálicas no aço são, fora os óxidos, relacionadas com o enxofre ⁽³⁹⁾. Este se combina comumente com o Manganês formando o Sulfeto de Manganês em uma forma laminar, o que o torna facilmente deformável durante laminação controlada a baixas temperaturas. As finas camadas de sulfeto se tornam alongadas o que causa uma sensível piora na resistência ao impacto e, em alguma extensão, na resistência a baixas temperaturas ⁽³⁹⁾.

Em relação aos Limites de Escoamento e de Resistência observa-se, na prática, para os perfis com amostragem de corpo de prova na região da alma, queda pouco acentuada com o aumento do teor do Enxofre. Tal fato pode ser explicado pela provável segregação do Enxofre na região central do lingote que, após intensa conformação mecânica, se torna a região da alma do perfil. Quanto maior o teor de Enxofre, maior a quantidade de Sulfeto de Manganês o que ocasiona decréscimo no Limite de Escoamento e de Resistência ⁽³⁹⁾. Para perfis com amostragem na aba, praticamente não se observa nenhum efeito nas propriedades mecânicas, uma vez que a presença do Enxofre nesta região acaba sendo bastante inferior se comparada à alma.

3.7.2 – Parâmetros de Laminação

a) Efeito da Temperatura de Laminação

A figura 3.9 ⁽⁴⁰⁾ mostra o efeito da temperatura de laminação nas propriedades mecânica de um aço de baixo carbono e baixa liga e alta resistência em dois esquemas diferentes de laminação:

- ✓ Esquema 1: Re-aquecimento à temperatura final de laminação, laminação na região de recristalização, laminação na região bifásica (Austenita + Ferrita), resfriamento final;
- ✓ Esquema 2: Re-aquecimento à temperatura de laminação, laminação na região de não recristalização da austenita, laminação na região bifásica (Austenita + Ferrita), resfriamento final.

A diferença entre estes dois esquemas de laminação é o primeiro estágio de laminação: a faixa de temperatura de recristalização da austenita é utilizada no primeiro esquema e região de não recristalização da austenita é utilizada no segundo esquema.

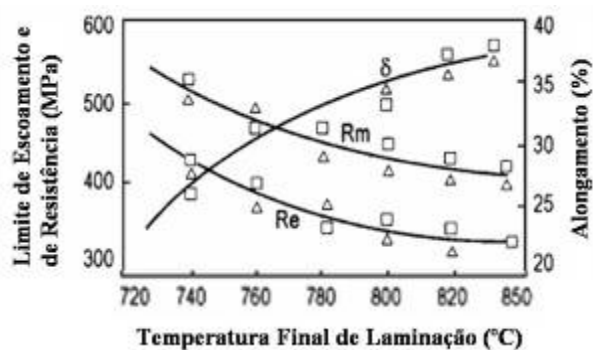


Figura 3.9: Efeito da temperatura final de laminação nas propriedades mecânicas de placas de aço. A redução final é igual a 30% (□, esquema 2; Δ, esquema 1) (40).

O limite de escoamento e o limite de resistência do aço após a laminação aumentam significativamente com o decréscimo da temperatura final de laminação. O alongamento decresce apreciavelmente com o decréscimo da temperatura final de laminação.

Observa-se pela figura 3.10 que o tamanho de grão ferrítico aumenta com o aumento da temperatura final de laminação.

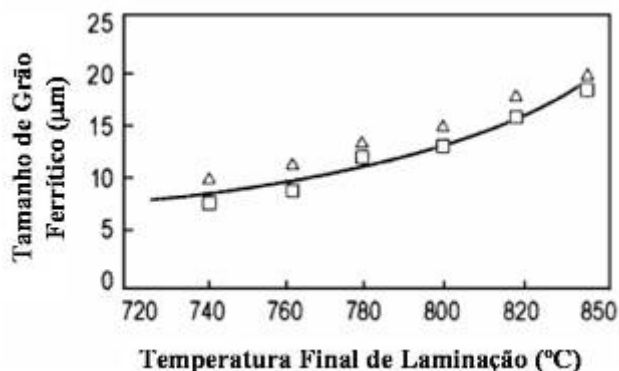


Figura 3.10: Efeito da temperatura final de laminação no tamanho de grão ferrítico. A redução final é igual a 30% (40).

b) Efeito da Redução durante a Laminação

O efeito da redução na laminação nas propriedades mecânicas ⁽⁴⁰⁾ é mostrado na figura 3.11.

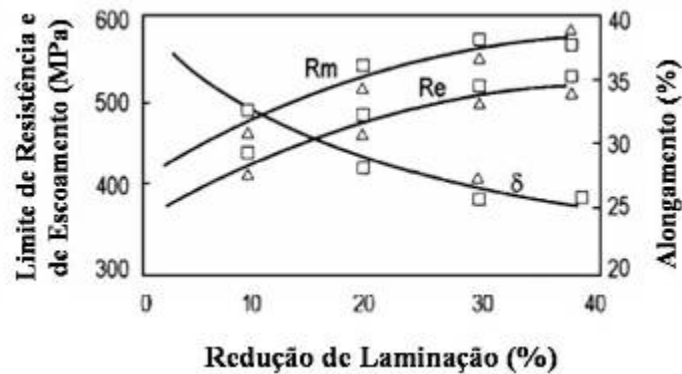


Figura 3.11: Efeito da Redução na laminação nas propriedades mecânicas de placas de aço. Temperatura final de laminação é igual a 740°C (□, esquema 2; Δ, esquema 1) (40).

Pode ser visto que os limites de escoamento e resistência aumentam apreciavelmente e a ductilidade decresce ligeiramente com o aumento na redução durante a laminação.

Observa-se, também, que o tamanho de grão ferrítico segue o comportamento inverso das propriedades mecânicas, isto é, o aumento da redução durante a laminação implica em queda no tamanho de grão, conforme pode ser visto na figura 3.12.




Figura 3.12 Efeito da Redução na laminação no tamanho de grão da placa de aço. A temperatura final de laminação é igual a 740°C (□, esquema 2; Δ, esquema 1) (40).

Em temperaturas constantes ⁽⁴¹⁾, quando as condições de deformação não são fortes o suficiente para produzir a recristalização da austenita ocorre a orientação da austenita (Pancaking) com a direção de laminação e, como a ferrita nucleia a partir dos contornos de grão da austenita, o número de sítios de nucleação potenciais para os grãos de ferrita aumenta substancialmente levando à formação de finos grãos de ferrita. Com o aumento no percentual de deformação, o número de bandas que sofreram torção (Twist Bands) e bandas deformadas, e a densidade de deslocamentos aumentam. Como resultado, a nucleação de ferrita, a qual estava limitada aos contornos de grão da austenita, também é observada dentro dos grãos de austenita. Este acréscimo nos sítios de nucleação de ferrita leva a um aumento na taxa de nucleação da ferrita e finalmente a menores tamanhos de grão ferrítico.

c) Efeito da Taxa de Resfriamento

As propriedades mecânicas de aços laminados a 780°C e subsequentemente resfriados a diferentes taxas são mostradas na figura 3.13 ⁽⁴⁰⁾. O processo de laminação controlada aliado a resfriamento acelerado permite aumentar ainda mais os limites de resistência e de escoamento. Os limites de escoamento e de resistência aumentam com o aumento na taxa de resfriamento embora a variação na resistência com taxas de resfriamento seja menor a altas taxas do que em baixas taxas (< °C/s, isto é, resfriado ao ar ou em ar forçado). Com taxas muito altas de resfriamento (20°C/s, isto é, resfriado em água), a austenita se transforma em ferrita e martensita. Os Limites de Resistência e de Escoamento aumentam significativamente, enquanto o alongamento decresce levemente com o aumento da taxa de resfriamento de 5 a 20°C. O efeito da taxa de resfriamento no tamanho de grão ferrítico é mostrado na figura 3.14. É claro que o tamanho de grão ferrítico diminui com o aumento da taxa de resfriamento.

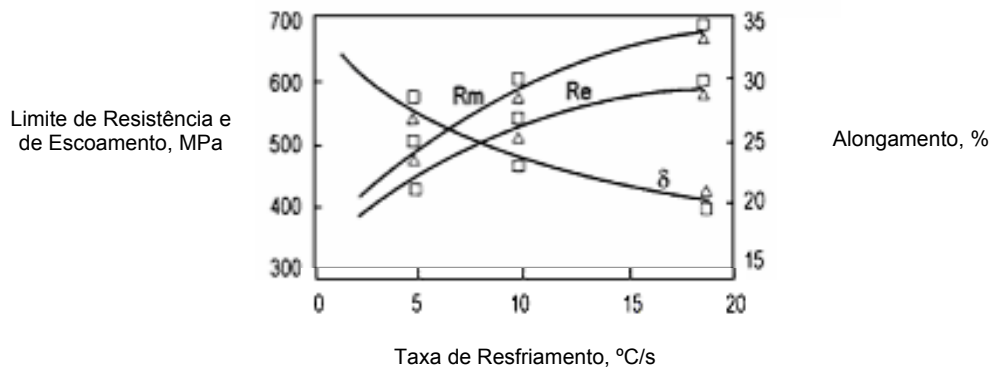


Figura 3.13: Efeito da taxa de resfriamento nas propriedades mecânicas de placas de aço. Temperatura final de laminação é igual a 780°C e redução final igual a 25% (□, esquema 2; Δ, esquema 1) (40).

O efeito da taxa de resfriamento no tamanho de grão ferrítico⁽⁴⁰⁾ é mostrado na figura 3.14.




Figura 3.14: Efeito da taxa de resfriamento no tamanho de grão ferrítico. Temperatura final de laminação é igual a 780°C e redução final igual a 25% (40).

d) Microestrutura X Parâmetros de Laminação

As propriedades mecânicas do aço laminado estão relacionadas à sua microestrutura. O tamanho de grão ferrítico é influenciado pelos parâmetros de laminação na região bifásica (Austenita + Ferrita). As figuras 3.10 e 3.15 mostram o efeito da temperatura de laminação no tamanho de grão ferrítico e microestrutura do aço⁽⁴⁰⁾.




Figura 3.15: Efeito da temperatura final de laminação na microestrutura final da placa de aço laminada, conforme esquema de laminação 2. A redução final foi de 30%: (a) 740°C, (b) 780°C, (c) 820°C (40).

O tamanho de grão médio final decresce parabolicamente com o decréscimo da temperatura final de laminação ⁽⁴⁰⁾. Como mostrado na figura 3.10, a redução na temperatura de laminação de 850 para 740°C resultou em um decréscimo do tamanho de grão ferrítico médio de 20 para 8µm. A razão para tal variação do tamanho de grão ferrítico com a temperatura de laminação é devido ao fenômeno de recristalização.

É observado que o refino do tamanho de grão ferrítico é, principalmente, o resultado da deformação da austenita abaixo da temperatura de recristalização e resfriamento acelerado após a deformação; ambos os processos aumentam a nucleação da fase ferrítica ⁽⁴⁰⁾. Vários mecanismos aceleradores da taxa de nucleação pela deformação foram propostos. Estes incluem uma inter-relação entre a taxa de nucleação aumentada da ferrita com:

- (a) Protuberâncias formadas pela migração local do contorno de grão austenítico;
- (b) Formação de sub-grãos perto dos contornos de grão austeníticos;
- (c) Energia de deformação das discordâncias armazenadas na austenita deformada.

O mecanismo primário de refino de grão é a recristalização da austenita durante a deformação a quente ⁽⁴⁰⁾. Pequenas adições de elementos de liga tais como Nb, V e Ti resultam na formação de carbonitretos na microestrutura. Estes precipitados, por serem muito finos, são efetivos em evitar o crescimento de grão.

A quantidade de redução também tem influência no tamanho de grão ferrítico. A figura 3.16 mostra micrografias óticas de aço laminado a 740°C em função da quantidade de redução.




Figura 3.16: Efeito da redução de laminação na microestrutura final da placa de aço laminada, conforme esquema de laminação 2. A temperatura final de laminação foi igual a 740°C: (a) 15%, (b) 25%, (c) 35% (40).

Pode ser observado que o tamanho de grão ferrítico decresce com o aumento das reduções de laminação ⁽⁴⁰⁾, conforme mostrado na figura 3.12. Durante a laminação na região bifásica (Austenita + Ferrita) os grãos de ferrita e austenita são comprimidos. Os grãos de austenita são alongados e os grãos de ferrita transformados a partir da austenita se tornam muito finos. Conseqüentemente, estes grãos de ferrita na região bifásica (Austenita + Ferrita) também são alongados durante a laminação e também se tornam mais finos após a recristalização.

e) Mudanças estruturais do aço durante Laminação Controlada

O controle de processo Termo Mecânico tem sido usado intensivamente na produção de aço ⁽⁴⁰⁾. Neste processo o produto é laminado a uma quantidade necessária de redução em uma temperatura apropriada. O objetivo primário da Laminação Controlada em um aço do tipo ARBL (Alta-Liga, Baixa Resistência) é a obtenção de um tamanho de grão ferrítico muito fino e uniforme resultando em aumento no Limite de Escoamento, Limite de Resistência e na Tenacidade. As mudanças estruturais no aço durante a Laminação Controlada estão esquematicamente ilustradas na figura 3.17.

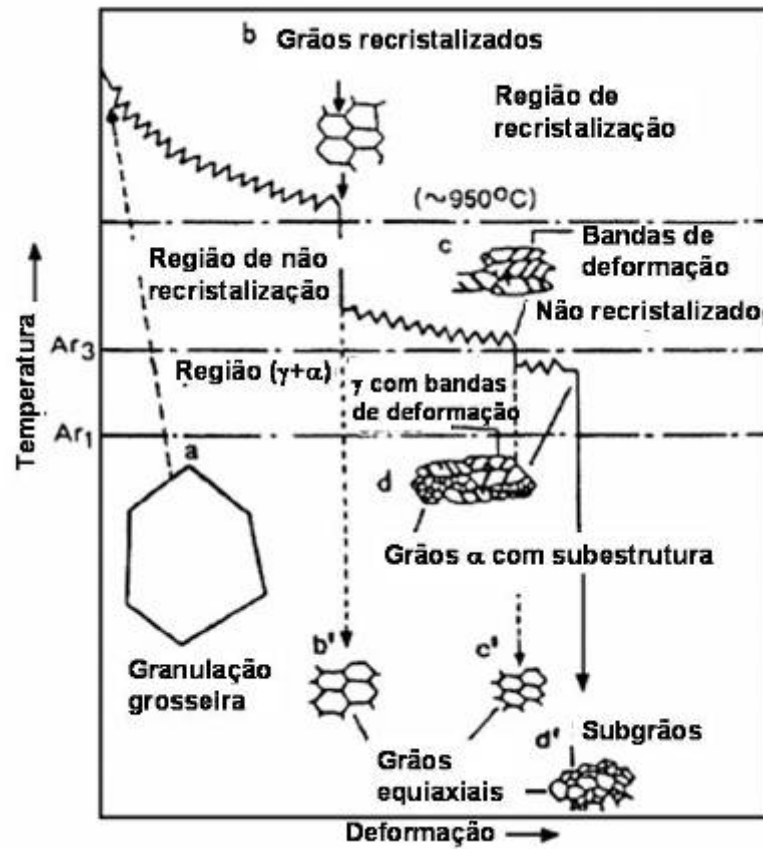


Figura 3.17: Ilustração Esquemática das mudanças na microestrutura com deformação durante a Laminação Controlada (40).

Estas mudanças estão relacionadas à deformação em três regiões:

- (1) Deformação na região de Recristalização: Nesta região o grão de austenita de granulação grosseira “a” é refinado por repetidas deformações e recristalização as quais produzem os grãos recristalizados “b”. Durante o resfriamento estes grãos se transformariam em ferrita de granulometria relativamente grosseira “b’”;
- (2) Deformação em região de Não Recristalização ⁽⁴⁰⁾: Nesta região, bandas de deformação são formadas na austenita alongada, não recristalizada “c”. Durante o resfriamento, a ferrita nuclearia nas bandas de deformação bem como nos contornos de grão “gama”, resultando nos finos grãos “alfa”;
- (3) Deformação na região “gama – alfa” ⁽⁴⁰⁾: Nesta região as bandas de deformação continuam a ser formadas e também a ferrita deformada

produz uma subestrutura “d”. Após deformação, durante o resfriamento, a austenita não recristalizada se transforma em grãos equiaxiais “alfa”, enquanto a ferrita deformada se transforma nos sub-grãos “d”.

Conforme citado na seção 1, o uso desta abordagem permitiria a laminação de perfis estruturais em aços de resistência mecânica mais elevada, maior soldabilidade além de implicar em significativa redução de custos devido à menor adição de elementos de liga.

CAPITULO 4 – METODOLOGIA

Para permitir a previsão das propriedades mecânicas de perfis laminados a partir de variáveis de seu processo de produção, foi desenvolvido, neste trabalho, um modelo em Rede Neural Artificial que foi treinado e validado com os dados de produção. Para isto, as seguintes etapas foram seguidas:

4.1 – Escolha do tipo de Perfil Estrutural para modelamento das propriedades mecânicas

Escolheu-se a bitola W200X46,1 [altura (d) X kg/m] em função de apresentar as seguintes particularidades:

- ✓ Possui amostragem na Aba, o que implica em uma menor variabilidade de resultados dos ensaios mecânicos;
- ✓ Trata-se de uma bitola com razoável quantidade de ensaios realizados em diversas normas técnicas (ASTM A572-50, ASTM A992, EN 10025-2). Desta forma tem-se um banco de dados com maior número de dados, ideal para o treinamento das Redes Neurais Artificiais.

Avaliaram-se outras bitolas (W250X32,7; W610X101,0), porém o pequeno número de dados disponíveis, além de maior variabilidade de resultados, inviabilizou a escolha das mesmas neste projeto.

O Perfil estudado possui as seguintes características dimensionais, de acordo com a figura 3.5:

- ✓ Altura: (d): 203mm;
- ✓ Largura da Aba (bf): 203mm;
- ✓ Espessura da alma (tw): 7,2mm;
- ✓ Espessura da aba (tf): 11,0mm;
- ✓ Altura interna da alma: 181mm;
- ✓ Altura livre da alma (d'): 161mm;
- ✓ Peso Linear: 46,1kg/m.

Como mostrado em 3.6.5 tal bitola possui amostragem para ensaios de propriedades mecânicas realizada na aba, uma vez que a largura de aba é superior a 150mm.

4.2 – O Banco de Dados

O banco de dados, que foi usado para o treinamento e validação da rede neural e para a definição de sua estrutura, continha dados de algumas etapas de processo. Além dos dados de processo, foram usados dados que permitem a identificação da campanha que está em processo de laminação e o tipo de aço (ASTM A572-50, ASTM A992, ASTM AH36, etc.). Estes dados são importantes para acompanhamento de processo das campanhas.

O banco de dados utilizado compreende o período entre 10/03/2003 e 07/03/2007, dos quais foram selecionados os registros para composição do banco de dados, com as seguintes características:

- ✓ Diversas normas (todas relativas a aços do tipo Alta Resistência e Baixa Liga);
- ✓ Inúmeras composições químicas padronizadas, denominadas SIGLAS (ver 4.2.1);
- ✓ Total de ocorrências igual a 461 (Este número se refere ao total de amostras retiradas de 207 diferentes corridas, submetidas aos ensaios de tração).

Conforme indicado na seção 1 existe a possibilidade de inserir inúmeras outras variáveis de processo. Por questão de limitações do Sistema Integrado de Controle da Laminação (SICLA) apenas as seguintes informações são passíveis de utilização no processo de implementação do Modelo de Previsão de Propriedades Mecânicas:

- ✓ Composição química do aço, com análise dos teores de 24 diferentes elementos químicos presentes no aço, resultado da análise do Laboratório Químico da Aciaria;
- ✓ Temperatura final de laminação na aba (Ver 3.6.5 e 4.1) do perfil estrutural W200X46,1;

- ✓ Espessura do corpo de prova proveniente da aba do perfil (3.6.5 e 4.1);
- ✓ Limite de Resistência, Limite de Escoamento e Alongamento.

Após análise da massa de dados recuperada observou-se que 11 dos elementos químicos disponíveis não tinham valores de resultados indicados em todos os registros. Estes elementos foram descartados como entrada da RNA. São: Ni, Co, Ca, Ti, B, W, Zr, As, Sb, Te e Pb.

4.2.1 – Dados Gerais

Estes dados são relativos à identificação do material. São parâmetros de processo que identificam o tipo de aço, bitola, corrida e bloco e garantem a rastreabilidade dos lotes em produção. Os dados selecionados são:

- ✓ Bitola (Tamanho padrão conforme norma ASTM);
- ✓ Data de Laminação;
- ✓ OPL (Ordem de Produção de Laminado): Remete ao lote sendo produzido na laminação de perfis;
- ✓ OPK (Ordem de Produção de Acabado): Remete à produção do Bloco Acabado;
- ✓ Código do Material: Código que permite identificar o material em termos de tipo de aço, bitola e comprimento final;
- ✓ Sigla: Código alfanumérico relativo à composição química padrão processada na Aciaria. A composição química padrão possui faixas para cada um dos elementos químicos com importância no processo de lingotamento, obtenção de propriedades mecânicas e características físicas dos produtos laminados;
- ✓ Bloco: Identifica a matéria prima do perfil laminado, ou seja, as dimensões nominais do bloco utilizado.

Estes registros não serão usados no processo de modelagem, mas são importantes para a utilização do modelo quando este for implantado no Sistema de Simulação.

4.2.2 – Redução percentual durante o Processo de Laminação

Tais dados mostram, por amostra ensaiada, a redução total sofrida pelo bloco até o perfil estrutural finalmente laminado.

Utilizou-se como espessura inicial a espessura do Beam Blank na região da aba, cuja seção transversal pode ser vista na figura 4.1 (ver item 3.6.5 e 4.1, a aba do perfil laminado é originária desta região). O Beam Blank é uma matéria prima intermediária, já significativamente conformada em processos anteriores de laminação a partir de um lingote, e o perfil laminado.

Tal valor foi obtido através do seguinte cálculo:

$$\% \text{Redução} = \frac{(\text{Espessura}_f - \text{Espessura}_i)}{\text{Espessura}_i} * 100 \quad (4.1)$$

As variáveis utilizadas são:

- ✓ Espessura f: Espessura final do perfil laminado no ponto de amostragem. É medido no Laboratório de Ensaios Mecânicos no corpo de prova preparado, antes do ensaio;
- ✓ Espessura i: Espessura inicial da aba do Beam Blank conforme ilustrado na figura abaixo. Tal região, após sofrer sucessivos passes de deformação, dará origem ao perfil laminado em sua espessura final.




Figura 4.1: Beam Blank do Perfil W200X46,1 com espessura da aba.

Foi adotada a espessura nominal (de projeto) do Beam Blank e não a espessura real devido ao fato de não existir medição de espessuras em tempo real durante o processo de laminação. Este fato limitador pode ser uma fonte de ruídos no modelo final uma vez que se trata de uma aproximação e não do resultado real. Em virtude da não disponibilidade dos valores reais não é possível estimar o impacto do uso da espessura nominal no modelo. Espera-se que eventuais melhorias de processo possam eliminar esta fonte de ruídos.

4.3 – Análise Estatística das Variáveis do Banco de Dados

O banco de dados obtido a partir das considerações feitas nas etapas anteriores possui um número muito elevado de variáveis. Espera-se, contudo, que uma grande parte delas esteja fortemente correlacionada ou tenha uma influência pouco significativa nas propriedades mecânicas do produto acabado nas condições operacionais usadas e que não precisem, assim, ser incluídas no modelo. Visando a análise do relacionamento entre as diversas variáveis de entrada com as propriedades mecânicas, foi realizada uma análise estatística dos dados obtidos com o objetivo de determinar quais variáveis seriam utilizadas no treinamento da Rede Neural e no modelo de previsão final. As seguintes análises foram realizadas:

- ✓ Análise de Correlação entre as diversas variáveis de entrada (Composição Química, Temperaturas, Reduções) e as saídas;
- ✓ Determinação dos valores médios, mínimos, máximos e desvios padrões dos dados de entrada;
- ✓ Histogramas;
- ✓ Tratamento de Dados: foi realizada análise estatística das inúmeras variáveis envolvidas, através do aplicativo MINITAB. Os dados utilizados foram apenas aqueles que estiveram incluídos dentro do intervalo +/- 3 desvios padrões visando diminuição na variabilidade total encontrada.
- ✓ Eliminação de pontos discrepantes: Eliminação dos dados que não foram considerados como representativos do processo. No caso das propriedades mecânicas (LE, LR), utilizou-se como critério de aceitação a diferença máxima de 20MPa dentro de uma mesma ordem de produção (mesma corrida, laminada na mesma campanha), tanto para LE quanto para LR. As ocorrências com diferenças superiores a 20MPa, foram excluídas. Adotou-

se o critério de 20MPa em função das ordens de produção normalmente apresentarem valores inferiores a este. Valores superiores normalmente estão ligados a alguma anormalidade de processo, tais como amostragem e ensaio.

As técnicas mencionadas acima foram utilizadas visando eliminar a presença de dados discrepantes, erros de medida, enfim, dados que poderiam vir a comprometer a confiabilidade do banco de dados.

4.4 – Análise Gráfica dos Dados

Estando definida a massa de dados para implantação da RNA utilizou-se o MINITAB para se analisar graficamente a relação das variáveis de saída (LE, LR e A) com as variáveis de entrada. O objetivo deste procedimento foi verificar qual o impacto da variação dos dados de entrada nas propriedades mecânicas.

Observou-se que os dados de composição química do banco de dados, obtidos a partir do SICLA, estavam truncados, isto é, apresentavam número de casas decimais menor que o obtido pela análise química. Como exemplo, os resultados de teor de carbono (% em peso) no banco de dados possuíam apenas duas casas decimais enquanto o processo de análise química fornecia resultados com uma maior precisão. Esta perda de informação poderia reduzir a eficiência do modelo que se pretendia desenvolver e, mesmo, dificultar o processo de minimização de seu erro. Assim, optou-se por substituir as informações de composição química obtidas do SICLA pelas correspondentes arquivadas no Laboratório de Análise Química. A figura 4.2 (a) mostra os histogramas do teor de carbono para os dados truncados (contidos originalmente no banco de dados).

O truncamento dos valores de entrada é um problema considerável para o processo de treinamento e validação de uma RNA, pois esconde características importantes do comportamento da variável, indispensáveis para minimização do erro de previsão do modelo.

Após a recuperação dos dados originais realizaram-se novamente todas as análises indicadas no item 4.2. A figura 4.2 (b) mostra o Histograma para o teor de carbono após atualização do banco com os dados revistos:




Figura 4.2: Dados Agrupados (a) X Dados não Agrupados (b) para o teor de Carbono.

Os resultados das análises gráficas e estatísticas do banco de dados estão descritos na seção 5, Resultados e Discussões.

4.5 – Desenvolvimento do Modelo

O desenvolvimento do modelo de Rede Neural Artificial envolveu os seguintes passos:

4.5.1 – Definição do Tipo de Rede Neural Artificial

O tipo de Rede Neural Artificial mais comumente utilizado tanto em aplicações gerais como na previsão de propriedades mecânicas é o de Propagação Reversa^(5, 21, 24) e este foi o tipo utilizado no presente trabalho. Os detalhes da arquitetura desta rede foram definidos a partir da estrutura do banco de dados. As propriedades mecânicas de interesse foram os Limites de escoamento e de Resistência e o Alongamento dos perfis laminados.

Uma Rede Neural Artificial do tipo Propagação Reversa consiste de⁽²⁵⁾:

- ✓ Uma camada de entrada cujos nodos representam as variáveis de entrada para o problema;

- ✓ Uma camada de saída com nodos representando as variáveis dependentes (isto é, o que está sendo modelado);
- ✓ Uma ou mais camadas ocultas contendo nodos para interpretação dos dados (os neurônios).

O comando padrão do MatLab utilizado para a criação da Rede Neural Artificial do tipo Propagação Reversa foi o NEWFF. A partir de uma série de argumentos, mostrados nos itens 4.5.4 a 4.5.11, tal comando cria uma rede com número de camadas N, definidas pelo usuário. De acordo com o item 3.3 as Redes Neurais Artificiais podem ser construídas com inúmeras camadas embora não haja vantagens nisso. De modo a diminuir a complexidade da rede decidiu-se por construir a rede com apenas uma camada oculta.

4.5.2 – Partição e Tamanho do Banco de Dados

O desenvolvimento de uma Rede Neural Artificial requer a partição dos dados em dois subconjuntos: Treinamento e Validação:

- ✓ Conjunto de Treinamento: Tais dados são utilizados para a determinação e atualização dos pesos do Modelo. Deve incluir todos os dados pertencentes ao domínio do problema ⁽²⁵⁾. Compreendeu um conjunto de dados aleatoriamente escolhidos através de um comando específico do MATLAB, o RANPERM (Random Permutation ou Busca e Referência Aleatória), a partir do banco de dados.
- ✓ Conjunto de Validação: Este conjunto inclui dados diferentes daqueles utilizados no primeiro conjunto, também selecionados a partir do comando RANPERM do MATLAB. Nota-se que no programa utilizado a separação dos conjuntos de treinamento e de validação se dá de maneira automática através da utilização deste comando, sendo garantida a distinção entre os dois conjuntos. Estes dados foram utilizados após a obtenção do modelo com menor erro para posterior validação de seu desempenho, antes que a rede seja considerada como desenvolvida.

A definição do tamanho dos dois subconjuntos provenientes do Banco de Dados original seguiu a seguinte regra ⁽²⁵⁾:

- ✓ Conjunto de Treinamento: 75% do Banco de Dados Original;
- ✓ Conjunto de Validação: 25%.

4.5.3 – Normalização dos dados

A normalização dos dados dentro de uma faixa (por exemplo: 0 a 1) é importante para (i) evitar que números grandes prevaleçam sobre números pequenos e, (ii) evitar a saturação prematura dos nós ocultos da rede, o que impede o processo de aprendizado. Isto é especialmente verdadeiro quando os dados de entradas reais assumem grandes valores ⁽²⁵⁾.

Não há um procedimento padronizado para o processo de normalização de dados de entrada e saída ⁽²⁵⁾. Uma maneira é distribuir os dados de entrada e saída (z_i) em um intervalo $[\lambda_1, \lambda_2]$ correspondente ao intervalo da função de transferência ⁽²⁵⁾.

$$x_i = \lambda_1 + (\lambda_2 - \lambda_1) * \left(\frac{z_i - z_i^{\min}}{z_i^{\max} - z_i^{\min}} \right) \quad (4.2)$$

Uma outra maneira é utilizar a seguinte equação:

$$x_i = \frac{z_i - z_i^{\min}}{z_i^{\max} - z_i^{\min}} \quad (4.3)$$

Onde x_i é o valor normalizado de z_i . z_i^{\max} , z_i^{\min} são, respectivamente, os valores máximos e mínimos de z_i no banco de dados ⁽²⁵⁾. Outras técnicas mais complicadas podem ser utilizadas mas podem não produzir solução melhor do que a técnica de normalização linear (Equação 4.2). Para parâmetros com um intervalo excepcionalmente grande pode ser benéfico calcular o logaritmo dos dados antes da

normalização (Se os dados contêm valores zero, $\text{Log}(z_i + 1)$ pode ser utilizado) ⁽²⁵⁾. Pela simplicidade de utilização foi utilizada no presente trabalho a equação 4.3.

4.5.4 – Inicialização dos Pesos da Rede

A inicialização de uma rede envolve a designação de valores iniciais para os pesos (e pontos iniciais) de todas as conexões. Alguns pesquisadores indicam que a inicialização dos pesos pode ter um efeito na convergência dos dados ⁽²⁵⁾. Um dos estudos mostrou que se o Vetor Peso Inicial está posicionado em uma região plana na superfície de erro, pode se ter uma convergência bastante lenta. Outros estudos mostram que a inicialização tem um efeito insignificante na convergência e arquitetura final da rede ⁽²⁵⁾.

Tipicamente os pesos e os mínimos valores requeridos para estímulo dos neurônios são inicializados uniformemente em um intervalo relativamente pequeno com números aleatórios. No entanto, um intervalo extremamente curto pode levar a gradientes de variação do erro muito pequenos o que pode tornar mais lento o processo de aprendizado inicial. A escolha de números pequenos é essencial para reduzir a probabilidade de saturação prematura dos neurônios. Basheer e Hajmeer ⁽²⁵⁾ citam um estudo que recomenda pequenos valores aleatórios iniciais de Pesos e Pontos Iniciais entre -0,30 e 0,30. Um outro estudo propõe a inicialização dos pesos da rede de tal maneira que cada exemplar de entrada imponha um aprendizado eficiente aos nodos ocultos ⁽²⁵⁾.

Nguyen e Widrow ⁽⁴²⁾ inicializam o vetor de pesos de tal maneira que cada exemplar de entrada forçará o aprendizado eficiente do neurônio ⁽²⁵⁾. O Algoritmo de Nguyen e Widrow gera pesos e fatores de ajuste iniciais para uma camada de tal maneira que as regiões ativas das camadas de neurônios são distribuídas aproximadamente de maneira uniforme no espaço de entrada.

Neste trabalho, utiliza-se o comando INITNW do MatLab. Tal comando é uma função de inicialização que inicializa os pesos das camadas de acordo com o algoritmo de inicialização de Nguyen-Widrow. Trata-se do método padrão utilizado pelo MatLab.

4.5.5 – Taxa de aprendizado da Rede de Propagação Reversa

Uma alta taxa de aprendizado, η , irá acelerar o treinamento através de uma mudança do vetor de peso significativamente grande de um ciclo para outro. No entanto, isto pode fazer com que a procura pelo erro mínimo oscile na superfície de erro e a convergência nunca ocorra, aumentando, desta maneira o risco de definir erroneamente um vetor de pesos quase ótimo. Em contraste, uma pequena taxa de aprendizado leva a procura pelo mínimo erro continuamente na direção de um mínimo global, embora vagorosamente. Uma taxa de aprendizado constante pode ser utilizada em todo o processo de treinamento. Valores recomendados por Basheer e Hajmeer ⁽²⁵⁾ estão entre $\eta = 0,1$ e 10 . Uma taxa de aprendizado adaptativa, $[\eta(t)]$, a qual varia ao longo do curso de treinamento pode também ser utilizada e pode ser efetiva em se obter um vetor de peso ótimo em algumas situações. Geralmente, grandes passos são necessários quando a procura está distante do mínimo e passos menores quando a procura se aproxima do mínimo erro ⁽²⁵⁾.

No presente trabalho utilizou-se o comando TRAINGDX do MatLab. Tal comando é uma função de treinamento de redes que atualiza os valores pesos e ajustes de acordo com o gradiente descendente do momento e à uma taxa de aprendizado adaptativa ⁽⁴³⁾. Trata-se do método padrão utilizado pelo MatLab.

4.5.6 – Função de Transferência

A função de transferência (ou função de ativação), σ , é necessária para transformar a soma ajustada de todos os sinais que tiveram impacto em um neurônio bem como determinar sua intensidade ⁽²⁵⁾. A maioria das aplicações utilizando Redes Neurais Artificiais de Propagação Reversa emprega uma função sigmoideal, a qual possui as propriedades de continuidade e diferenciabilidade em $(-\infty, \infty)$, requerimentos essenciais no aprendizado do método de Propagação Reversa. Diversos estudos mostram várias taxas de sucesso com diferentes funções de transferências em relação à não linearidade de dados e presença de ruídos. A vantagem de escolher uma função de transferência particular não é ainda teoricamente entendida ⁽²⁵⁾.

As funções de transferência de uma rede do tipo Propagação Reversa podem ser quaisquer funções diferenciáveis tais como Tangente Sigmoidal, Logaritmo Sigmoidal ou Linear Puro.

No modelo de previsão de propriedades mecânicas proposto foi escolhida como função de transferência a função Tangente Sigmoidal (Comando TANSIG do MatLab) por se tratar de um método bastante utilizado nas previsões de propriedades mecânicas em processos siderúrgicos ⁽²¹⁾ e possuir as características essenciais de aprendizado do método de Propagação Reversa.

4.5.7 – Critério de Convergência

O parâmetro mais comumente utilizado para caracterizar o erro para a interrupção do treinamento da Rede Neural é a soma dos quadrados dos erros (SSE, Sum of Squared Errors), calculado para o treinamento ou para testar os subconjuntos de dados ⁽²⁵⁾. É calculado conforme equação 4.4:

$$SSE = \frac{1}{N} \sum_{p=1}^N \sum_{i=1}^M (t_{pi} - O_{pi})^2 \quad (4.4)$$

Onde O_{pi} e t_{pi} são, respectivamente, a solução obtida e o valor real ou alvo do i -ésimo nodo de saída do p -ésimo exemplo, N é o número de exemplos (ou dados) de treinamento e M é o número de nodos de saída. Alguns critérios SSE incorporam uma medida de complexidade da arquitetura da rede. Geralmente o erro nos dados de treinamento decresce indefinidamente com o acréscimo no número de nodos ocultos ou de ciclos de treinamento, como mostrado na figura 4.3:

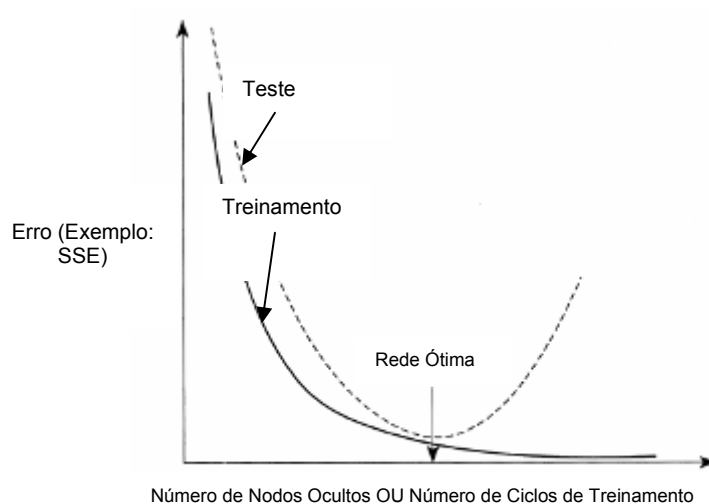


Figura 4.3: Critério para interrupção do treinamento e seleção da arquitetura ótima da rede

A grande queda inicial no erro é devida ao aprendizado, mas a subsequente redução lenta no erro pode ser atribuída a:

- I. Memorização pela rede, a qual resulta do grande número de ciclos de treinamento utilizados, e/ou;
- II. Superajuste, devido ao grande número de nós ocultos utilizados.

Durante o treinamento da Rede Neural Artificial, o erro nos subconjuntos de teste é monitorado. Este geralmente apresenta uma redução inicial seguida por um aumento subsequente devido à memorização e super treinamento da rede já treinada. A arquitetura final (ótima) da rede é obtida quando o erro nos dados de teste atinge o seu valor mínimo como é mostrado na figura 4.3 ⁽²⁵⁾.

No presente trabalho, o critério de convergência a ser utilizado será o SSE e o erro mínimo objetivado é igual a 0,001.

4.5.8 – Número de Ciclos de Treinamento

O número de ciclos de treinamento requerido para generalização apropriada pode ser determinado por tentativa e erro. Para uma dada arquitetura de RNA, o erro nos dados de treinamento e teste é monitorado para cada ciclo de treinamento. Longos treinamentos podem resultar em uma rede adequada apenas àqueles dados

utilizados para o seu treinamento, ou seja, uma rede incapaz de generalização, um fenômeno chamado de super treinamento ou memorização ⁽²⁵⁾.

Quando uma rede perde sua habilidade de generalizar percebe-se aumento no erro SSE após cada período de treinamento. Embora o erro nos dados de teste possa variar de forma não suave, o ponto a partir do qual este erro passa a aumentar de forma consistente é considerado como o ponto que define o número ótimo de ciclos para aquela arquitetura da RNA ⁽²⁵⁾.

Adotou-se o número máximo de ciclos de treinamento igual a 700 por permitir um tempo de treinamento longo o suficiente de modo a minimizar o erro.

4.5.9 – Modos de Treinamento

Os exemplos de treinamento são apresentados à rede em um modo ou uma combinação de dois modos:

- I. Treinamento Exemplo a Exemplo, (EET, Example by Example Training), e;
- II. Treinamento por batelada (BT, Batch Training).

No modo EET os pesos são atualizados imediatamente após a apresentação de cada exemplo de treinamento. Neste, o primeiro exemplo é apresentado à rede e o algoritmo de aprendizado por Propagação Reversa é aplicado até que se atinja um número especificado de iterações ou queda do erro até um nível desejado. Uma vez aprendido o primeiro exemplo, apresenta-se o segundo exemplo e então todo o procedimento é repetido. As vantagens do EET incluem, ao contrário do modo BT, menores requerimentos de armazenamento para os pesos e à melhor busca estocástica, a qual evita o aprisionamento da rede em um mínimo local ⁽²⁵⁾. As desvantagens da EET estão associadas com o fato de que o aprendizado pode se tornar preso em um primeiro exemplo ruim, o que pode forçar a procura em uma direção errada ⁽²⁵⁾.

De maneira oposta, o modo BT requer que a atualização dos pesos seja realizada após todos os exemplos de treinamento sejam apresentados à rede. Isto é, o

primeiro ciclo de treinamento incluirá a apresentação de todos os exemplos de treinamento, o erro sendo uma média de todos os exemplos de treinamento e então propagados de maneira reversa de acordo com lei de aprendizado do método de propagação reversa. Uma vez realizada esta etapa, o segundo ciclo inclui outra apresentação de todos os exemplos e assim se segue. As vantagens do modo BT incluem uma melhor estimativa do vetor gradiente de erro e uma medida mais representativa da mudança requerida nos pesos. No entanto, este modo de treinamento requer grande armazenamento dos pesos e é mais suscetível de ser aprisionada em um mínimo local. Para uma melhor procura a ordem de apresentação dos exemplos pode ser mudada aleatoriamente entre sucessivos ciclos de treinamento ⁽²⁵⁾.

Em função da melhor precisão (melhor estimativa do vetor gradiente de erro e medida mais representativa da mudança requerida nos pesos) do método BT, este foi o método selecionado para a construção do modelo proposto.

4.5.10 – Tamanho da Camada Oculta

Na maioria dos problemas de aproximação de funções, uma camada oculta é suficiente para aproximar funções contínuas. Geralmente, duas camadas ocultas podem ser necessárias para o aprendizado de funções com descontinuidades. A determinação do número apropriado de camadas ocultas e do número apropriado de nodos ocultos (NHN, Number of Hidden Nodes) em cada camada é uma das tarefas mais críticas no projeto de uma Rede Neural Artificial. Ao contrário do que ocorre com as camadas de entrada e saída, começa-se o desenvolvimento de uma RNA sem conhecimento prévio do número e tamanho das camadas ocultas ⁽²⁵⁾.

Como mostrado na figura 4.4, uma rede com número insuficiente de nodos ocultos pode ser incapaz de diferenciar entre padrões complexos, levando apenas a uma estimativa linear da tendência real. Em contraste, se uma rede possui um número excessivo de nodos ocultos, ela irá seguir o ruído presente nos dados devido à superparametrização levando a generalização pobre para dados não treinados ⁽²⁵⁾.

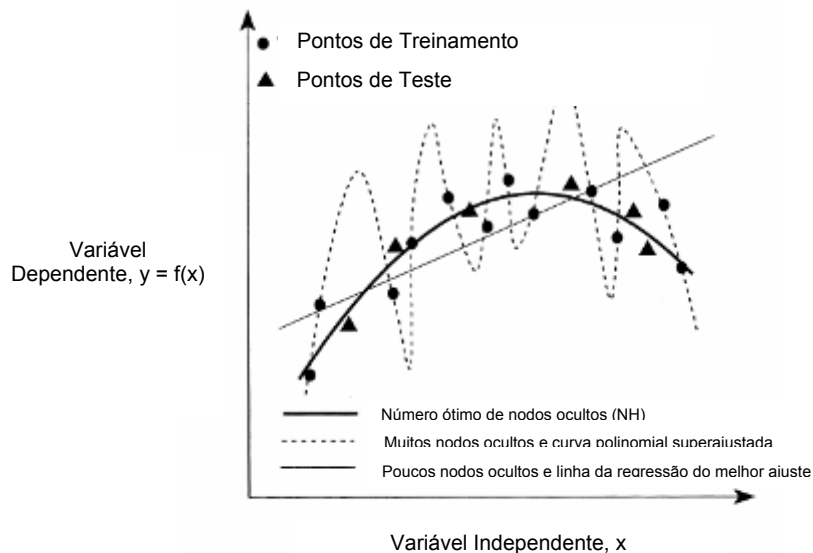


Figura 4.4: Efeito do tamanho da camada oculta na generalização da rede

O número ótimo de nodos ocultos para generalização da rede pode ser função do tamanho dos vetores de entrada e saída e tamanho dos subconjuntos de teste. Existem regras práticas na literatura que relacionam o tamanho da camada oculta ao número de nodos nas camadas de entrada (N_{INP}) e saída (N_{OUT}). As equações abaixo (4.5 a 4.8) mostram algumas abordagens ⁽²⁵⁾:

$$✓ \quad NHN \approx (N_{INP} * N_{OUT})^{1/2} \quad (4.5)$$

$$✓ \quad NHN \leq N_{INP} + 1 \quad (4.6)$$

$$✓ \quad N_W = N_{TRN} * \text{Log}_2(N_{TRN}), \text{ onde } N_W \text{ é o número total de pesos e } N_{TRN} \text{ é o número de padrões de treinamento} \quad (4.7)$$

$$✓ \quad N_W / N_{OUT} \leq N_{TRN} \leq (N_W / N_{OUT}) * \text{Log}2(N_W / N_{OUT}) \quad (4.8)$$

A abordagem mais comum para se encontrar o número ótimo de nodos ocultos é por tentativa e erro com uma das regras acima sendo utilizada como ponto inicial. No entanto, uma maneira mais simples é começar com um pequeno número de nodos ocultos e aumentá-lo quando necessário para atender a precisão desejada do modelo ⁽²⁵⁾.

De acordo com o exposto acima a definição do tamanho da camada oculta foi feita através de abordagem estatística dos resultados obtidos para um número inicial de neurônios igual a 4 com critério de escolha utilizando Análise de Variância realizada no software MINITAB.

4.5.11 – Processo de Treinamento da Rede Neural Artificial

O processo de treinamento atualiza os pesos e fatores de ajuste da Rede ⁽²⁵⁾. Foi utilizada uma função específica do MatLab (TRAINBR) para o processo de treinamento da Rede. Esta função minimiza a combinação dos pesos e erros quadráticos (SSE, seção 4.5.7), de acordo com o algoritmo padrão de otimização, e então determina a combinação correta de modo a produzir uma rede que tenha boa capacidade de generalização.

O treinamento ocorre de acordo com os parâmetros de treinamento da função TRAINBR dentre as quais se tem ⁽⁴³⁾:

- ✓ Número máximo de épocas de treinamento;
- ✓ Erro objetivado (%);
- ✓ Valor adaptativo que indica evolução na queda do erro;
- ✓ Fator para uso de memória dos recursos computacionais utilizados;
- ✓ Gradiente de desempenho mínimo padrão: Fator que indica o desempenho de aprendizado da rede através da taxa de aprendizado (Ver 4.5.5);
- ✓ Tempo máximo de treinamento em segundos.

O processo de treinamento é interrompido quando uma das condições abaixo ocorre ⁽⁴³⁾:

- ✓ O número máximo de épocas (Repetições) é alcançado;
- ✓ O tempo máximo de treinamento é excedido;
- ✓ O erro é minimizado ao valor mínimo objetivado;
- ✓ A evolução da queda do erro é interrompida (Não ocorre minimização do erro);
- ✓ O gradiente de desempenho cai abaixo do mínimo valor padrão: O processo de aprendizado não ocorre de maneira eficaz.

Todas as funções aqui mencionadas fazem parte da caixa de ferramentas para desenvolvimento de Redes Neurais Artificiais no Software Matlab (Neural Network Toolbox). Não faz parte do escopo deste projeto a descrição detalhada da implementação de RNA's neste software, mas sim fazer uso de suas funcionalidades e

recursos visando o desenvolvimento das RNA's para previsão de propriedades mecânicas de Perfis Estruturais Laminados a Quente.

A tabela V.33 mostra as características das Redes Neurais Artificiais utilizadas neste trabalho.

4.6 – Simulação das Propriedades Mecânicas a partir dos dados de entrada

A etapa seguinte ao desenvolvimento da RNA foi a simulação dos valores de propriedades mecânicas a partir do conjunto de dados de entrada reservados para a validação da Rede. 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 das propriedades mecânicas e erros percentuais calculados, elaboraram-se três diferentes gráficos para análise dos resultados da validação da RNA. Estes gráficos foram os seguintes:

- ✓ Gráfico de correlação linear: valor medido x valor previsto (Inclui-se um gráfico seqüencial auxiliar o qual permite comparar os valores reais com os valores simulados para cada uma das 111 amostras utilizadas no processo de validação da rede);
- ✓ Curva “Amostra X Erro Percentual” com indicação do erro médio.

Os seguintes parâmetros são utilizados para interpretar os resultados obtidos no processo de treinamento:

- ✓ Mínimo erro percentual na validação de LE, LR e A: Mínimo valor obtido para o erro percentual;
- ✓ Máximo erro percentual na validação de LE, LR e A: Máximo valor obtido para o erro percentual;
- ✓ Erro percentual médio na validação de LE, LR e A: Média dos valores de erro percentual obtidos;
- ✓ Correlação Linear entre LE, LR e A estimado e LE, LR e A medidos.

O erro é calculado através da fórmula 4.9:

$$\% Erro = \left| \frac{(Valor Real - Valor Simulado)}{Valor Real} * 100 \right| \quad (4.9)$$

O coeficiente de correlação de Pearson (Ou coeficiente de correlação linear), ρ , mede o grau de relacionamento linear entre duas variáveis. Para duas variáveis, x e y tem-se a equação 4.10:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} \quad (4.10)$$

Onde \bar{x} é a média amostral para a primeira variável, S_x é o desvio padrão para a primeira variável, \bar{y} , é a média amostral para a segunda variável, S_y é o desvio padrão para a segunda variável e n é o tamanho da amostra.

O coeficiente de correlação linear (Pearson, fórmula 4.10) é calculado através do comando CORRCOEF do Matlab e é o coeficiente linear padrão no MINITAB. Essa função produz uma matriz de coeficientes de correlação para uma matriz de dados, onde cada coluna representa uma quantidade separada. Os coeficientes de correlação assumem valores entre -1 e +1.

O desvio padrão fornece uma medida do espalhamento dos dados utilizados. É igual à raiz quadrada da variância amostral. Se a coluna contém x_1, x_2, \dots, x_N dados com média \bar{x} , então o desvio padrão é dado pela equação 4.11:

$$S = \sqrt{\frac{\sum x_i^2 - (\sum x_i)^2 / N}{N-1}} \quad (4.11)$$

Onde: X_i é a i ésima observação, \bar{x} é a média das observações e N é o número de observações.

O desvio padrão é calculado através do comando STD do Matlab e a fórmula acima é a mesma utilizada pelo MINITAB (StdDev).

Ao final de todo o processo, foram elaborados gráficos nos quais a variação prevista pelo modelo das propriedades mecânicas é simulada para cada uma das variáveis de entrada. Em cada simulação realizada altera-se uma determinada variável dentro de seus limites de treinamento (do valor mínimo ao valor máximo) e fixam-se as outras variáveis de entrada nos seus respectivos valores médios.

Em função do discutido no item 3.1.1 tal procedimento teve como objetivo verificar se os modelos implementados eram capazes de refletir alguns dos aspectos do processo apresentados nas seções 3.7.1 e 3.7.2.

4.7 – Modelamento em Regressão Múltipla Linear

Elaborou-se no MINITAB modelo em Regressão Múltipla Linear visando previsão das propriedades mecânicas com o intuito de comparar os resultados assim obtidos com os resultados obtidos via Redes Neurais Artificiais.

A base de dados adotada foi a mesma utilizada no modelamento por Redes Neurais Artificiais. Assim sendo tal análise foi realizada individualmente para LE, LR e A. De acordo com a seção 1, tem-se a seguinte equação:

$$y = b_1 * x_1 + b_2 * x_2 + \dots + b_n * x_n + c \quad (4.12)$$

A base de dados utilizada foi a mesma da modelagem por RNA obtida após análise estatística descrita em 4.3 e critério de escolha das variáveis descrito em 5.3. Somente as variáveis de entrada e saída utilizadas no modelamento por RNA foram utilizadas no modelamento por Regressão Múltipla Linear. As demais variáveis existentes foram desprezadas.

CAPITULO 5 – RESULTADOS E DISCUSSÕES

5.1 – Análise gráfica do Banco de Dados

5.1.1 – Análise de Correlação: Limite de Escoamento X Variáveis de Entrada

A figura 5.1 ilustra a dependência do Limite de Escoamento em relação às diversas variáveis de processo disponíveis.

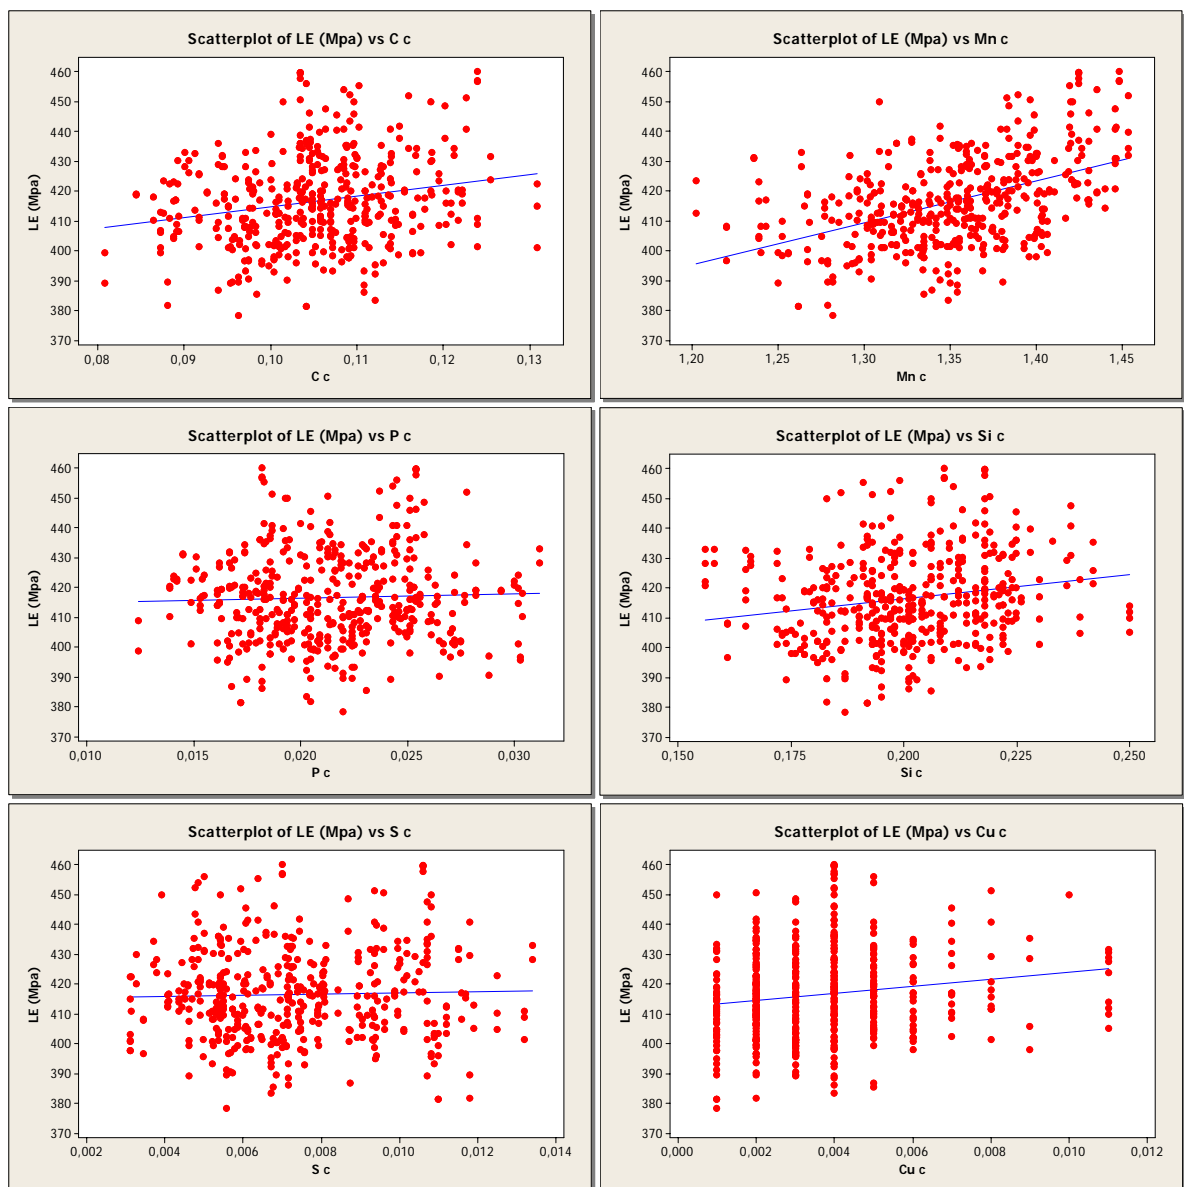


Figura 5.1: Curvas de Tendência: Limite de Escoamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.

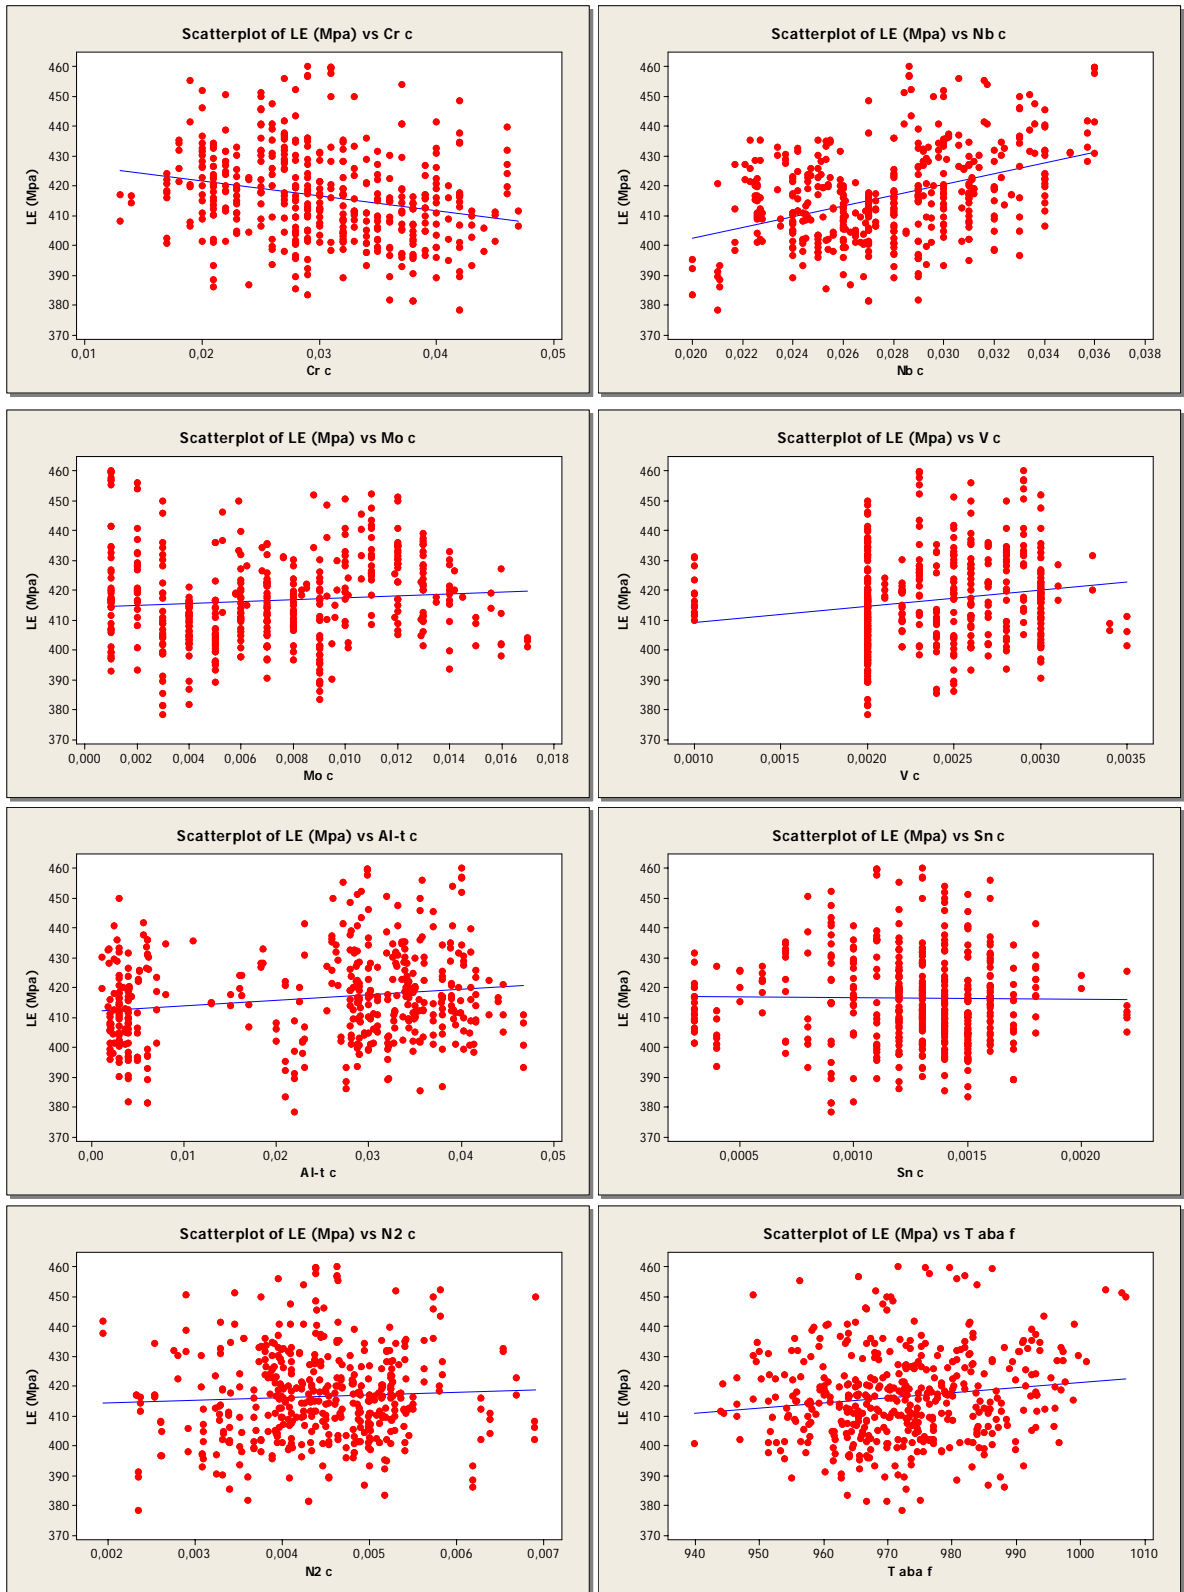


Figura 5.1 (Continuação): Curvas de Tendência: Limite de Escoamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.




Figura 5.1 (Continuação): Curvas de Tendência: Limite de Escoamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.

5.1.2 – Análise de Correlação: Limite de Resistência X Variáveis de Entrada

A figura 5.2 ilustra a dependência do Limite de Resistência em relação às diversas variáveis de processo disponíveis.

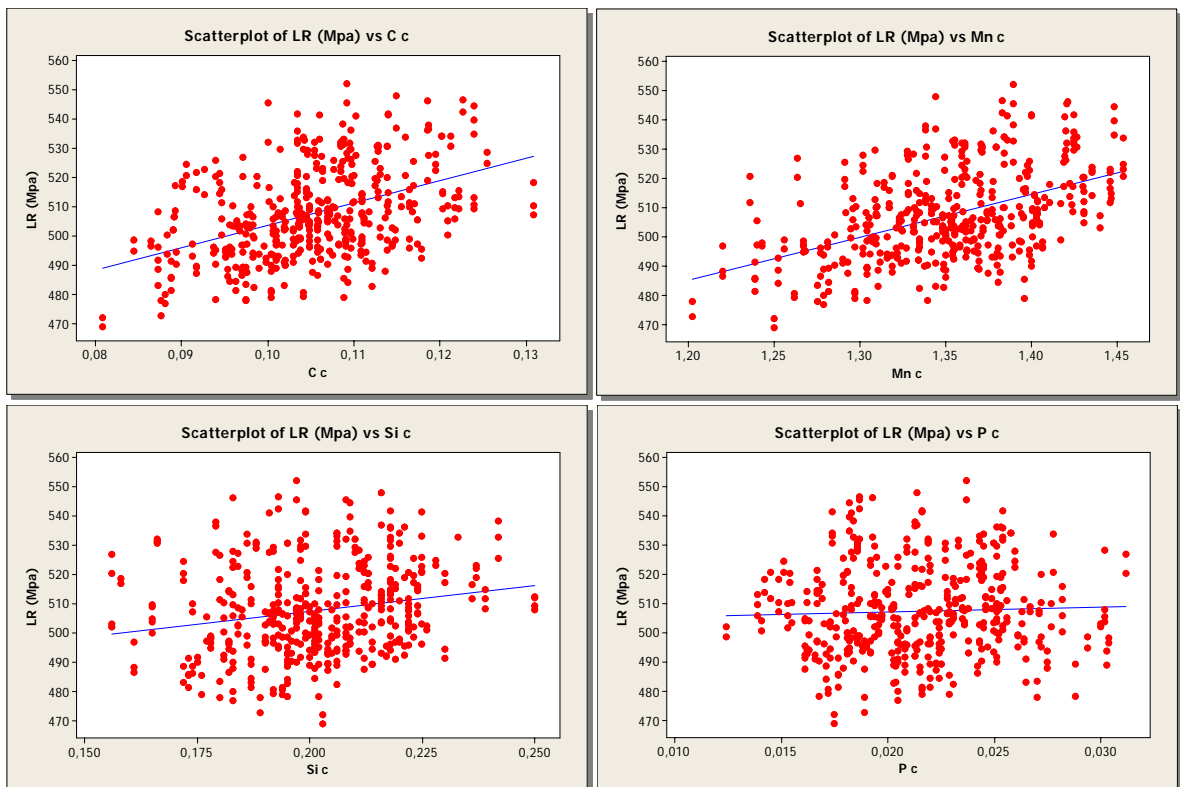


Figura 5.2: Curvas de Tendência: Limite de Resistência em função das diversas variáveis de processo disponíveis. Dados reais de produção.

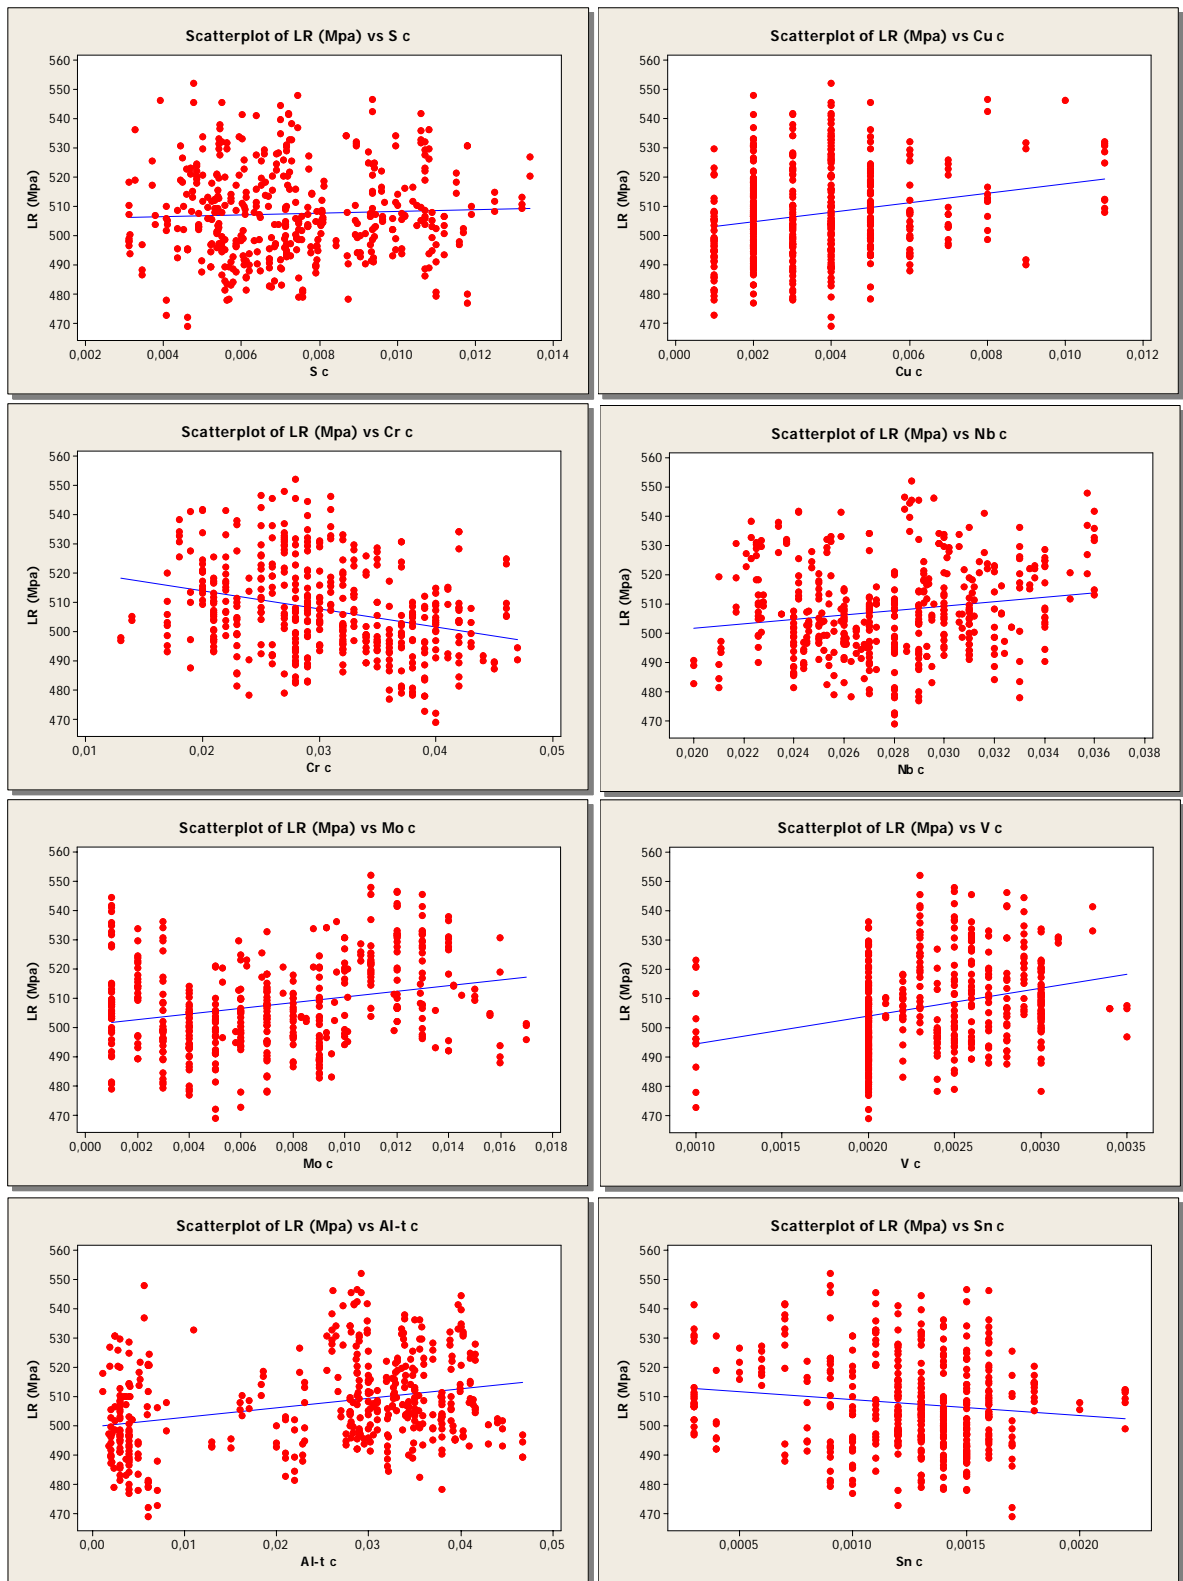


Figura 5.2 (Continuação): Curvas de Tendência: Limite de Resistência em função das diversas variáveis de processo disponíveis. Dados reais de produção.

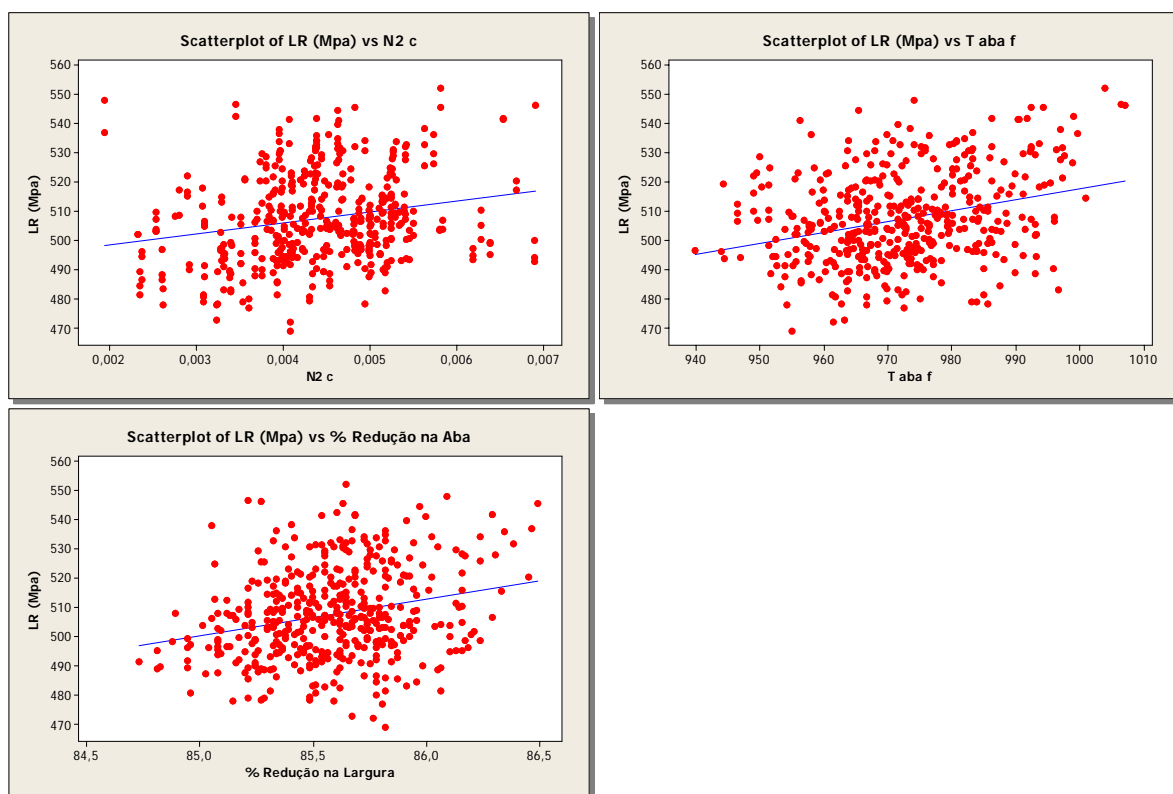


Figura 5.2 (Continuação): Curvas de Tendência: Limite de Resistência em função das diversas variáveis de processo disponíveis. Dados reais de produção.

5.1.3 – Análise de Correlação: Alongamento X Variáveis de Entrada

A figura 5.3 ilustra a dependência do Alongamento em relação às diversas variáveis de processo disponíveis.

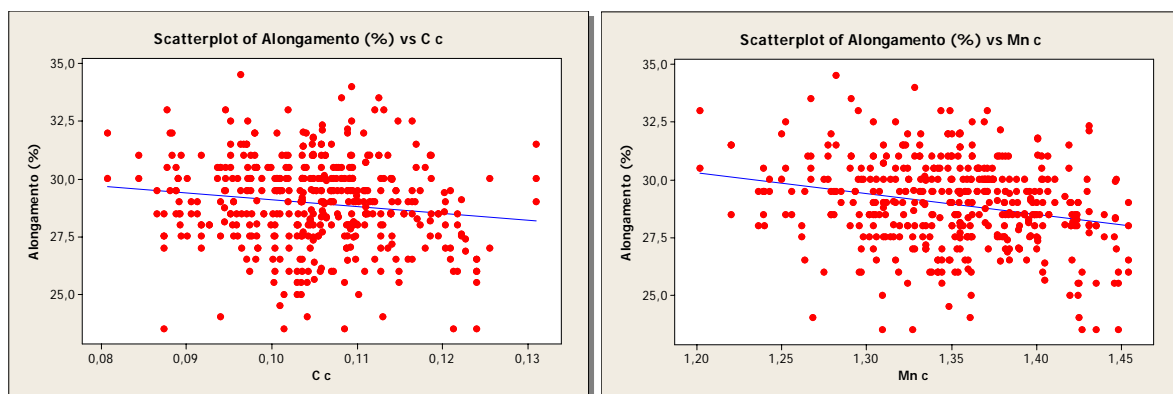


Figura 5.3: Curvas de Tendência: Alongamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.

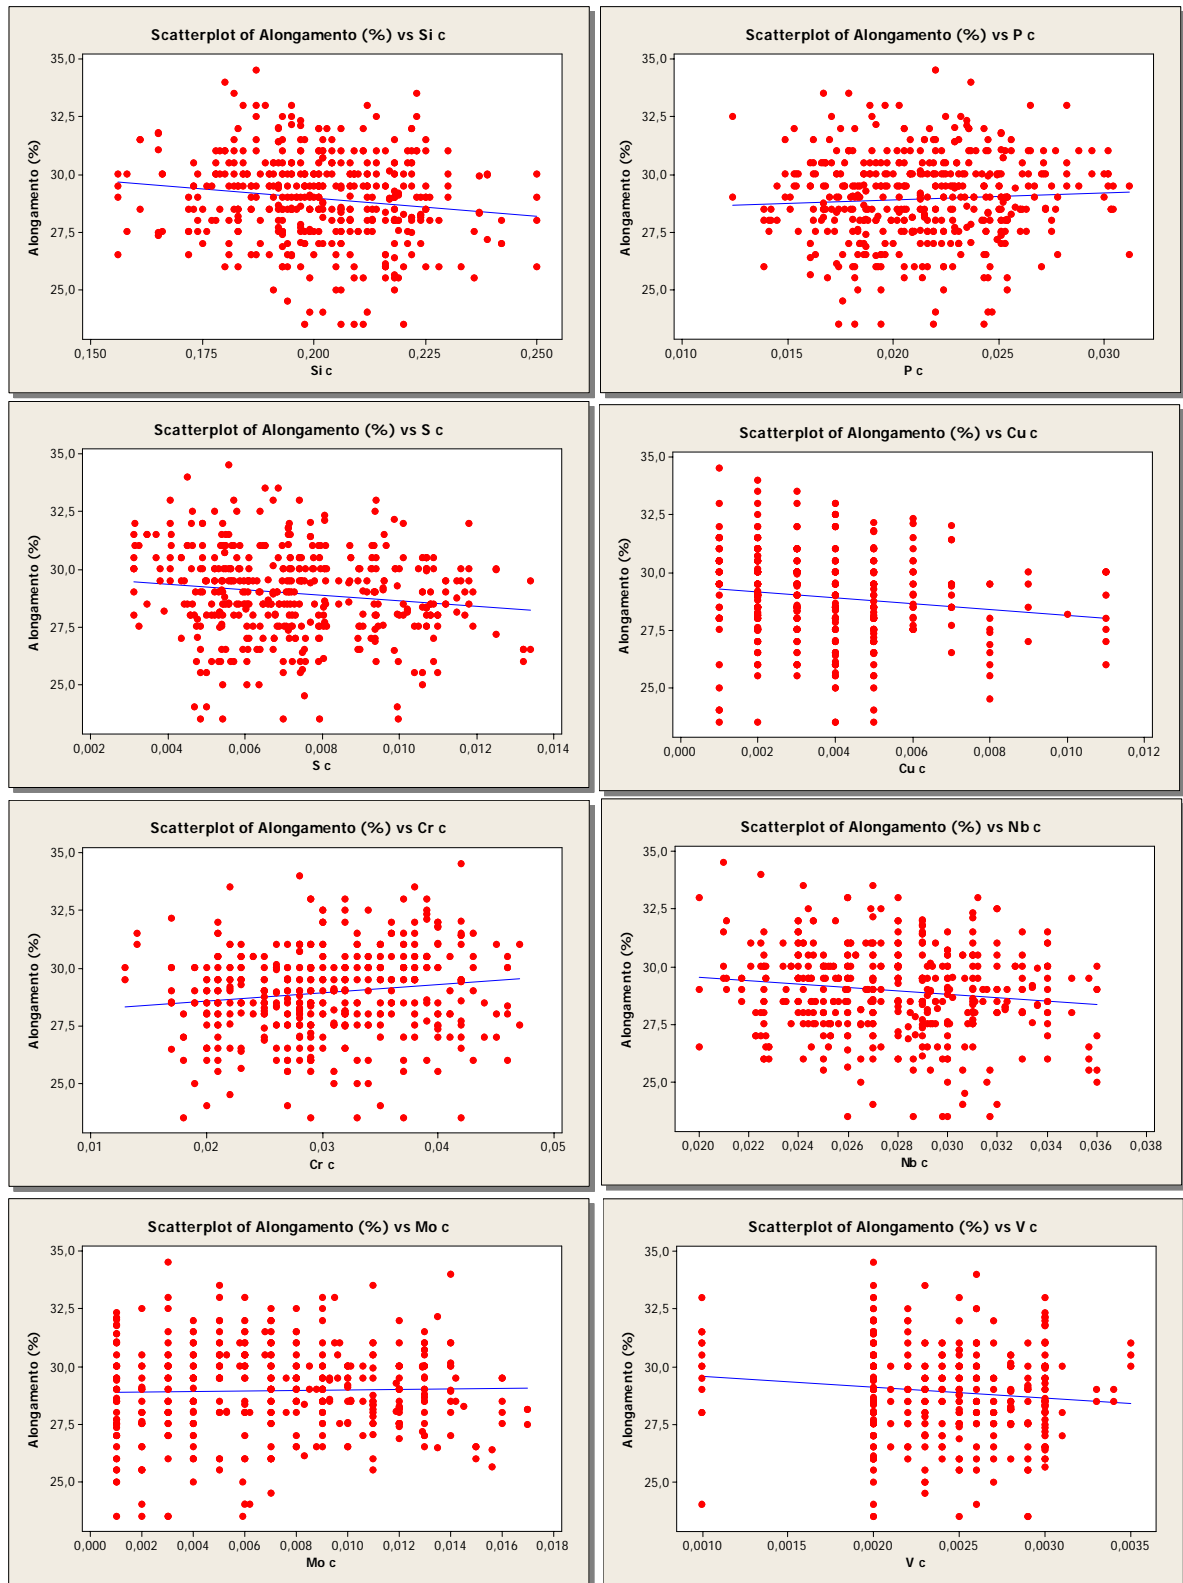


Figura 5.3 (Continuação): Curvas de Tendência: Alongamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.

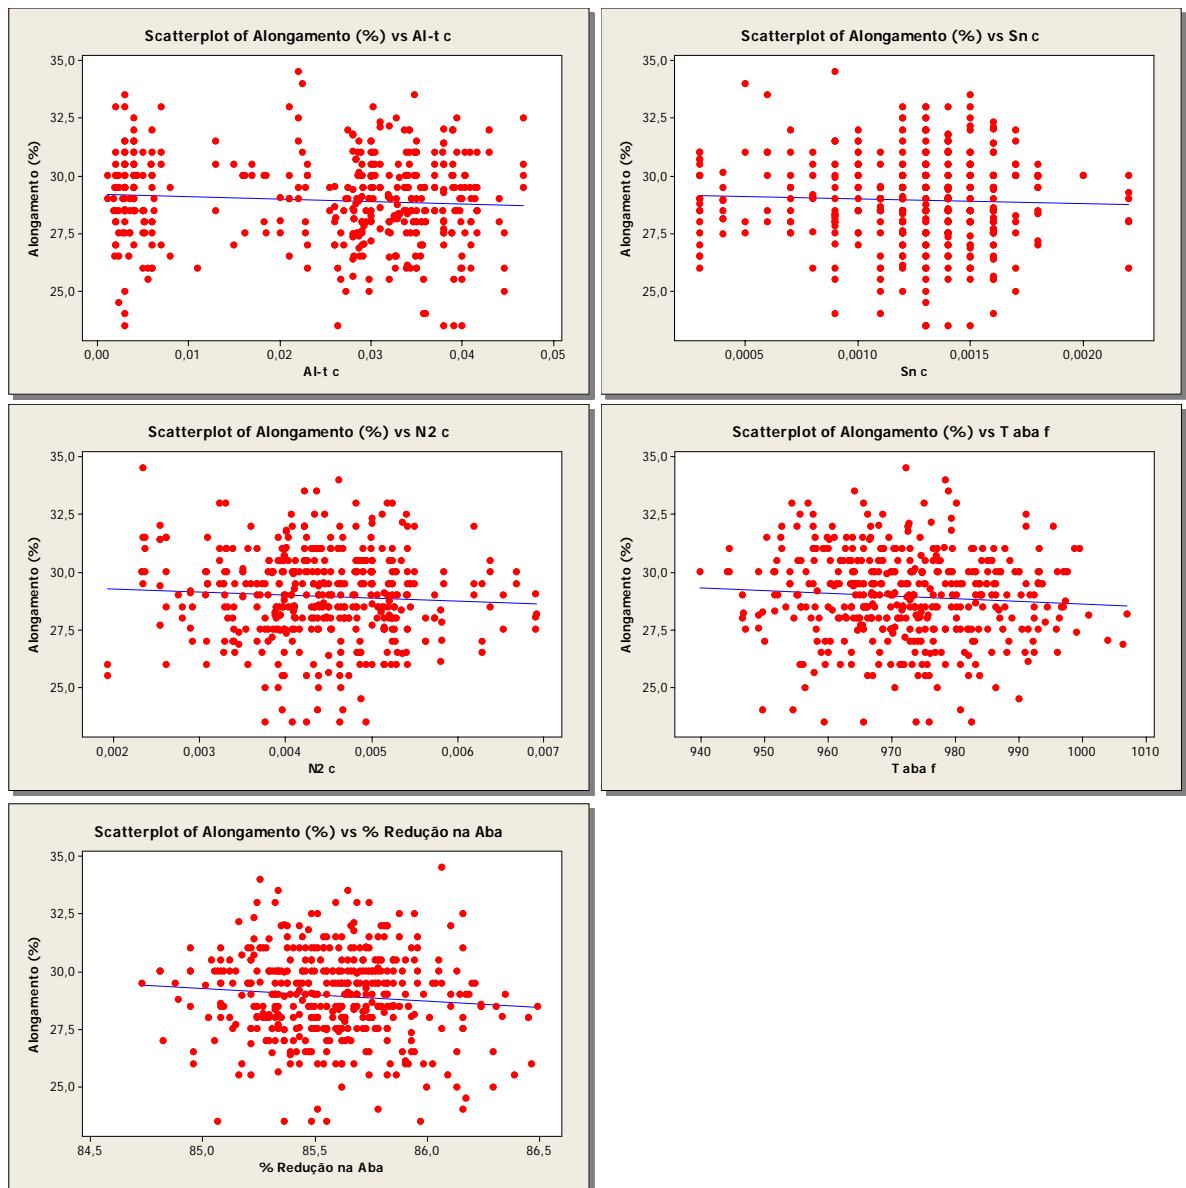


Figura 5.3 (Continuação): Curvas de Tendência: Alongamento em função das diversas variáveis de processo disponíveis. Dados reais de produção.

5.2 – Resumo do Banco de Dados sem Tratamento Estatístico

Como informação adicional, a tabela V.1 resume as informações estatísticas de todas as variáveis de processo disponíveis. Estas informações foram obtidas de um total de 461 ocorrências de resultados de testes mecânicos. Estes resultados ilustram o banco de dados original, sem nenhum tratamento estatístico.

Tabela V.1: Resumo Estatístico – Banco de Dados Inicial

Variável de Entrada	Unidade	Média	Máximo	Mínimo	Desvio Padrão	3- Sigma	3+ Sigma
Limite de Escoamento	MPa	416,93	461,67	378,35	15,36	370,86	463,01
Limite de Resistência	MPa	507,92	551,99	469,10	15,58	461,19	554,65
Alongamento	%	28,84	34,50	20,00	2,03	22,74	34,93
C	%	0,1052	0,1309	0,0808	0,0089	0,0784	0,1319
Mn	%	1,3521	1,4540	1,2020	0,0508	1,1997	1,5045
Si	%	0,2011	0,2500	0,1560	0,0174	0,1489	0,2533
S	%	0,0075	0,0160	0,0031	0,0026	0,0000	0,0153
Cr	%	0,0302	0,0470	0,0130	0,0073	0,0082	0,0521
Nb	%	0,0278	0,0360	0,0200	0,0035	0,0174	0,0383
N	%	0,0044	0,0069	0,0019	0,0009	0,0018	0,0071
P	%	0,0214	0,0312	0,0124	0,0037	0,0102	0,0326
Cu	%	0,0036	0,0110	0,0010	0,0020	0,0000	0,0098
Mo	%	0,0071	0,0170	0,0010	0,0041	0,0000	0,0194
V	%	0,0024	0,0035	0,0010	0,0004	0,0010	0,0037
Al _t	%	0,0238	0,0467	0,0011	0,0140	0,0000	0,0658
Sn	%	0,0012	0,0022	0,0003	0,0004	0,0001	0,0024
Temperatura Final de Laminação	°C	972,50	1007,05	939,84	12,45	935,15	1009,84
Redução no Laminador Tandem	%	85,58	86,49	84,73	0,31	84,66	86,51

5.3 – Escolha das Variáveis de Entrada

As seguintes etapas foram seguidas para a seleção das variáveis do modelo:

1. Elaboração da Matriz de Correlação (ρ) entre as variáveis de entrada e as variáveis de saída, conforme tabela V.2 abaixo:

Tabela V.2: Matriz de Correlação – Banco de Dados Inicial

Variável de Entrada	Elemento residual?	ρ LE (MPa)	ρ LR (MPa)	ρ Alongamento (%)
C	Não	0,214	0,441	-0,144
Mn	Não	0,473	0,48	-0,247
Si	Não	0,184	0,199	-0,145
S	Sim	0,028	0,042	-0,142
Cr	Sim	-0,24	-0,289	0,139
Nb	Não	0,417	0,17	-0,138
N	Sim	0,05	0,217	-0,065
P	Sim	0,035	0,041	0,063
Cu	Sim	0,16	0,213	-0,138
Mo	Sim	0,085	0,257	0,029
V	Sim	0,16	0,275	-0,114
Al _t	Sim	0,167	0,297	-0,073
Sn	Sim	-0,012	-0,132	-0,043
T aba f	-	0,141	0,298	-0,077
% Redução na Largura	-	0,217	0,252	-0,088

2. Avaliação dos coeficientes de correlação, ρ , obtidos para as variáveis de saída LE e LR dentro do conjunto de dados de entrada utilizados:

(a) Estabelecimento do critério de ρ mínimo (em módulo) entre a variável de entrada e as variáveis de saída (somente LE e LR) igual a 0,10 para manutenção da variável em questão no modelo;

(b) Eliminação das variáveis de entrada com coeficiente de correlação inferior a 0,10 para as variáveis de saída LE e LR.

3. Eliminação dos elementos químicos considerados residuais (Ou seja, não adicionados intencionalmente no processo de aciaria).

O Alongamento não foi considerado nesta análise em virtude dos baixos coeficientes de correlação obtidos. Com exceção do manganês todos os demais parâmetros apresentaram o coeficiente de correlação inferior a 0,10.

Com base nestes critérios, as seguintes variáveis foram incluídas no modelo:

- ✓ Composição Química: C, Mn, Si, Cr, Nb. Embora o Cromo seja um elemento químico residual, decidiu-se por manter o mesmo no modelo em virtude dos coeficientes de correlação obtidos para LE e LR, bastante expressivos se comparados aos coeficientes obtidos para os elementos químicos não residuais (Tabela V.2);
- ✓ As variáveis de composição química: N e S, embora sejam elementos químicos residuais e as análises descritas acima indicassem uma influência muito pequena nas propriedades mecânicas, foram mantidas no modelo. Este procedimento tem como objetivo verificar se a simulação das propriedades mecânicas (Item 4.6) para estas duas variáveis é coerente com as análises realizadas no item 5.1 (Análise de Dispersão dos dados de saída em função dos dados de entrada). A escolha dos elementos N e S se baseou no efeito esperado nas propriedades mecânicas conforme item 3.7.1, sub-itens d e f, respectivamente. Neste caso espera-se influência positiva (N) e negativa (S) nas propriedades mecânicas;

- ✓ Variáveis de Processo: Temperatura Final de Laminação, Redução Total no Laminador Tandem. Observa-se que tais variáveis de entrada apresentaram $\rho > 0,15$ com exceção somente da temperatura de aba para o Limite de Escoamento.

As variáveis eliminadas foram:

- ✓ Composição Química: P, Cu, Mo, V, Al e Sn.

5.4 – Avaliação dos Gráficos de Dispersão

Avaliou-se se as mudanças observadas nas variáveis de entrada, item 5.1, resultavam em alterações no Limite de Resistência de acordo com o que se poderia esperar com os aspectos metalúrgicos do processo (ver seção 3.7 da Revisão Bibliográfica). Observou-se uma grande variabilidade e um baixo coeficiente de correlação nos resultados de Limite de Resistência em função de todas as variáveis de entrada utilizadas. Além disto, as análises realizadas indicam que os resultados para LE e A apresentam, em geral, uma dispersão ainda maior e uma menor correlação.

Tal fato pode ser explicado pela origem industrial dos dados utilizados, com inúmeros ruídos de processo os quais podem induzir pequenas alterações entre diferentes campanhas e que levam a mudança significativa de resultados como verificado para o Limite de Resistência, Limite de Escoamento e Alongamento. Além disto, tratando-se de dados industriais, relacionados com a obtenção de produtos comerciais, a variação dos dados de entrada tende a ser relativamente estreita. Estas características dificultam o desenvolvimento de modelos empíricos seja por técnicas de regressão seja pela técnica aqui escolhida (RNA). Liu, Wang e Zao ⁽²¹⁾ observaram problemas similares na previsão das propriedades mecânicas de produtos de aço C-Mn e indicaram como ferramenta de modelamento as Redes Neurais Artificiais pelas razões apresentadas em 3.2.

Discutem-se, a seguir, os gráficos de correlação obtidos somente para as variáveis escolhidas. Neste caso, para o Limite de Resistência (figura 5.2):

a) Influência dos Elementos químicos no Limite de Resistência: Os gráficos da figura 5.2 indicam que um maior teor dos elementos C, Mn, Si, e Nb favorece um aumento do limite de resistência do perfil laminado, tendência que está de acordo com o mostrado na seção 3.7.1. Para estes, o coeficiente de correlação entre o seu teor e o limite de resistência foi superior a 0,10. Para tais elementos as variações observadas estão de acordo com o que seria esperado de dados oriundos de processos industriais. Para o elemento S, não se observou influência significativa no limite de resistência na faixa de teores. Para o elemento N observou-se leve aumento no limite de resistência com o aumento deste, conforme previsto em 3.7.1. Em relação ao elemento Cr observa-se tendência de queda com o aumento em seu teor. Espera-se o contrário, de acordo com o item 3.7.1. Tal fato pode ser explicado pela pequena faixa de variação no teor deste elemento e também pela variação encontrada nos dados de origem industrial;

b) Influência das variáveis de processo no Limite de Resistência: Os gráficos da figura 5.2 evidenciam uma tendência de aumento do Limite de Resistência com o aumento da temperatura final de laminação dentro do intervalo de dados disponível (940 a 1.010°C). Como, considerando os aspectos metalúrgicos do processo, se esperava uma tendência oposta (Seção 3.7.2), acredita-se, entre vários outros aspectos, que a faixa de variação relativamente estreita desta temperatura (70°C) possa ter contribuído para este resultado. Observou-se o mesmo comportamento em outras bitolas com altas temperaturas finais de laminação. Em bitolas com baixas temperaturas finais de laminação (em torno de 750°C) e amostragem na alma (pequenas espessuras) observa-se a relação esperada. Nestes casos as baixas temperaturas acabam por tornar o aço menos dúctil. Observa-se que as bitolas com amostragem na aba apresentam maiores temperaturas finais de laminação. Este fato pode ser explicado pelas maiores espessuras (menor taxa de resfriamento) e ausência de água de refrigeração acumulada na aba, exatamente o oposto do que ocorre com a alma de tais perfis (Os perfis são laminados na posição horizontal, desta maneira há acúmulo de água oriunda dos cilindros de laminação, contribuindo para maior resfriamento desta região). Em relação à influência da Redução na Espessura no limite de resistência verifica-se tendência de aumento com o aumento da redução dentro do pequeno intervalo de dados disponível (84,7 a 86,5%). Conforme explicado anteriormente, em 3.7.2, esta é a tendência esperada. Observa-se coeficiente de

correlação, ρ , igual a 0,25, significativo entre os coeficientes obtidos para as demais variáveis.

5.5 – Resumo do Banco de Dados com Tratamento Estatístico

Após a realização de todos os procedimentos descritos nas seções 4.3 e 5.3 obteve-se um banco de dados com 444 ocorrências. A tabela V.3 resume as informações estatísticas do banco de dados final que será utilizado no modelamento.

Tabela V.3: Resumo Estatístico – Banco de Dados Final

Variável	Descrição	Média	Máximo	Mínimo	Desvio Padrão	3- Sigma	3+ Sigma
Y1	LE (MPa)	416,49	459,97	378,35	15,23	370,82	462,17
Y2	LR (MPa)	507,45	551,99	469,10	15,53	460,85	554,05
Y3	Alongamento (%)	28,94	34,50	23,50	1,88	23,30	34,58
X1	C (%)	0,1051	0,1309	0,0808	0,0090	0,0780	0,1322
X2	Mn (%)	1,3511	1,4540	1,2020	0,0510	1,1981	1,5040
X3	Si (%)	0,2012	0,2500	0,1560	0,0175	0,1486	0,2539
X4	S (%)	0,0073	0,0134	0,0031	0,0023	0,0005	0,0142
X5	Cr (%)	0,0303	0,0470	0,0130	0,0073	0,0084	0,0523
X6	Nb (%)	0,0278	0,0360	0,0200	0,0035	0,0172	0,0384
X7	N ₂ (%)	0,0044	0,0069	0,0019	0,0009	0,0017	0,0071
X8	Temperatura Final de Laminação (TFL) (°C)	972,29	1007,05	939,84	12,37	935,17	1009,40
X9	% Redução na Largura (%)	85,58	86,49	84,73	0,31	84,65	86,52

5.6 – Ajuste da Rede Neural Artificial

Foi utilizada uma arquitetura de RNA com duas camadas (Uma camada oculta e uma camada de saída). O número ótimo de neurônios na camada oculta foi definido a partir do método de tentativa e erro, sendo que foram testadas configurações com no mínimo 4 neurônios. A camada de saída foi construída para apenas um neurônio. Foram desenvolvidas três redes, uma para cada variável de saída (Limite de Resistência, Limite de Escoamento e Alongamento).

Como explicado anteriormente, as variáveis escolhidas foram:

- ✓ Composição Química: C, Mn, Si, S, Cr, Nb, N;
- ✓ Variáveis de Processo: Temperatura Final de Laminação, Redução total no Laminador Tandem.

Após a escolha e definição do banco de dados iniciou-se o processo de ajuste das RNA's com o objetivo de se obter a melhor configuração, ou seja, o número ótimo de neurônios na camada de entrada. Foi observado durante o processo de treinamento que as simulações poderiam apresentar desempenhos diferentes para uma mesma configuração de rede. Uma explicação para este fato seria a existência de dados contaminados no conjunto de amostras e, como eles são selecionados aleatoriamente, dependendo da distribuição, os impactos seriam percebidos na fase de treinamento ou na fase de validação. Uma outra explicação seria a escolha aleatória dos pesos iniciais o que levaria a resultados diferentes em cada simulação.

A variação observada no treinamento das redes criou dificuldades para se definir o número ótimo de neurônios na camada de entrada. Partiu-se, assim, para uma abordagem estatística onde se realizaram 10 simulações para cada uma das configurações de quantidade de neurônios. Os resultados foram analisados utilizando-se os seguintes parâmetros de desempenho na simulação:

- ✓ Mínimo erro percentual na validação de LE, LR e A;
- ✓ Máximo erro percentual na validação de LE, LR e A;
- ✓ Erro percentual médio na validação de LE, LR e A;
- ✓ Correlação Linear entre LE, LR e A estimado e LE, LR e A medidos.

A definição dos parâmetros de desempenho é mostrada no item 4.6, Os itens seguintes ilustram o processo de treinamento para as variáveis modeladas.

5.6.1 – Ajuste da Rede Neural Artificial para o Limite de Escoamento

As tabelas V.4 a V.8 mostram os resultados do ajuste da RNA para o Limite de Escoamento. Nos gráficos das figuras 5.4, 5.9 e 5.14 têm-se o “Training SSE” o qual significa Soma Quadrática dos Erros durante a fase de treinamento.

Tabela V.4: Rede Neural Artificial com 4 neurônios na camada de entrada, Limite de Escoamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LE's (%)
LE	4	1	300	6,76778	0,02	6,81	2,24	66,4
LE	4	2	173	4,40424	0,01	7,94	2,23	64,4
LE	4	3	152	4,22187	0,03	6,9	2,26	62,9
LE	4	4	188	4,46749	0,06	6,77	2,27	71,1
LE	4	5	358	6,47708	0,09	6,95	2,44	66,1
LE	4	6	119	4,64527	0,04	7,95	1,94	70,2
LE	4	7	153	4,13895	0,11	8,28	2,41	66
LE	4	8	233	4,5037	0,02	6,27	2,2	65,1
LE	4	9	183	5,32274	0	8,19	2,16	58,9
LE	4	10	516	6,75603	0,02	7,71	2,26	66,3
Valores Médios			238	5,17052	0,040	7,38	2,24	65,74

Tabela V.5: Rede Neural Artificial com 5 neurônios na camada de entrada, Limite de Escoamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LE's (%)
LE	5	1	292	3,51519	0,04	11,1	2,41	64,6
LE	5	2	332	6,85118	0,09	6,38	2,26	62,7
LE	5	3	141	4,546	0,01	7,37	2,11	66,5
LE	5	4	345	6,21573	0,03	7,45	2,52	59,9
LE	5	5	230	6,88939	0,02	6,99	2,25	74,1
LE	5	6	312	7,07512	0,03	7,03	2,11	68
LE	5	7	349	6,89272	0	6,9	2,21	65,4
LE	5	8	224	6,7647	0,03	6,81	2,24	66,4
LE	5	9	172	4,50052	0,04	7,53	1,89	72,1
LE	5	10	278	6,95035	0,06	7,29	2,22	68,3
Valores Médios			268	6,02009	0,035	7,49	2,22	66,80

Tabela V.6: Rede Neural Artificial com 6 neurônios na camada de entrada, Limite de Escoamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LE's (%)
LE	6	1	249	6,76006	0,02	7,89	2,21	63
LE	6	2	199	6,72418	0,02	6,83	2,34	68,4
LE	6	3	268	6,7628	0,01	7,47	2,21	65
LE	6	4	288	6,40057	0,06	6,93	2,46	67,9
LE	6	5	220	6,83067	0,04	7,76	2,28	73,6
LE	6	6	273	7,10267	0	6,41	2,1	67,5
LE	6	7	237	6,83084	0,01	7,42	2,25	67,3
LE	6	8	221	6,85724	0,04	6,62	2,24	69,1
LE	6	9	234	7,07672	0,03	7,54	2,14	67,6
LE	6	10	245	6,73148	0,04	7,73	2,34	64,3
Valores Médios			243	6,80772	0,027	7,26	2,26	67,37

Tabela V.7: Rede Neural Artificial com 7 neurônios na camada de entrada, Limite de Escoamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LE's (%)
LE	7	1	214	6,73403	0,05	7,96	2,25	64,3
LE	7	2	146	6,80635	0,02	6,64	2,26	68,1
LE	7	3	255	6,61559	0,13	7,49	2,33	56,7
LE	7	4	157	6,66575	0,12	7,69	2,35	72
LE	7	5	211	6,68442	0,04	6,62	2,37	64,9
LE	7	6	239	7,24405	0,02	6,89	2,01	62,5
LE	7	7	176	6,82726	0,03	7,44	2,22	64,2
LE	7	8	451	3,19372	2,33	14,03	2,33	61,4
LE	7	9	367	6,79177	0,07	6,91	2,23	64,1
LE	7	10	182	6,5349	0,01	7,37	2,33	61,8
Valores Médios			240	6,40978	0,282	7,90	2,27	64,00

Tabela V.8: Rede Neural Artificial com 8 neurônios na camada de entrada, Limite de Escoamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LE's (%)
LE	8	1	152	6,46894	0	7,67	2,4	62,2
LE	8	2	449	6,36765	0,05	7,47	2,38	60,2
LE	8	3	153	6,60209	0,02	6,99	2,32	71,7
LE	8	4	169	6,35292	0,11	7,34	2,55	66,3
LE	8	5	239	6,70276	0	8,16	2,27	60,9
LE	8	6	159	7,00894	0,01	6,23	2,17	69
LE	8	7	161	7,07737	0,05	7,55	2,00	68,7
LE	8	8	165	6,95756	0	6,94	2,23	66,6
LE	8	9	145	6,41306	0,01	7,34	2,49	63,6
LE	8	10	189	6,90673	0,03	8,1	2,26	58,9
Valores Médios			198	6,68580	0,028	7,38	2,31	64,81


Conforme discutido em 4.5.10 realizou-se através do MINITAB uma análise de variância para os resultados obtidos para as 10 simulações realizadas para cada configuração da rede. A partir dos resultados obtidos definiu-se a configuração ideal da rede.

As tabelas V.9 a V.12 mostram o resultado desta análise.

Tabela V.9: Erro Mínimo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	0,499	0,125	1,19	0,327
Error	45	4,707	0,105		
Total	49	5,206			

S = 0,3234 R-Sq = 9,59% R-Sq(adj) = 1,55%




Pooled StDev = 0,3234

Tabela V.10: Erro Máximo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	2,49	0,62	0,41	0,803
Error	45	69,02	1,53		
Total	49	71,51			

S = 1,238 R-Sq = 3,48% R-Sq(adj) = 0,00%



Pooled StDev = 1,238

Tabela V.11: Erro Médio (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	0,0408	0,0102	0,54	0,711
Error	45	0,8580	0,0191		
Total	49	0,8988			

S = 0,1381 R-Sq = 4,54% R-Sq(adj) = 0,00%

Level	N	Mean	StDev	Individual 95% CIs For Mean Based on Pooled StDev
4	10	2,2410	0,1369	(-----*-----)
5	10	2,2220	0,1707	(-----*-----)
6	10	2,2570	0,1047	(-----*-----)
7	10	2,2680	0,1051	(-----*-----)
8	10	2,3070	0,1596	(-----*-----)

-----+-----+-----+-----+-----
2,170 2,240 2,310 2,380

Pooled StDev = 0,1381

Tabela V.12: Correlação entre LE's (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	76,7	19,2	1,32	0,278
Error	45	654,8	14,6		
Total	49	731,5			

S = 3,814 R-Sq = 10,49% R-Sq(adj) = 2,53%

Level	N	Mean	StDev	Individual 95% CIs For Mean Based on Pooled StDev
4	10	65,740	3,442	(-----*-----)
5	10	66,800	4,171	(-----*-----)
6	10	67,370	2,932	(-----*-----)
7	10	64,000	4,067	(-----*-----)
8	10	64,810	4,286	(-----*-----)

-----+-----+-----+-----+-----
62,5 65,0 67,5 70,0

Pooled StDev = 3,814

Na análise de variância para os parâmetros de desempenho Erro Mínimo, Erro Médio, Erro Máximo e Correlação entre LE's obteve-se p-valor superior ao nível de significância adotado, $\alpha = 0,05$. Tal resultado demonstra não haver diferenças significativas entre as médias obtidas para cada configuração testada.

Para o erro mínimo não se observa qualquer diferença significativa dentre as várias configurações utilizadas para a rede, embora a configuração com 7 neurônios apresentasse maior valor médio e maior desvio padrão, se destacando dos demais. Obteve-se resultado análogo para o erro máximo. Já no erro médio observa-se menor

média para a configuração com 5 neurônios embora o desvio padrão neste caso fosse o maior entre todas as configurações. É possível dizer que o valor do erro médio não parece ser significativamente afetado pela utilização de 4 a 8 neurônios uma vez que existe pouca variação para a média e o desvio padrão. Já no caso da Correlação entre LE's obteve-se maior correlação média e menor desvio padrão para a configuração de 6 neurônios. Observa-se neste caso maior diferença de resultados entre as diversas configurações, sendo que a configuração com 7 neurônios apresentou os piores resultados, com menor média e terceiro maior desvio padrão. Desta forma, a melhor configuração obtida foi aquela com 6 neurônios.

Com base nos resultados obtidos, optou-se por definir a configuração da rede a partir apenas do coeficiente de correlação que, entre os parâmetros inicialmente utilizados, apresentou o menor valor de p na análise de variância. Dentro da Análise de Variância para a correlação tem-se que a configuração de seis neurônios apresenta o menor desvio padrão. Desta forma optou-se por esta configuração.

Nas Análises de Variância realizadas (tabela V.9 a tabela V.12) percebe-se que o desvio padrão é considerável em todas as configurações de rede utilizadas para todos os parâmetros de desempenho adotados. Tal fato denota a variabilidade encontrada no processo industrial de laminação onde diversos ruídos (Variação nas temperaturas finais de laminação, variação nas reduções de laminação, etc.) estão presentes levando a uma grande dispersão nos resultados de propriedades mecânicas. Percebe-se que dentro de uma composição química similar (Teores aproximadamente iguais de Carbono, Manganês e Nióbio) tem-se uma variação em torno de 40MPa para o Limite de escoamento. Isto pode ser explicado pela variabilidade dos parâmetros incluídos no modelo e na existência de outros fatores importantes que influenciam nas propriedades mecânicas (Taxa de resfriamento, ajustes do laminador, taxa de redução, tempo de laminação, etc.) e que não estão incluídos neste modelo. Evidentemente um maior controle do processo de laminação trará maior precisão a futuros modelos de previsão de propriedades mecânicas através de RNA's ou qualquer outro método.

5.6.2 – Ajuste da Rede Neural Artificial para o Limite de Resistência

As tabelas V.13 a V.17 mostram os resultados do ajuste da RNA para o Limite de Resistência.

Tabela V.13: Rede Neural Artificial com 4 neurônios na camada de entrada, Limite de Resistência:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LR's (%)
LR	4	1	171	3,93	0,01	5,9	1,78	73,6
LR	4	2	175	3,57873	0,06	6,07	1,66	71,1
LR	4	3	700	3,94195	0,01	7,59	1,64	73,7
LR	4	4	396	3,98625	0,01	5,24	1,62	73,7
LR	4	5	180	3,88842	0,01	5,34	1,63	78,2
LR	4	6	125	3,59274	0,03	6,03	1,68	66,3
LR	4	7	126	3,64397	0,01	6,78	1,79	67,9
LR	4	8	98	3,81907	0,01	6,61	1,75	61,1
LR	4	9	200	4,14754	0,02	5	1,53	71,6
LR	4	10	114	3,79382	0,06	6,52	1,70	75
Valores Médios			229	3,83225	0,023	6,11	1,68	71,22

Tabela V.14: Rede Neural Artificial com 5 neurônios na camada de entrada, Limite de Resistência:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LR's (%)
LR	5	1	167	3,76576	0,07	5,66	1,67	76,2
LR	5	2	262	3,63111	0,01	6,15	1,68	73
LR	5	3	113	3,53652	0,03	5,62	1,56	73,9
LR	5	4	163	3,13808	0,02	6,42	1,8	70,9
LR	5	5	121	3,5045	0,03	6,6	1,69	74,3
LR	5	6	161	3,88061	0	5,85	1,32	79,2
LR	5	7	183	3,62905	0	5,22	1,52	72,5
LR	5	8	174	3,81382	0,04	4,8	1,63	73,8
LR	5	9	700	3,28917	0	6,18	1,64	68,2
LR	5	10	191	3,4154	0,01	5,49	1,55	75,8
Valores Médios			224	3,56040	0,021	5,80	1,61	73,78

Tabela V.15: Rede Neural Artificial com 6 neurônios na camada de entrada, Limite de Resistência:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LR's (%)
LR	6	1	295	3,34946	0,01	7,28	1,52	72,5
LR	6	2	700	3,22993	0,03	6,54	1,48	78,2
LR	6	3	653	3,42404	0,04	5,17	1,49	77,7
LR	6	4	306	3,5043	0	6,01	1,47	76,7
LR	6	5	380	3,442978	0,02	6,13	1,54	74,4
LR	6	6	525	3,27752	0,02	5,28	1,6	77,9
LR	6	7	441	3,27218	0,03	6,08	1,48	74,9
LR	6	8	291	3,61479	0,01	5,54	1,69	72,3
LR	6	9	290	3,41804	0,01	4,86	1,56	73,7
LR	6	10	168	2,94769	0,01	6,8	1,83	72,4
Valores Médios			405	3,34809	0,018	5,97	1,57	75,07

Tabela V.16: Rede Neural Artificial com 7 neurônios na camada de entrada, Limite de Resistência:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LR's (%)
LR	7	1	480	2,60777	0,03	7,39	1,8	67,9
LR	7	2	302	2,93114	0,04	7,24	1,67	66,5
LR	7	3	270	2,93035	0	5,26	1,66	74,1
LR	7	4	415	2,704	0,01	6,04	1,76	71,4
LR	7	5	292	2,80959	0,02	8,32	1,61	76,8
LR	7	6	283	2,54936	0,11	5,05	1,88	69,7
LR	7	7	191	2,63504	0,01	6,13	1,62	74,5
LR	7	8	416	3,0182	0	7,54	1,46	79,9
LR	7	9	462	2,49777	0,01	7,62	1,78	68,6
LR	7	10	450	2,96154	0,02	6,67	1,55	66,4
Valores Médios			356	2,76448	0,025	6,73	1,68	71,58

Tabela V.17: Rede Neural Artificial com 8 neurônios na camada de entrada, Limite de Resistência:


Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre LR's (%)
LR	8	1	657	2,36553	0,04	6,32	1,57	78
LR	8	2	212	2,74076	0,02	8,2	1,71	72,2
LR	8	3	176	5,8123	0	6,83	1,76	69,9
LR	8	4	153	5,91704	0	5,33	1,66	69,8
LR	8	5	700	2,39077	0,01	12,35	1,74	61,6
LR	8	6	134	5,79054	0	5,54	1,8	68,6
LR	8	7	122	5,85091	0,02	5,33	1,7	70,7
LR	8	8	423	2,77969	0,01	8,16	1,59	70,3
LR	8	9	103	5,92651	0,01	5,35	1,81	72,1
LR	8	10	130	5,94714	0,02	5,45	1,72	75,6
Valores Médios			281	4,55212	0,013	6,89	1,71	70,88

Como em 5.6.1, realizou-se análise de variância para os resultados obtidos para LR (tabelas V.18 a V.21):

Tabela V.18: Erro Mínimo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	0,000880	0,000220	0,48	0,748
Error	45	0,020520	0,000456		
Total	49	0,021400			

S = 0,02135 R-Sq = 4,11% R-Sq(adj) = 0,00%




Pooled StDev = 0,02135

Tabela V.19: Erro Máximo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	9,22	2,31	1,51	0,216
Error	45	68,87	1,53		
Total	49	78,09			

S = 1,237 R-Sq = 11,81% R-Sq(adj) = 3,97%




Pooled StDev = 1,237

Tabela V.20: Erro Médio (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	0,1371	0,0343	2,91	0,032
Error	45	0,5304	0,0118		
Total	49	0,6674			

S = 0,1086 R-Sq = 20,54% R-Sq(adj) = 13,47%




Pooled StDev = 0,1086

Tabela V.21: Correlação entre LR's (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	4	133,5	33,4	2,11	0,095
Error	45	711,2	15,8		
Total	49	844,7			

S = 3,975 R-Sq = 15,81% R-Sq(adj) = 8,32%



Pooled StDev = 3,975

Na análise de variância para os parâmetros de desempenho Erro Mínimo, Erro Médio, Erro Máximo e Correlação entre LR's obteve-se p-valor superior ao nível de significância adotado, $\alpha = 0,05$ para o erro mínimo obtido e o erro máximo obtido. Tal resultado demonstra não haver diferenças significativas entre as médias obtidas para cada configuração testada. Já para o erro médio obteve-se p-valor igual a 0,032, menor que α , indicando haver diferenças significativas entre as configurações testadas. No caso da correlação, obteve-se p-valor também acima do nível de significância, igual a 0,095.

Para o erro médio observa-se menor valor para a configuração com 6 neurônios com o desvio padrão próximo do valor máximo obtido dentre todas as configurações. Como já descrito é possível afirmar que o valor do erro médio varia significativamente pela utilização de 4 a 8 neurônios em função do p-valor obtido. Já no caso da Correlação entre LR's obteve-se maior correlação média e menor desvio padrão para a configuração de 6 neurônios. Com estes resultados, foi selecionada, para a modelagem do limite de resistência, a configuração com 6 neurônios.

As mesmas considerações a respeito da variabilidade citadas no item 5.6.1 se aplicam a este caso.

5.6.3 – Ajuste da Rede Neural Artificial para Alongamento

As tabelas V.22 a V.28 mostram os ajustes da RNA para o Alongamento.

Tabela V.22: Rede Neural Artificial com 4 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	4	1	320	8,69016	0,01	26,76	4,8	29,4
A	4	2	399	8,68581	0,05	23,03	4,9	30,8
A	4	3	568	8,76031	0,02	18,89	5,1	50,2
A	4	4	437	8,90019	0,16	27,42	4,6	25,7
A	4	5	700	9,10471	0	16,53	4,57	37,9
A	4	6	405	8,66136	0,01	17,11	5	13,6
A	4	7	443	8,51236	0,04	19,87	5,22	28
A	4	8	386	8,41304	0,13	21,89	5,15	30,5
A	4	9	346	8,58704	0,02	26,83	4,85	37,7
A	4	10	371	8,62281	0,01	26,75	4,88	29,6
Valores Médios			438	8,69378	0,045	22,51	4,91	31,34

Tabela V.23: Rede Neural Artificial com 5 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	5	1	399	9,26734	0,03	18,43	4,44	36,5
A	5	2	429	8,87779	0,09	19,63	4,81	38,6
A	5	3	700	8,77163	0,03	23,72	5,04	34,5
A	5	4	482	8,75645	0,01	18,68	4,97	28,3
A	5	5	349	9,20331	0,04	27,93	5,22	31,1
A	5	6	700	8,73824	0,01	23,97	5,03	26,9
A	5	7	544	8,68126	0,08	15,6	4,54	27,5
A	5	8	508	8,72635	0	16,81	5,12	31,5
A	5	9	389	9,03093	0,02	22,72	4,95	33,5
A	5	10	450	9,01294	0,06	14,77	4,67	37
Valores Médios			495	8,90662	0,037	20,23	4,88	32,54

Tabela V.24: Rede Neural Artificial com 6 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	6	1	699	8,11479	0,01	26,98	5,53	21,9
A	6	2	470	8,0977	0,07	25,28	5,3	25,5
A	6	3	680	8,94158	0,13	23,89	4,71	36,6
A	6	4	697	7,59931	0,05	27,02	5,78	24,5
A	6	5	556	8,78308	0,01	23,54	4,69	29,1
A	6	6	443	9,41292	0,01	18,41	4,17	41,7
A	6	7	700	8,91877	0	26,66	4,66	31,2
A	6	8	700	8,99819	0,01	17,08	4,81	29,6
A	6	9	566	8,95116	0,01	14,31	4,71	35,6
A	6	10	700	8,67523	0,09	19,21	5,19	39,8
Valores Médios			621	8,64927	0,039	22,24	4,96	31,55

Tabela V.25: Rede Neural Artificial com 7 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	7	1	580	8,4822	0,08	19,03	4,99	26,2
A	7	2	700	9,04638	0,02	17,66	4,76	35,4
A	7	3	700	8,37426	0,1	27,58	5,01	31,8
A	7	4	453	8,96094	0,01	13,98	4,74	25,2
A	7	5	700	8,50133	0,06	24,08	5,22	29,4
A	7	6	597	8,80169	0,01	23,41	4,56	27,3
A	7	7	700	8,89075	0,09	25,51	4,66	38,6
A	7	8	700	8,93558	0,02	13,05	5,05	33,9
A	7	9	657	8,25587	0,05	19,99	5,09	34,8
A	7	10	500	8,73231	0,05	18,6	4,81	40,7
Valores Médios			629	8,69813	0,049	20,29	4,89	32,33

Tabela V.26: Rede Neural Artificial com 8 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	8	1	700	9,41274	0,01	18,41	4,17	41,8
A	8	2	588	8,65863	0,1	19,03	5,02	31,6
A	8	3	700	8,48198	0,06	22,57	5,22	36,9
A	8	4	700	8,37318	0,02	21,45	5,12	32,2
A	8	5	552	8,98855	0,01	16,29	4,68	38,2
A	8	6	700	8,66647	0,01	18,95	5,17	40
A	8	7	700	8,32535	0,14	21,51	5,39	35,3
A	8	8	700	8,73209	0,02	18,89	4,99	33,2
A	8	9	700	8,85682	0	19,97	4,76	33,8
A	8	10	625	8,88332	0,03	23,85	4,70	41,5
Valores Médios			667	8,73791	0,040	20,09	4,92	36,45

Tabela V.27: Rede Neural Artificial com 9 neurônios na camada de entrada, Alongamento:

Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	9	1	700	9,38493	0,06	12,82	4,27	34,5
A	9	2	549	8,50816	0,07	18,47	4,45	34,7
A	9	3	700	9,1773	0,06	13,2	4,56	34,6
A	9	4	700	8,2914	0,14	18,89	5,41	33,3
A	9	5	700	9,15184	0,06	22,82	4,35	39,3
A	9	6	452	8,94548	0	22,23	4,73	45,2
A	9	7	590	8,74991	0,01	25,83	4,9	32,2
A	9	8	700	8,66303	0,01	17,89	4,87	38,4
A	9	9	700	8,38917	0,05	17,88	5,23	37,7
A	9	10	700	8,3978	0,06	19,5	5,26	32,6
Valores Médios			649	8,76590	0,052	18,95	4,80	36,25

Tabela V.28: Rede Neural Artificial com 10 neurônios na camada de entrada, Alongamento:


Característica	Número de Neurônios	Simulação	Nº de épocas	Training SSE	Erro Mínimo (%)	Erro Máximo (%)	Erro Médio (%)	Correlação entre A's (%)
A	10	1	700	8,34437	0,03	21,91	5,23	48,5
A	10	2	700	8,8697	0,01	26,33	4,64	30,8
A	10	3	700	9,41268	0,01	18,41	4,17	41,8
A	10	4	561	8,75672	0,09	19,84	4,61	32,7
A	10	5	700	8,77429	0,14	18,2	4,97	24,2
A	10	6	700	8,47999	0,13	21,42	5,13	36,8
A	10	7	700	9,41268	0,01	18,41	4,17	41,8
A	10	8	561	8,75672	0,09	19,84	4,61	32,7
A	10	9	700	8,77429	0,14	18,2	4,97	24,2
A	10	10	700	8,47999	0,13	21,42	5,13	36,8
Valores Médios			672	8,80614	0,078	20,40	4,76	35,03

Neste caso, considerando que o alongamento foi a resposta que, em geral, apresentava uma menor correlação com as variáveis de entrada, decidiu-se utilizar redes com até 10 neurônios na camada de entrada para definir o número ideal de neurônios. As tabelas V.29 a V.32 mostram os resultados da análise de variância.

Tabela V.29: Erro Mínimo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	6	0,01190	0,00198	0,98	0,444
Error	63	0,12696	0,00202		
Total	69	0,13886			

S = 0,04489 R-Sq = 8,57% R-Sq(adj) = 0,00%




Pooled StDev = 0,04489

Tabela V.30: Erro Máximo (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	6	95,4	15,9	1,03	0,416
Error	63	974,7	15,5		
Total	69	1070,0			

S = 3,933 R-Sq = 8,91% R-Sq(adj) = 0,24%




Pooled StDev = 3,933

Tabela V.31: Erro Médio (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	6	0,276	0,046	0,39	0,883
Error	63	7,438	0,118		
Total	69	7,713			

S = 0,3436 R-Sq = 3,57% R-Sq(adj) = 0,00%




Pooled StDev = 0,3436

Tabela V.32: Correlação entre A's (%) versus Número de Neurônios:

Source	DF	SS	MS	F	P
Número de Neurônios	6	292,2	48,7	1,26	0,287
Error	63	2428,3	38,5		
Total	69	2720,5			

S = 6,208 R-Sq = 10,74% R-Sq(adj) = 2,24%



Pooled StDev = 6,208

Na análise de variância obteve-se p-valor superior ao nível de significância adotado, $\alpha = 0,05$, para todos os parâmetros de desempenho. Tal resultado demonstra não haver diferenças significativas entre as médias obtidas para cada configuração testada. Apesar disto, considerando que os resultados das tabelas V.29 a V.32 sugerem uma redução do erro médio e um aumento da correlação com o aumento no número de neurônios, a configuração final adotada foi a com 10 neurônios.

Percebe-se, para o Alongamento, um maior número de épocas do processo de treinamento da RNA, o que ilustra a tentativa do modelo em RNA em obter o melhor ajuste para uma variável de difícil modelamento. O número médio de épocas foi bastante superior ao obtido para LE e LR (672 contra 268 e 405 épocas respectivamente).

Tais fatos demonstram a maior complexidade (Em termos de modelamento) da variável Alongamento. Esta apresenta a maior variabilidade se comparada a LE e LR. O processo de obtenção do alongamento envolve inúmeras fontes de ruídos, tais como seleção dos pontos de amostragem na viga mãe, processo de preparação, presença de defeitos superficiais, forma de medição do alongamento (Podem ocorrer variações devido aos paquímetros utilizados). Tais variações podem ocorrer em menor escala para o LE e o LR, sendo que para o LR utiliza-se leitura direta da carga máxima

(A qual é indicada por um ponteiro móvel que se fixa neste valor) no visor do equipamento utilizado, o que minimiza possíveis erros. Já para o LE o ponto de escoamento lido na escala do equipamento pode variar levemente, o que poderia ocasionar maior erro de leitura se comparado ao LR já que a leitura de LE não possui as mesmas características da leitura de LR. Conclui-se que a melhoria nas condições de seleção de amostras, preparação, leitura dos resultados nos ensaios mecânicos (Possível automação do processo) pode ter um efeito significativo na melhoria de desempenho de qualquer modelo matemático para previsão do alongamento. Os resultados obtidos nas seções 5.6.1 e 5.6.3 comprovam estas afirmações, especialmente os resultados de 5.6.3.

A tabela V.33 mostra o resumo das características das Redes Neurais Artificiais utilizadas neste trabalho:

Tabela V.33: Resumo das Características das Redes Neurais Artificiais:

Característica	Critério	Comando MatLab
Tipo de Perfi Estrutural	W200X46,1	-
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	-	TRAINGD
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

5.7 – Treinamento e Validação

5.7.1 – Limite de Escoamento

A figura 5.4 mostra as curvas de treinamento da RNA durante uma simulação com a função de treinamento Propagação Reversa conforme ajustes mostrados no item 4.5. Tal figura mostra a evolução da Soma Quadrática dos Erros (SSE, Sum of Squared Errors, equação 4.4 da seção 4.5.7) calculada para os dados de treinamento da Rede Neural configurada com 6 neurônios para previsão do Limite de Escoamento. O treinamento utilizou o conjunto de dados de treinamento conforme item 4.5.2.

O gráfico da figura 5.4 mostra o resultado do treinamento, onde a Soma Quadrática dos Erros (Tr-Blue: “Training Error” ou erro de treinamento) é exibida em função do número de épocas de treinamento, ou seja, a evolução da convergência durante o processo de treinamento no Software Matlab.




Figura 5.4: Treinamento da RNA, utilizando o MATLAB, para previsão de LE, número de épocas utilizadas: 200.

Observa-se a rápida convergência da RNA até a estabilização, o que ocorre com 10 épocas. Como não há diminuição na Soma Quadrática dos Erros e o treinamento prosseguiu até a interrupção, considera-se que não houve superajuste da Rede, conforme item 4.5.8, uma vez que se percebe grande queda inicial no erro SSE.

Esta queda é devida unicamente ao aprendizado e não houve nenhuma queda posterior do erro. Neste caso a interrupção do treinamento ocorreu com 200 épocas. Tal interrupção ocorre de acordo com os critérios mostrados no item 4.5.11.

A figura 5.5 compara os valores reais e simulados pelo modelo de 111 amostras (25% do banco de dados original) utilizadas nos testes de validação da RNA.




Figura 5.5: Resultado da Validação da RNA, para previsão de LE.

Os dados estão normalizados, porém o valor máximo é igual a 460MPa, o valor médio igual a 417MPa e o valor mínimo igual a 378MPa de acordo com a tabela V.3. Percebe-se que a Rede simula melhor os valores próximos à média do Limite de Escoamento, não sendo muito precisa na simulação de dados que se afastam muito da média (Maior diferença entre os pontos simulados e medidos). Tal fato é devido ao processo de treinamento ser eficaz nas regiões de maior concentração de dados. Como o histograma da figura 5.6 mostra, a região central (Média dos resultados, em torno de 417MPa) concentra a maior parte das ocorrências. Nas extremidades, devido à ausência de maior quantidade de dados, como em qualquer distribuição normal, o aprendizado não é muito eficaz o que é comprovado pelo maior erro dos dados simulados. Tal fato também foi verificado no trabalho conduzido por Singh ⁽²⁾.




Figura 5.6: Histograma dos valores reais do Limite de Escoamento.

A figura 5.7 mostra a correlação entre Limite de Escoamento medido e Limite de Escoamento estimado. Os pontos desta figura correspondem aos resultados das 111 amostras utilizadas na etapa de validação do modelo. Nesta simulação foi obtida uma correlação linear (ρ) igual a 66,5%. Percebe-se considerável dispersão dos dados ao redor da reta, o que evidencia a variabilidade do processo de laminação.

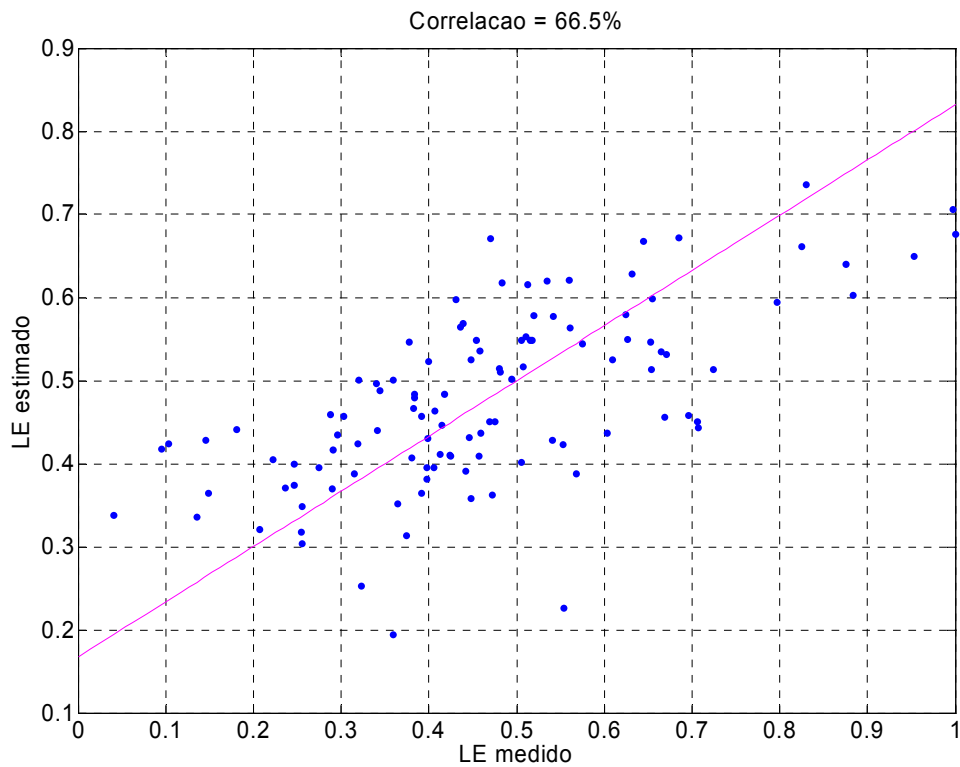


Figura 5.7: Correlação entre LE medido e LE estimado.

A figura 5.8 mostra a variação do erro estimado de LE para cada amostra utilizada no processo de validação da RNA. Conforme comentado anteriormente, os maiores erros estão associados aos dados localizados nas extremidades do histograma do limite de escoamento (Figura 5.6). Estas regiões, por apresentar um menor número de dados, não permitem a mesma eficiência de aprendizado a exemplo da região central do histograma.

Utilizou-se a equação 4.9, seção 4.6, para cálculo do erro, ou erro estimado.

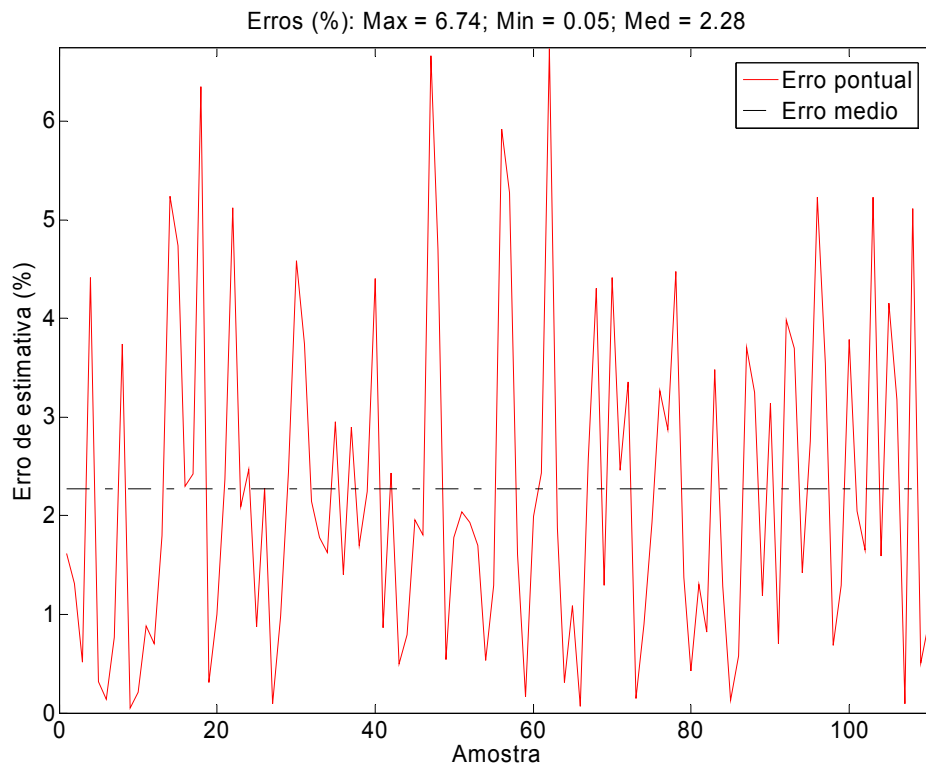


Figura 5.8: Erro de estimativa de LE para cada amostra.

5.7.2 – Limite de Resistência

De maneira similar ao discutido na seção 5.7.1, a figura 5.9 mostra as curvas de treinamento da RNA durante uma simulação com a função de treinamento Propagação Reversa conforme ajustes mostrados no item 4.5.

Tal figura mostra a evolução da Soma Quadrática dos Erros (SSE, Sum of Squared Errors) calculada para os dados de treinamento da Rede Neural configurada com 6 neurônios para previsão do Limite de Resistência.




Figura 5.9: Treinamento da RNA, utilizando o MATLAB, para previsão de LR, número de épocas utilizadas: 222.

Também se observa a convergência gradual e progressiva da RNA até a estabilização, o que ocorre com apenas 6 épocas. As mesmas considerações a respeito do número de épocas de treinamento, interrupção e superajuste discutidas em 5.7.1 se aplicam a este caso.

Para o Limite de Resistência a interrupção do treinamento ocorreu com 222 épocas.

A figura 5.10 compara os valores medidos e modelados do limite de resistência para as 111 amostras utilizadas nos testes de validação da RNA. Os dados estão normalizados, porém o valor máximo é igual a 552,0MPa, o valor médio igual a 507,4MPa e o valor mínimo igual a 469,1MPa de acordo com a tabela V.3.




Figura 5.10: Resultado da Validação da RNA, para previsão de LR.

A figura 5.11 mostra a distribuição dos valores medidos de Limite de Resistência. Como ocorrido para o Limite de Escoamento também se percebe que a Rede simula melhor os valores próximos à média do Limite de Resistência. As mesmas considerações discutidas no item 5.7.1 se aplicam a este caso.




Figura 5.11: Histograma dos valores reais do Limite de Resistência.

Outro resultado avaliado foi a correlação entre os valores medidos e calculados de LR, o qual é mostrado graficamente na figura 5.12. Os dados se referem às 111 amostras usadas na validação da rede. Neste caso foi obtida uma correlação linear (ρ) igual a 69,1%. Este valor foi maior se comparado ao obtido para o Limite de Escoamento. Tal fato pode ser explicado pela menor presença de variáveis presentes no ensaio de tração para determinação do Limite de Resistência, conforme discutido em 5.6.3. A técnica de determinação do LE leva a uma maior incerteza, ou maior variabilidade, na sua determinação, uma vez que a leitura do ponto de escoamento não é automatizada.

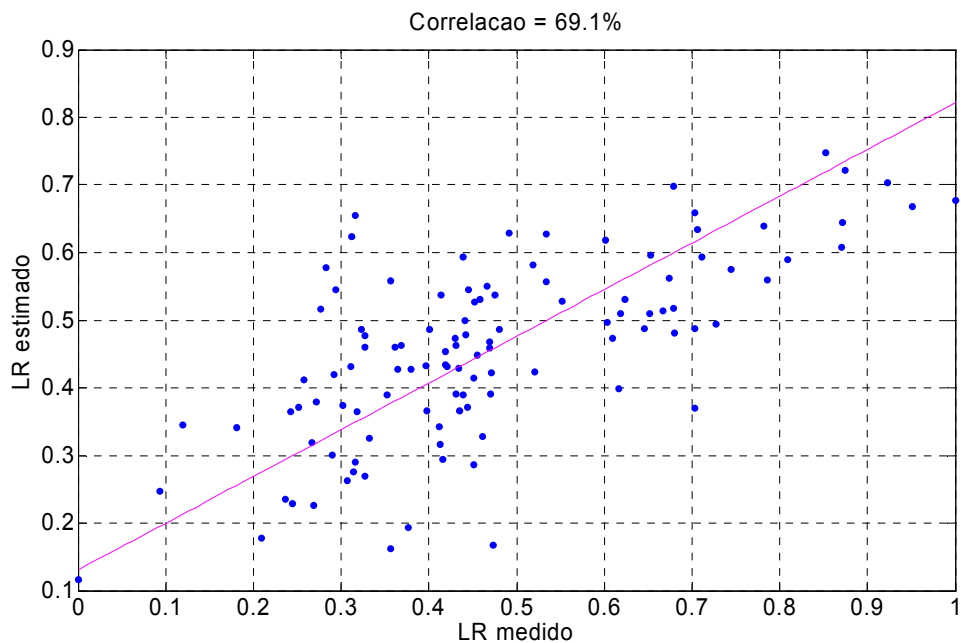


Figura 5.12: Correlação entre LR medido e LR estimado.

A figura 5.13 mostra o erro de estimativa de LR (Equação 4.9) para cada amostra utilizada no processo de validação da RNA. Obteve-se erro máximo igual a 5.68% com erro de estimativa médio igual a 1,82%. Como discutido em 5.7.1 os maiores erros estão associados às extremidades do histograma dos dados.




Figura 5.13: Erro de estimativa de LR para cada amostra.

5.7.3 – Alongamento

A figura 5.14 mostra as curvas de treinamento da RNA durante uma simulação com a função de treinamento Propagação Reversa conforme ajustes mostrados no item 4.5.

Tal figura mostra a evolução da Soma Quadrática dos Erros (SSE, Sum of Squared Errors) calculada para os dados de treinamento da Rede Neural configurada com 10 neurônios para previsão do Limite de Resistência.




Figura 5.14: Treinamento da RNA, utilizando o MATLAB, para previsão de A, número de épocas utilizadas: 700.

Também se observa a convergência gradual e progressiva da RNA até a estabilização, o que ocorre com apenas 6 épocas. As mesmas considerações a respeito do número de épocas de treinamento e superajuste discutidas em 5.7.1 se aplicam a este caso.

Para o Alongamento a interrupção do treinamento ocorreu com 700 épocas. Percebe-se maior número de treinamentos para o Alongamento, conforme discutido no item 5.6.3.

A figura 5.15 ilustra de maneira gráfica os valores de 111 amostras utilizadas nos testes de validação da RNA. Os dados estão normalizados, porém o valor máximo é igual a 34,5%, o valor médio igual a 28,94% e o valor mínimo igual a 23,50% de acordo com a tabela V.3. O resultado para o Alongamento é bem inferior ao conseguido para LE e LR.




Figura 5.15: Resultado da Validação da RNA, para previsão de A.

A figura 5.16 mostra a distribuição dos dados reais de Alongamento. Como ocorrido para o Limite de Escoamento também se percebe que a Rede simula bem os valores próximos à média do Alongamento. As mesmas considerações discutidas no item 5.7.1 se aplicam a este caso, porém observa-se maior dispersão dos dados em torno da média, se comparado a LE e LR, o que pode ser uma das justificativas para a maior diferença entre valores reais e estimados conforme verificado na figura 5.15.




Figura 5.16: Histograma dos valores reais do Alongamento.

Outro resultado obtido é a correlação entre os A's mostrado graficamente na figura 5.17. Neste caso foi obtida uma correlação linear (ρ) igual a 24,9%. Percebe-se considerável dispersão dos dados ao redor da reta, o que evidencia a variabilidade do processo quanto ao alongamento.




Figura 5.17: Correlação entre A medido e A estimado.

A figura 5.18 ilustra o erro de estimativa de A para cada amostra utilizada no processo de validação da RNA. Percebe-se variação acentuada dos erros ao redor do erro de estimativa médio, bem superior ao verificado para LE e LR. Como discutido em 5.7.1 os maiores erros estão associados às extremidades do histograma dos dados.




Figura 5.18: Erro de estimativa de A para cada amostra.

5.8 – Simulação das Propriedades Mecânicas nas faixas de validade

De acordo com o discutido no item 4.6, os itens 5.8.1 a 5.8.3 mostram o processo de simulação das propriedades mecânicas nas faixas de validade do modelo. Espera-se verificar se o modelamento por RNA é coerente com alguns dos aspectos metalúrgicos do processo de laminação obtidos para condições controladas. Serão comparados, também, estes resultados em relação ao comportamento previsto dos dados pelas análises gráficas das seções 5.1.1 a 5.1.3. A interpretação dos resultados da simulação e sua comparação com os aspectos metalúrgicos (Seção 3.7) ocorrerá no item 5.9.

5.8.1 – Limite de Escoamento

As figuras 5.19 a 5.27 apresentam as simulações da variação do Limite de Escoamento para todas as variáveis de entrada da RNA (Variáveis de Processo e

Composição Química) usando os pesos definidos após o treinamento mostrado na figura 5.4. Para cada uma destas simulações alterou-se a variável alvo dentro de seus limites de treinamento (Valores mínimos e máximos) com as demais variáveis sendo mantidas fixas em seus valores médios, conforme tabela V.3.

Com a curva de simulação do Limite de Escoamento também são mostrados nos gráficos todos os resultados reais disponíveis (LE x variável) com o objetivo de se verificar sua distribuição ao longo da faixa de validade destas variáveis. Para se verificar qual a tendência da curva de simulação dentro do espaço de validade do modelo, inseriram-se três retas as quais delimitam o espaço de 2 desvios padrões das amostras. Tal abordagem visou restringir a verificação visual do efeito das variáveis no LE à região central do respectivo Histograma, tal como mostrado na figura 5.6, eliminando assim os pontos situados nas extremidades do Histograma os quais apresentam maior erro de previsão, conforme item 5.7.1.




Figura 5.19: LE em função da Temperatura Final de Laminação (°C).




Figura 5.20: LE em função da Redução (%).




Figura 5.21: LE em função do teor de Carbono (%).




Figura 5.22: LE em função do teor de Manganês (%).




Figura 5.23: LE em função do teor de Silício (%).




Figura 5.24: LE em função do teor de Enxofre (%).




Figura 5.25: LE em função do teor de Cromo (%).




Figura 5.26: LE em função do teor de Nióbio (%).




Figura 5.27: LE em função do teor de Nitrogênio (%).

5.8.2 – Limite de Resistência

As figuras 5.28 a 5.36 apresentam as simulações da variação do Limite de Resistência para todas as variáveis de entrada da RNA (Variáveis de Processo e Composição Química) usando os pesos definidos após o treinamento mostrado na

figura 5.9. Para cada uma destas simulações alterou-se a variável alvo dentro de seus limites de treinamento (Valores mínimos e máximos) com as demais variáveis sendo mantidas fixas em seus valores médios, conforme tabela V.3.

Com a curva de simulação do Limite de Resistência também são mostrados nos gráficos todos os resultados reais disponíveis (LR x variável) com o objetivo de se verificar sua distribuição ao longo da faixa de validade destas variáveis. De maneira semelhante ao realizado para o Limite de Escoamento inseriram-se três retas as quais delimitam o espaço de 2 desvios padrões das amostras. Conforme explicado anteriormente tal abordagem visou restringir a verificação visual do efeito das variáveis no LR à região central do respectivo Histograma, tal como mostrado na figura 5.11, eliminando assim os pontos situados nas extremidades do Histograma os quais apresentam maior erro de previsão, conforme item 5.7.2.




Figura 5.28: LR em função da Temperatura Final de Laminação (°C).




Figura 5.29: LR em função da Redução (%).




Figura 5.30: LR em função do teor de Carbono (%).




Figura 5.31: LR em função do teor de Manganês (%).




Figura 5.32: LR em função do teor de Silício (%).




Figura 5.33: LR em função do teor de Enxofre (%).




Figura 5.34: LR em função do teor de Cromo (%).




Figura 5.35: LR em função do teor de Nióbio (%).




Figura 5.36: LR em função do teor de Nitrogênio (%).

5.8.3 – Alongamento

As figuras 5.37 a 5.45 apresentam as simulações da variação do Alongamento para todas as variáveis de entrada da RNA (Variáveis de Processo e Composição Química) usando os pesos definidos após o treinamento mostrado na figura 5.14. Também se utilizou o procedimento descrito em 5.8.2 para elaboração das curvas.

Com a curva de simulação do Alongamento também são mostrados nos gráficos todos os resultados reais disponíveis (A x variável) com o objetivo de se verificar sua distribuição ao longo da faixa de validade destas variáveis.




Figura 5.37: A em função da Temperatura Final de Laminação (°C).




Figura 5.38: A em função da Redução (%).




Figura 5.39: A em função do teor de Carbono (%).




Figura 5.40: A em função do teor de Manganês (%).




Figura 5.41: A em função do teor de Silício (%).




Figura 5.42: A em função do teor de Enxofre (%).

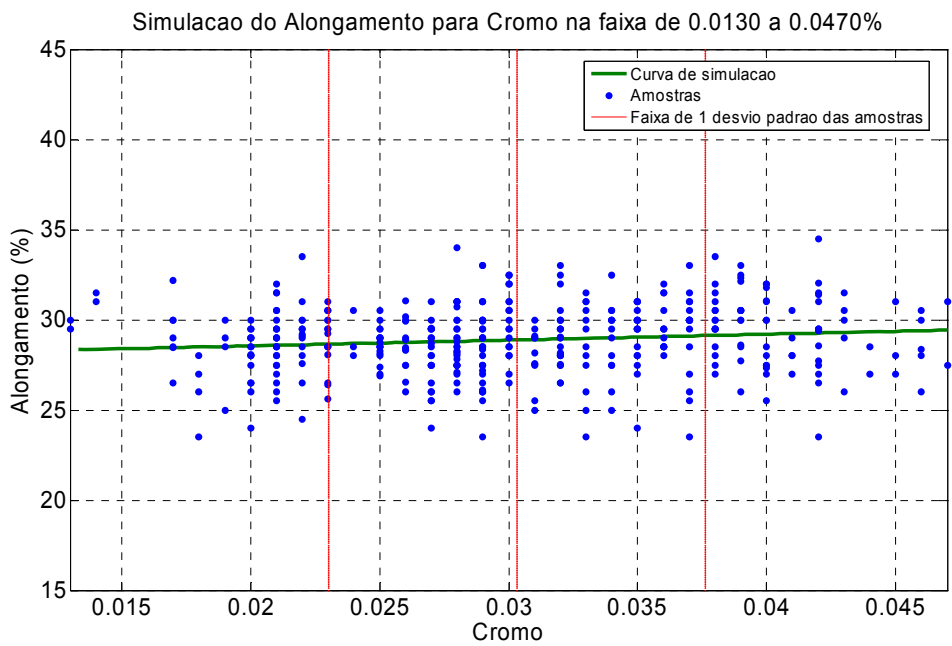


Figura 5.43: A em função do teor de Cromo (%).




Figura 5.44: A em função do teor de Nióbio (%).




Figura 5.45: A em função do teor de Nitrogênio (%).

5.9 – Discussão dos Resultados Obtidos

5.9.1 – Limite de Escoamento

Observa-se que os resultados obtidos na simulação de LE nas faixas de validade para cada variável de entrada foram coerentes com as tendências inicialmente observadas na análise da base de dados disponível, conforme item 5.1.1. No desempenho de previsão da RNA obteve-se um coeficiente de correlação linear (Equação 4.10 na seção 4.6) entre “LE” medido e “LE” estimado igual a 66,5% com erro de estimativa médio igual a 2,28%. A acentuada dispersão verificada é devida em parte à origem industrial dos dados e também pela inevitável presença de regiões onde a quantidade de dados é menor, conforme figura 5.6, o que torna o aprendizado da Rede Neural Artificial menos eficiente em relação à região central do histograma. No trabalho apresentado por Singh ⁽²⁾ percebe-se o mesmo efeito do aumento do erro em regiões onde a concentração de dados é menor, isto é, pontos extremos no histograma de distribuição.

A simulação dos resultados de LE estimados nas faixas de validade do modelo traz alguns pontos importantes:

a) LE em função da Temperatura Final de Laminação (°C): Observa-se pouca variação de LE com o aumento da temperatura. 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 a 1.000°C ⁽³⁹⁾. Aços do tipo ARBL, microligados ao Nióbio, apresentam grande aumento do LE na faixa de temperatura entre 700 e 850°C em função do refino da microestrutura, conforme pode ser visto nas referências (39) e (40). No tipo de processo de laminação avaliado, convencional, não é adotada qualquer técnica visando modificação ou obtenção das propriedades mecânicas, tais como na Laminação Controlada ou Termo-Mecânica ⁽³⁴⁾. É pronunciada a dispersão dos resultados estimados com a variação da temperatura;

b) LE em função da Redução (%): Embora a faixa de variação da Redução seja pequena (De 85,6% a 86,49%), obteve-se uma variação que segue o esperado

conforme a revisão bibliográfica ⁽⁴⁰⁾. Ou seja, quanto maior a redução total maior o Limite de Escoamento obtido já que o tamanho de grão ferrítico final acaba sendo menor. Mais uma vez se observa grande dispersão dos resultados estimados com a variação da redução;

c) LE em função do teor de Carbono (%): A tendência aqui observada é a esperada conforme revisão bibliográfica ^(2, 39). Quanto maior o teor de carbono maior o Limite de Escoamento previsto pelo modelo. Este efeito é bastante pronunciado na faixa de teor de carbono utilizada, entre 0,08 e 0,13%. Observa-se que, pelo modelo, um aumento em 0,01% de Carbono ocasiona aumento de aproximadamente 7MPa ao Limite de Escoamento. Obteve-se um valor semelhante no trabalho apresentado por Singh ⁽²⁾;

d) LE em função do teor de Manganês (%): Mais uma vez, a tendência prevista pelo modelo segue o esperado segundo a literatura consultada ^(2, 39). O Limite de Escoamento aumenta com o aumento do teor de Manganês utilizado. Tal efeito é bastante pronunciado na faixa de teor de Manganês utilizado, entre 1,20 e 1,45%. O aumento de 0,1% no teor de Manganês ocasiona, segundo o modelo, aumento de 10MPa ao Limite de Escoamento. Também se observa acréscimos similares no LE no trabalho apresentado por Singh ⁽²⁾;

e) LE em função do teor de Silício (%): Neste caso também a tendência prevista pelo modelo foi similar à colocada pela literatura ⁽³⁹⁾, isto é, aumento no Limite de Escoamento com o aumento do teor de Silício, porém tem-se um leve aumento (3MPa) para cada 0,1% de adição de Si;

f) LE em função do teor de Enxofre (%): Observa-se leve queda no Limite de Escoamento com o aumento do teor de Enxofre. É bastante acentuada a dispersão dos resultados estimados. Como esperado a influência do Enxofre no Limite de Escoamento é praticamente nula, como já havia sido evidenciado na seção 5.1.1, figura 5.1. Desta forma os resultados obtidos na simulação refletem o comportamento esperado (Seção 3.7.1) e ao constatado na seção 5.1.1;

g) LE em função do teor de Cromo (%): Também se observa leve queda no Limite de Escoamento com o aumento do teor de Cromo. É o contrário do que se espera conforme o relatado pela Literatura ⁽³⁹⁾. Tal fato pode estar ligado à grande variabilidade dos dados de entrada e já havia sido visualizado anteriormente na análise de correlação entre estas duas variáveis a partir do Banco de Dados. Uma outra explicação para este fato pode estar relacionada aos baixos teores típicos para estes produtos, uma vez que não são intencionalmente adicionados (Entre 0,013 e 0,047%, vide seção 5.5). De acordo com Lyakishev e Tulin ⁽³⁹⁾, acréscimos nas propriedades mecânicas podem se conseguidos a custas de adições consideráveis de Cromo, usualmente acima de 1,00%. Nesta faixa de adição o efeito não é visível;

h) LE em função do teor de Nióbio (%): Esta variável tem um efeito bastante pronunciado no Limite de Escoamento, conforme esperado ^(2, 37, 39). Observa-se considerável aumento de LE com o aumento no teor de Nióbio, em torno de 12MPa para cada adição de 0,01% de Nb. Ganhos semelhantes foram visualizados por Singh ⁽²⁾. A faixa de temperatura final de laminação, em torno de 950 a 1000°C não é a ideal para ganhos maiores de propriedades mecânicas. Tal fato denota uma oportunidade de redução de custos do produto laminado, com a utilização das propriedades intrínsecas aos elementos micro-ligantes como ocorre na laminação controlada, onde altos valores de resistência são conseguidos com adições mínimas de elementos de liga, conforme seção 3.7.2;

i) LE em função do teor de Nitrogênio (%): Também se observa leve queda no Limite de Escoamento com o aumento do teor de Nitrogênio. De acordo com a literatura o mesmo exerce um efeito indireto na resistência. A propriedade de aumento de resistência do Nióbio é consequência da separação das fases dispersas de Carbonitreto de Nióbio, Nb (C, N), formados na decomposição da solução sólida supersaturada em uma solução sólida em equilíbrio e partículas dispersas ⁽³⁹⁾. Isoladamente pouco influencia nos resultados finais ⁽³⁸⁾.

Um outro problema relacionado ao processo de determinação do Limite de Escoamento se refere à leitura da escala do Equipamento de Tração que se traduz em

mais uma fonte de variação dos dados, piorando assim o desempenho da RNA. Tal processo não é automatizado, estando sujeito a possíveis erros de interpretação, conforme discutido em 5.6.3.

5.9.2 – Limite de Resistência

Para o Limite de Resistência, os resultados obtidos no processo de simulação nas faixas de validade de cada variável de entrada também foram bastante coerentes com as tendências inicialmente observadas nas análises da base de dados disponível, de acordo com o item 5.1.2. Obteve-se um coeficiente de correlação linear (Equação 4.10 na seção 4.6) entre “LR” medido e “LR” estimado igual a 69,1% com erro de estimativa médio igual a 1,82%. Observa-se que a capacidade de previsão de LR foi significativamente superior ao do modelo para o LE. Tal fato pode estar ligado ao método de obtenção do LR o qual apresenta maior facilidade de leitura da carga máxima no equipamento de tração do que a leitura da carga de escoamento.

A dispersão verificada é devida em parte à origem industrial dos dados e também pela inevitável presença de regiões onde a quantidade de dados é menor, conforme figura 5.11, o que torna o aprendizado da Rede Neural Artificial menos eficiente em relação à região central do histograma. Fato este também verificado em outros trabalhos ⁽²⁾.

A simulação dos resultados de LR estimados nas faixas de validade do modelo 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 final de laminação. Esta tendência é oposta do esperado, ou seja, queda de LR com o aumento da temperatura final de laminação ^(39, 40). Já se havia detectado esta tendência na análise de dispersão realizada em 5.1.2. Verificar considerações do item 5.9.1;

b) LR em função da Redução (%): Observa-se o efeito esperado conforme Bakaloglu ⁽⁴⁰⁾. Tem-se um aumento de 10MPa para cada aumento de um ponto percentual na redução total utilizada. Mais uma vez se observa a grande

dispersão dos resultados estimados com a variação da redução. Dentro do intervalo de dois desvios padrão observa-se a mesma inclinação da curva de simulação tanto para LE quanto para LR. O comportamento é exatamente igual ao mostrado na seção 3.7.2 ⁽⁴⁰⁾. As mesmas considerações a respeito do pequeno intervalo dos dados, item 5.9.1, são válidas para o Limite de Resistência;

c) LR em função do teor de Carbono (%): O comportamento previsto pelo modelo é o esperado considerando as informações da revisão bibliográfica ^(2, 39). O aumento de LR com o aumento no teor de Carbono é bastante pronunciado na faixa de teor de carbono utilizada, entre 0,08 e 0,13%. Observa-se aqui que o aumento em 0,01% de Carbono ocasiona acréscimo de 10MPa no Limite de Resistência, apresentando maior influência se comparado ao observado no Limite de Escoamento. Tal observação é coerente com o estudo realizado na seção 5.1.2. O trabalho de Singh ⁽²⁾ mostra resultados similares;

d) LR em função do teor de Manganês (%): O Limite de Resistência aumenta com o aumento do percentual de Manganês, conforme esperado ⁽³⁹⁾. O aumento de 0,10% no teor de Manganês ocasiona aumento aproximado de 10MPa ao Limite de Resistência, resultado idêntico ao obtido para o Limite de Escoamento e em concordância com o estudo realizado nas seções 5.1.1 e 5.1.2. No trabalho apresentado por Singh ⁽²⁾ observa-se que para maiores teores de Manganês ($\geq 1,00\%$) as curvas de LR e LE são praticamente paralelas, o que replica o resultado obtido neste trabalho;

e) LR em função do teor de Silício (%): Neste caso também temos a tendência esperada, conforme Lyakishev e Tulin ⁽³⁹⁾, aumento no Limite de Resistência com o aumento do teor de Silício. O efeito não é tão pronunciado quanto no caso do Carbono e Manganês, porém tem-se um leve aumento (aproximadamente 5MPa) para cada 0,1% de adição de Si;

f) LR em função do teor de Enxofre (%): Não se observa nenhuma relação entre o Limite de Resistência e o teor de Enxofre. A curva é praticamente linear sem nenhuma inclinação. Como esperado a influência do Enxofre no Limite de

Resistência é praticamente nula, como já havia sido evidenciado na seção 5.1.2, figura 5.2. Desta forma os resultados obtidos na simulação são coerentes com os resultados verificados em 5.1.2 e esperados (item f da Seção 3.7.1);

g) LR em função do teor de Cromo (%): Observa-se leve queda no Limite de Resistência com o aumento do teor de Cromo. É o contrário do que se espera conforme Literatura ⁽³⁹⁾. Vide item (g) em 5.9.1 acerca das possíveis causas deste resultado;

h) LR em função do teor de Nióbio (%): Este elemento químico tem um efeito pronunciado no Limite de Resistência, conforme literatura ^(2, 37, 39). Observa-se aumento de LR com aumento do teor de Nióbio, em torno de 6MPa para cada adição de 0,01% de Nb. Observa-se nas seções 5.1.1 e 5.1.2 o maior efeito do Nióbio no LE do que em LR. As mesmas considerações sobre o uso de processo de laminação controlado, discutido na seção 5.9.1, item h, são válidas para este caso;

i) LR em função do teor de Nitrogênio (%): Observa-se pouco ou quase nenhum aumento no Limite de Resistência com o aumento do teor de Nitrogênio. As observações feitas no item (i) da seção 5.9.1 são aplicáveis na discussão do efeito do Nitrogênio no LR.

5.9.3 – Alongamento

Para o Alongamento os resultados obtidos na simulação de A nas faixas de validade de cada variável de entrada também foram bastante coerentes com as tendências inicialmente observadas nas análises gráficas da base de dados disponível, conforme item 5.1.3. No desempenho de previsão da RNA obteve-se um coeficiente de correlação linear entre “A” medido e “A” estimado igual a 24,9% com erro de estimativa médio igual a 4,97%. Observa-se que os resultados de desempenho de previsão de A foram significativamente inferiores aos de LE e LR. Tal fato pode estar ligado ao método de obtenção do A o qual é bastante influenciado por questões de seleção e preparo de corpos de prova, leitura de dimensões iniciais e finais.

A simulação dos resultados de Alongamento calculados nas faixas de validade do modelo traz alguns pontos importantes:

a) A em função da Temperatura Final de Laminação (°C): Observa-se leve tendência de queda de A com o aumento da temperatura final de laminação. É exatamente o oposto do esperado, ou seja, aumento de A com o aumento da temperatura final de laminação ^(39, 40). Já se havia detectado esta tendência na análise de dispersão realizada em 5.1.3. Verificar considerações em (a) na seção 5.9.1;

b) A em função da Redução (%): Neste caso não se observa o efeito esperado conforme revisão bibliográfica, ou seja, quanto maior a redução total menor o Alongamento obtido já que o tamanho de grão ferrítico final acaba sendo menor, de acordo com Bakaloglu ⁽⁴⁰⁾. A relação entre A e Redução é praticamente plana ao longo da faixa de validade do modelo. Verificar considerações em (b) na seção 5.9.1;

c) A em função do teor de Carbono (%): A tendência aqui observada é a esperada conforme revisão bibliográfica ^(2, 39). Quanto maior o teor de carbono menor o Alongamento. Este efeito é pouco pronunciado na faixa de teor de carbono utilizada, entre 0,08 e 0,13%. Observa-se aqui que o aumento em 0,01% de Carbono ocasiona leve queda, de aproximadamente 1,00%, ao Alongamento;

d) A em função do teor de Manganês (%): O Alongamento diminui com o aumento do percentual de Manganês utilizado, sendo a tendência esperada conforme revisão bibliográfica ^(2, 39). Tal efeito é pouco pronunciado na faixa de teor de Manganês utilizado, entre 1,20 e 1,45%. O aumento de 0,10% no teor de Manganês ocasiona queda aproximada de 2,0% ao Alongamento. Observa-se grande dispersão dos resultados estimados com a variação do teor de Manganês;

e) A em função do teor de Silício (%): Neste caso também temos a tendência esperada, ou seja, queda no Alongamento com o aumento do teor de Silício, de

acordo com Lyakishev e Tulin ⁽³⁹⁾. O efeito é pouco pronunciado se comparado ao anteriormente verificado com LE e LR;

f) A em função do teor de Enxofre (%): Não se observa praticamente nenhuma relação entre o Alongamento e o teor de Enxofre. Comportamento coerente com a literatura (Seção 3.7.1). A curva é praticamente linear sem nenhuma inclinação. É bastante acentuada a dispersão dos resultados estimados;

g) A em função do teor de Cromo (%): Observa-se leve aumento no Alongamento com o aumento do teor de Cromo. É o contrário do que se espera conforme Literatura ⁽³⁹⁾. Vide item (g) em 5.9.1 acerca das possíveis causas deste fato;

h) A em função do teor de Nióbio (%): Observa-se leve queda do Alongamento com o aumento do teor de Nióbio, conforme se espera a partir da Literatura ^(2, 37, 39). Um acréscimo de 0,01% no teor de Nb implica em queda de 1,00% no alongamento. É pronunciada a dispersão dos resultados estimados com a variação da temperatura;

i) A em função do teor de Nitrogênio (%): Não se observa nenhuma relação entre o Alongamento e o teor de Nitrogênio. Vide considerações na seção (i) em 5.9.1.

5.10 – Modelamento em Regressão Múltipla Linear

Conforme citado no item 4.7 seguem os resultados obtidos no modelamento utilizando a técnica de Regressão Múltipla Linear.

5.10.1 - Limite de Escoamento

Os coeficientes da equação de regressão, seus efeitos sobre a variável estudada (LE) e a estatística da regressão são mostrados na tabela V.34.

Tabela V.34: Coeficientes da Equação Linear, Efeitos sobre LE e Estatística de Regressão:

Limite de Escoamento	Coeficientes	p-valor	Efeito no LE	Estatística de regressão	
Interseção	-503,63	0,002	-	R múltiplo	0,65
C	299,96	0,000	Positivo	R-Quadrado	0,42
Mn	92,58	0,000	Positivo	R-quadrado ajustado	0,41
Si	18,53	0,602	Positivo	Erro padrão	11,71
S	-368,67	0,150	Negativo	Observações	444
Cr	-301,81	0,000	Negativo		
Nb	1587,97	0,000	Positivo		
N	-654,93	0,364	Negativo		
T aba f	0,14	0,005	Positivo		
% Redução na Largura	6,99	0,000	Positivo		

Neste caso a equação gerada foi:

$$LE (MPa) = - 504 + 300 C + 92,6 Mn + 18,5 Si - 369 S - 302 Cr + 1588 Nb - 655 N + 0,136 T aba f + 6,99 \% Redução na Largura \quad (5.1)$$

O p-valor calculado mostra se a variável de entrada é estatisticamente significativa ou não para o modelo. Caso seja menor que o nível de significância utilizado ($\alpha = 0,05$) considera-se que a variável é significativa para o modelo. Caso seja maior é estatisticamente não significativa.

Para LE e considerando o critério acima, verifica-se que as variáveis de entrada Si, S e N não podem ser consideradas como significativas uma vez que os p-valores obtidos estiveram acima do nível de significância adotado. Tais resultados são coerentes com os resultados obtidos na seção 5.9.1.

Embora algumas das variáveis de entrada não fossem estatisticamente significativas (Si, S e N) decidiu-se manter as mesmas variáveis no modelo de Regressão Múltipla Linear de modo a permitir a comparação com os resultados obtidos com a técnica de modelamento por Redes Neurais Artificiais em igualdade de condições. Este procedimento foi adotado também para o LR e A.

5.10.2 - Limite de Resistência

Os coeficientes da equação de regressão, seus efeitos sobre a variável estudada (LR) e a estatística da regressão são mostrados na tabela V.35.

Tabela V.35: Coeficientes da Equação Linear, Efeitos sobre LR e Estatística de Regressão:

Limite de Resistência	Coeficientes	p-valor	Efeito no LR	Estatística de regressão	
Interseção	-870,69	0,000	-	R múltiplo	0,71
C	648,63	0,000	Positivo	R-Quadrado	0,50
Mn	87,37	0,000	Positivo	R-quadrado ajustado	0,49
Si	79,55	0,018	Positivo	Erro padrão	11,08
S	-199,24	0,410	Negativo	Observações	444
Cr	-174,54	0,028	Negativo		
Nb	649,41	0,000	Positivo		
N	307,46	0,652	Positivo		
T aba f	0,33	0,000	Positivo		
% Redução na Largura	9,84	0,000	Positivo		

Neste caso a equação gerada foi:

$$LR (MPa) = - 871 + 649 C + 87,4 Mn + 79,5 Si - 199 S - 175 Cr + 649 Nb + 307 N + 0,330 T aba f + 9,84 \% Redução na Largura \quad (5.2)$$

Observa-se que a influência das variáveis de entrada no LR são as mesmas obtidas no modelamento por RNA.

O p-valor obtido mostra que as variáveis S e N não são estatisticamente significativas para o modelo. O impacto nas propriedades mecânicas são coerentes com os resultados obtidos com o modelamento por RNA, conforme pode ser verificado em 5.9.2.

5.10.3 - Alongamento

Os coeficientes da equação de regressão, seus efeitos sobre a variável estudada (A) e a estatística da regressão são mostrados na tabela V.36.

Tabela V.36: Coeficientes da Equação Linear, Efeitos sobre A e Estatística de Regressão:

Alongamento	Coeficientes	p-valor	Efeito no A	Estatística de regressão	
Interseção	79,17	0,002	-	R múltiplo	0,33
C	-24,65	0,014	Negativo	R-Quadrado	0,11
Mn	-6,22	0,002	Negativo	R-quadrado ajustado	0,09
Si	-5,68	0,297	Negativo	Erro padrão	1,79
S	-96,12	0,014	Negativo	Observações	444
Cr	19,01	0,138	Positivo		
Nb	-43,04	0,126	Negativo		
N	57,49	0,603	Positivo		
T aba f	-0,01	0,432	Negativo		
% Redução na Largura	-0,37	0,198	Negativo		

Neste caso a equação gerada foi:

$$\text{Alongamento (\%)} = 79,2 - 24,7 C - 6,22 Mn - 5,68 Si - 96,1 S + 19,0 Cr - 43,0 Nb + 57 N - 0,00578 T \text{ aba f} - 0,367 \% \text{ Redução na Largura} \quad (5.3)$$

Neste caso o p-valor obtido mostra que as variáveis Si, Cr, Nb, N, T aba f e % Redução na Largura não são estatisticamente significativas para o modelo em Regressão Múltipla. Tal fato re-afirma a extrema dispersão encontradas nos dados reais.

5.11 - Comparação entre os resultados obtidos: RNA x Regressão Múltipla Linear

A tabela V.37 foi construída para comparar o desempenho das duas técnicas de modelamento.

Tabela V.37: Comparação entre os resultados obtidos: RNA x Regressão Múltipla Linear:

	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
Erro máximo (%)	7,77	7,26	6,66	5,97	27,00	20,40

O método de cálculo do coeficiente de correlação linear (Coeficiente de Pearson) é o mesmo tanto para o MatLab, quanto para o MINITAB (Ver seção 4.6).

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.

De acordo com o discutido na seção 3.2, as RNA's tendem a apresentar uma maior habilidade no tratamento de dados com incertezas e erros de medida. Tal fato é comprovado pelo melhor ajuste (Maior coeficiente de correlação e menores erros médios) obtido a partir do modelamento feito em RNA em comparação com o ajuste feito no modelamento por Regressão Múltipla Linear.

No trabalho conduzido por Jones ⁽¹⁾, observam-se resultados semelhantes aos obtidos no presente trabalho. Os resultados dos coeficientes de correlação e desvios (erros) obtidos com a técnica de Redes Neurais Artificiais foram superiores aos obtidos com a técnica de Regressão Múltipla Linear.

Em relação à qualidade dos dados de propriedades mecânicas, Jones ⁽¹⁾ observa que melhorias devem ser realizadas visando sua melhoria além de redução na variabilidade existente. Deste modo quanto melhor a qualidade dos dados utilizados, melhor a capacidade de previsão de qualquer técnica de modelamento.

CAPITULO 6 – CONCLUSÕES

Três modelos em Redes Neurais Artificiais, capazes de prever as Propriedades Mecânicas (Limite de escoamento, Limite de Resistência e Alongamento), como função da Composição Química e parâmetros de processo de laminação, foram treinados e testados. Os modelos se mostraram consistentes com as tendências metalúrgicas estabelecidas na 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. No caso do LR a eficiência desta técnica foi bastante clara. Para o LE e o A, cujos dados apresentavam um maior erro, os resultados foram menos evidentes.

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.

Foi possível verificar a influência das variáveis de entrada nos resultados finais. As tendências foram as mesmas verificadas nas análises de regressão realizadas, o que mostra que as Redes Neurais Artificiais retrataram de forma fiel as tendências verificadas nos dados reais, além de refletir algumas das tendências metalúrgicas esperadas.

Constatou-se, para as condições trabalhadas, uma baixa influência da Temperatura Final de Laminação (TFL) nas Propriedades Mecânicas dos Perfis Estruturais Laminados a Quente.

Como limitações importantes para o maior sucesso este trabalho verificou-se:

a) Qualidade do Banco de Dados utilizado: A origem industrial dos dados ocasiona elevada dispersão dos dados em relação ao seu intervalo de variação com baixas correlações entre as variáveis de entrada e de saída. O modelo obtido para o Alongamento teve um desempenho muito inferior aos outros dois. Para os demais modelos (Limite de Escoamento e Limite de Resistência) obteve-se maior sucesso em função dos menores ruídos presentes para sua determinação;

b) O banco de dados atualmente disponível, embora armazene uma grande quantidade de variáveis, não traz ainda algumas de grande importância para a compreensão do problema tais como, por exemplo:

- ✓ Temperatura de reaquecimento dos blocos;
- ✓ Tempo de processo de laminação;
- ✓ Parâmetros de Laminação, incluindo os ajustes passe a passe de laminação, eventual atraso durante o processo de laminação e tempo gasto durante cada passe de laminação;
- ✓ Taxa de resfriamento ($^{\circ}\text{C}/\text{s}$).

c) Quantidade de dados disponíveis: Em função de oferta comercial e tempo de operação da linha de laminação estudada, não se possui um banco com maior número de dados para cada uma das bitolas passíveis de laminação. A bitola escolhida, W200X46,1, por ser bastante produzida foi escolhida, entretanto o número de ocorrências foi abaixo de 500.

De uma forma geral, os resultados obtidos indicam, em concordância com diversos trabalhos disponíveis na literatura, que as Redes Neurais Artificiais podem modelar vários aspectos dos processos siderúrgicos, mesmo com o grau de complexidade e variabilidade significativa de seus resultados.

CAPITULO 7 – ETAPAS FUTURAS

7.1 – Projeto Green Belt

Em paralelo com este projeto de Dissertação de Mestrado é conduzido um projeto intitulado “*Seis Sigma – Green Belt: Redução no Percentual Fora de Faixa de Limite de Escoamento dos Perfis Estruturais Laminados*” conduzido por este autor em conjunto com a consultoria do INDG (Instituto de Desenvolvimento Gerencial) cujo foco é a minimização da variabilidade atualmente encontrada nas Propriedades Mecânicas.

O problema da variabilidade é altamente relevante, pois implica na possibilidade de redução de custos com Ferro-Ligas, minimizando assim o custo final do produto laminado o que aumenta a margem de lucro.

No cenário futuro vislumbra-se significativo aumento de produção dos Perfis Laminados o que acarreta em grandes possibilidades de redução de custos.

7.2 – Aprimoramento do Modelo a partir da inclusão de novas variáveis

Uma das premissas do Projeto Seis Sigma Green Belt é o conhecimento estatístico das diversas variáveis envolvidas na evolução das propriedades mecânicas do aço estrutural. Para tanto é prevista melhorias no banco de dados com a inclusão de mais variáveis de processo.

Prevê-se a expansão do banco de dados com a inclusão das variáveis presentes na tabela VII.1:

Tabela VII.1: Novas variáveis a serem utilizadas no futuro Banco de Dados

Variável
Temperatura das zonas do forno
Ajuste do Laminador por passe (mm)
Composição química do bloco (%)
Dimensões do bloco ou Beam Blank (mm)
Escala de passe
Redução Total (Esboço/Produto final) (%)
Taxa de redução (s ⁻¹)
Taxa de Resfriamento após laminação (°C/s)
Temperatura de Saída do perfil (°C)
Temperaturas de Entrada (°C)
Tempo de deslocamento do BD1 até BD2 (s)
Tempo de deslocamento do BD2 até o Tandem (s)
Tempo de deslocamento do forno até BD1 (s)
Tempo de percurso em cada zona
Tempo de Permanência (s)
Tempo morto (s)
Tipo de material (dimensão teórica) (mm)
Velocidade de laminação (m/s)
Volume de água utilizada no resfriamento dos cilindros (m ³ /s);

Com a inclusão das novas variáveis e minimização da variabilidade de processos será possível a melhoria e complementação do Modelo de Previsão de Propriedades Mecânicas baseado em Redes Neurais. Os benefícios advindos deste modelo estão ligados à redução de custos, otimização de processos e maior conhecimento do processo de laminação.

7.3 – Implantação da Rede Neural Artificial em Sistema

Fora do escopo do presente trabalho, mas como uma continuação deste e ainda diretamente ligada a ele, deverão ser cumpridas a seguintes etapas:

7.3.1 - Implementação do Sistema Simulador

Trata-se da implementação das RNA's obtidas em sistema computacional especialmente desenvolvido visando o gerenciamento eficiente dos dados calculados. Cita-se o trabalho realizado por Dobrzanski ⁽²³⁾ o qual consiste de um sistema com quatro módulos principais:

- ✓ Motor do Modelo (*Model Engine*): Gerenciamento dos parâmetros, aquisição dos resultados calculados pelo modelo e preparação dos dados para processamento posterior;
- ✓ Pacote de Teste (*Test Package*): A ferramenta que torna possível a avaliação dos resultados calculados pelo Motor do Modelo;
- ✓ Ferramenta de Algoritmo Genético (*Genetic Algorithm Tool*): Ferramenta suporte para seleção dos parâmetros e otimização das propriedades obtidas dos produtos em aço;
- ✓ Interface do Usuário (*User Interface*): Interface gráfica dos resultados calculados a qual torna possível a apresentação de gráficos 2D (Duas dimensões) e 3D (Três dimensões) bem como a seleção arbitrária dos parâmetros de entrada. A interface gráfica é mostrada na figura 7.1.




Figura 7.1: Telas de exemplo mostrando a resposta do Modelo em gráficos 2D e 3D

O sistema é controlado interativamente (O usuário especifica os valores dos parâmetros de entrada) ou automaticamente, quando os dados necessários para operação do sistema são adquiridos do banco de dados contendo os resultados reais de testes. O sistema processa todos os resultados de análise em tempo real, o que significa que cada mudança em um parâmetro de entrada implica reação imediata do modelo a qual pode ser observada nos gráficos. Os requerimentos de projeto do Sistema foram focados na facilidade e flexibilidade de uso. Isto significa que o usuário sempre possui informação plena sobre a situação do sistema ⁽²³⁾.

A interface do usuário torna a mudança das variáveis de entrada possível, bem como a observação dos resultados dos cálculos da RNA em função de mudanças em qualquer um dos parâmetros de entrada (Gráficos em duas dimensões) ou quaisquer dois dos parâmetros de entrada (Gráficos em três dimensões) ⁽²³⁾.

Os resultados calculados pelo modelo podem ser utilizados para inúmeras análises das propriedades dos aços para várias combinações dos parâmetros de entrada. O exemplo mostrado na figura 7.2 é um exemplo da saída do Sistema onde as propriedades mecânicas (LE e LR) são mostradas como função de dois parâmetros arbitrários⁽²³⁾.

Este Sistema foi concebido no ambiente de programação Microsoft Visual Studio.NET 2002.

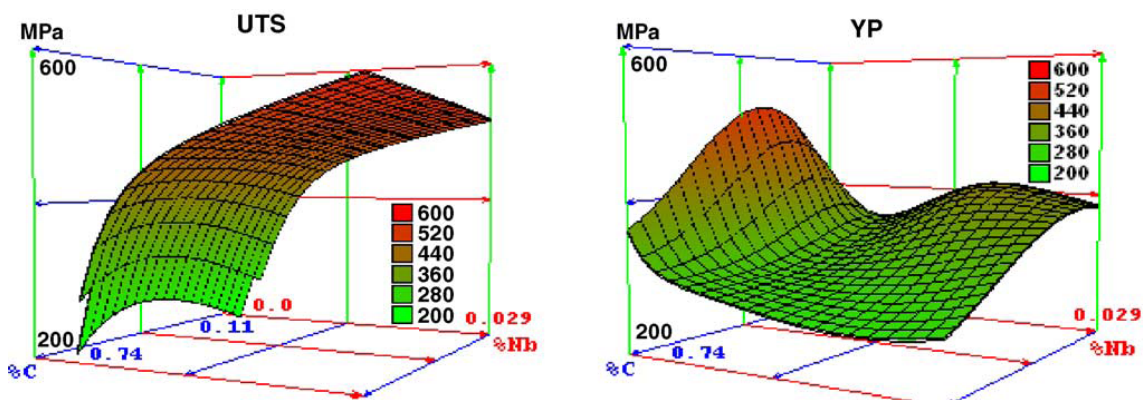


Figura 7.2: Resultado calculados de LR (UTS) e LE (YP) em função da concentração de Níobio e Carbono

A ferramenta para otimização automática dos parâmetros de entrada para obtenção das propriedades requeridas do aço é uma das características do Sistema. A otimização consiste em se encontrar o conjunto de vetores de entrada, para os quais LE e LR são calculados, de maneira tal que os valores calculados estão possivelmente próximos aos valores postulados⁽²³⁾. Esta característica torna possível o processo de seleção dos parâmetros que influenciam nas características do produto, tais como LE e LR.

O objetivo final deste trabalho é possuir uma ferramenta de Desenvolvimento que torne possível as simulações em computador, adequada para previsão das propriedades mecânicas em função dos diversos aspectos tecnológicos e composição química do aço.

REFERÊNCIAS BIBLIOGRÁFICAS

(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) 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;

(3) 60º Congresso Anual da Associação Brasileira de Metalurgia e Materiais – ABM, Belo Horizonte, MG, 2005. *Modelamento Matemático da Laminação: De Ficção Científica a Ferramenta para Capacitação Industrial*, Gorni, A. A. 10pp;

(4) Hohfeld, M., Schurmann, B. The Roles of Neural Networks and Fuzzy Logic in Process Optimization. *Siemens Review - R & D Special*, pp 9-13, 1993;

(5) Korczak, P., Dyja H., Labuda E. Using Neural Networks Models for Predicting Mechanical Properties after Plate Rolling Processes. *Journal of Materials Processing Technology*, Poland, vol.80, n.81, p481-486, 1998;

(6) Huamaní, I. L. *Redes Neurais Fuzzy Aplicadas em Identificação e Controle de Sistemas*. Campinas, SP: Faculdade de Engenharia Elétrica e de Computação, Unicamp, 2003, 165p. (Dissertação, Mestrado em Engenharia Elétrica);

(7) Von Zuben, F. J. *Modelos Paramétricos e Não Paramétricos de Redes Neurais Artificiais e Aplicações*. Campinas, SP: Faculdade de Engenharia Elétrica e de Computação, Unicamp, 1993, 244p. (Tese de Doutorado em Engenharia Elétrica);

(8) Tatibana, C. Y., Kaetsu, D. Y. *Uma Introdução às Redes Neurais*, <http://www.din.uem.br/ia/neurais/>, 2002

(9) McCulloch, W. S., Pitts, W. H. A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, n.5, p115-133, 1943;

- (10) Hebb, D. O. *The Organization of Behavior*. New York, Wiley, 1949;
- (11) Rosenblatt, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review Journal*, vol.65, p386-408, 1958;
- (12) Widrow, B., Hoff, M. E. Adaptive Switching Circuits, *IRE (Institute of Radio Engineers) WESCON Convention Record*, New York, vol.4, p96-140, 1960;
- (13) Minsky, M., Papert, S. *Perceptrons: An Introduction to Computational Geometry*. The MIT Press, Cambridge MA, 1969;
- (14) von der Malsburg, C. Self-Organization of Orientation Sensitive Cells in the Striate Cortex. *Kybernetik*, vol.14, n.2, p85-100, 1973;
- (15) Grossberg, S. Adaptive Pattern Classification and Universal Recoding. I. Parallel Development and Coding of Neural Feature Detectors. *Biological Cybernetics*, vol.23, p121-134, 1976;
- (16) Kohonen, T. Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*, vol.43, n.1, p56-69, 1982;
- (17) Hopfield, J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the U.S.A.*, vol.79, p2554-2558, 1982;
- (18) Rumelhart D., McClelland, J. *Parallel Distributed Processing, Explorations in the Microstructure of Cognition*, vol.1, MIT Press, Cambridge, MA, 1986;
- (19) Werbos, P., J. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Harvard University, Cambridge, MA, 1974. (Tese de Doutorado).
- (20) Graupe, D. *Principles of Artificial Neural Networks*; Advanced Series on Circuits and Systems. Singapore: World Scientific Publishing Company, Jul. 1997, 252p, vol.3

- (21) 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
- (22) 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;
- (23) Dobrzanski, 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;
- (24) 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;
- (25) I.A. Basheer, M. Hajmeer. Artificial Neural Networks: Fundamentals, Computing, Design and Application, *Journal of Microbiological Methods*, vol.43, p3-31, 2000;
- (26) 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;
- (27) Dyja H., Korczak P. Application of the Thermal-Mechanical-Microestructural 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;
- (28) Aguirre, L. A., Corrêa, M. V. Identificação não Linear Caixa Cinza: Uma revisão e novos resultados. *SBA Controle e Automação*, Campinas, Vol. 15, n. 2, 2004.
- (29) Dobrzanski, L. A., Sitek, W. The Modeling Of Hardenability Using Neural Networks. *Journal of Materials Processing Technology*, v.92, n.93, p8-14, Aug. 1999;

- (30) Dobrzanski, L. A., Sitek, W. Application of a Neural Network in Modeling of Hardenability of Constructional Steels. *Journal of Materials Processing Technology*, vol.78, n.1, p59-66, Jun. 1998;
- (31) Vermeulen, W., van der Zwaag, S., Morris, P., de Weijer, T. Prediction of the Continuous Cooling Transformation Diagram of some selected Steels using Neural Networks. *Steel Research*, v.68, n.2, 1997;
- (32) Kuziak, J., Kuziak, R. Modeling of Microstructure And Mechanical Properties of Steel Using Neural Network. *Journal of Materials Processing Technology*, v.127, p115-121, Mar. 2002;
- (33) Y. Y. Yang, D. A. Linkens, M. Mahfouf, A. J. Rose. Grain Growth Modeling of Continuous Reheating Process: A Neural Network-based Approach. *ISIJ International*, vol. 43, n.7, p1040-1049, 2003;
- (34) American Society for Testig Materials (ASTM), Pennsylvania, USA, 01.04 – 2006; Annual Book of ASTM Standards – Steel: Structural, Reinforcing, Pressure, 772p;
- (35) European Comittee for Standardization (CEN), Brussels, Belgium, *DIN EN 10025-1, 2005*; Hot Rolled Products of Structural Steel, 29p;
- (36) Instituto Argentino de Normalización (IRAM), Buenos Aires, Argentina, *U500-503 de 2003.05.26*; Aceros al Carbono para Uso Estrutural, 18p;
- (37) AMERICAN SOCIETY FOR METALS (ASM), Ohio, USA, 06117G; Alloying: Understanding the Basics, 18p, 2001;
- (38) Gorni A. A.; Cavalcanti, C. G. Efeito dos Elementos de Liga sobre a resistência à deformação a quente de aços ao carbono e microligados. In: 2º Congresso Internacional de Tecnologia Metalúrgica e de Materiais, 1997, São Paulo. www.gorni.eng.br/abm97_gorni.pdf. São Paulo: Associação Brasileira de Metalurgia e de Materiais, Out. 1997;

- (39) 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;
- (40) 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.
- (41) M. Jahazi, B. Egbali. The Influence Of Hot Rolling Parameters On The Microstructure and Mechanical Properties of an Ultra-High Strength Steel. *Journal of Materials Processing Technology*, Vol.103, n.2, p276-279, Jun. 2000.
- (42) Nguyen, D., Widrow, B. Improving the learning speed of two-layer neural networks by choosing initial values of the adaptive weights. In: Proceedings of an IEEE International Joint Conference on Neural Networks, San Diego, CA, 1990, pp. 21–26.
- (43) The MathWorks, Inc. Documentation about Neural Network Toolbox. Disponível em: <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/>. Acesso em Janeiro de 2008.