

ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

EPUSP

CURSO MBA DE SIDERURGIA

PEDRO SEGUNDO DA SILVA VALLIM

**“APLICAÇÃO DE REDE NEURAL AO CÁLCULO DA
TENSÃO DE ESCOAMENTO E DA FORÇA ESPECÍFICA DE
LAMINAÇÃO DE AÇOS C-MN PROCESSADOS EM UM
LAMINADOR DE TIRAS A QUENTE”**

ESP/SO
2008
V244a

**SÃO PAULO
2008**

PEDRO SEGUNDO DA SILVA VALLIM

**“APLICAÇÃO DE REDE NEURAL AO CÁLCULO DA
TENSÃO DE ESCOAMENTO E DA FORÇA ESPECÍFICA DE
LAMINAÇÃO DE AÇOS C-Mn PROCESSADOS EM UM
LAMINADOR DE TIRAS A QUENTE”**

SÃO PAULO

2008

PEDRO SEGUNDO DA SILVA VALLIM

**“APLICAÇÃO DE REDE NEURAL AO CÁLCULO DA
TENSÃO DE ESCOAMENTO E DA FORÇA ESPECÍFICA DE
LAMINAÇÃO DE AÇOS C-Mn PROCESSADOS EM UM
LAMINADOR DE TIRAS A QUENTE”**

**Monografia apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título de
Especialista em Siderurgia.**

**Área de concentração:
Engenharia Metalúrgica de Materiais**

**Orientador:
Professor Dr. Ronald Lesley Plaut**

SÃO PAULO

2008

DEDICATÓRIA

*Dedico esta monografia aos meus
pais, Septimo e Aurélia, e à tia Thereza.*

AGRADECIMENTOS

Aos Deuses, que se nos lançam em tempestades, pelo menos nelas nos acompanham.

À minha esposa e filhos por me levarem a instantes de absoluto lazer e aparente perda de tempo, que sempre alegam e aliviam o meu coração.

Ao Professor Doutor Ronald Lesley Plaut, por ter-me motivado no tema desta monografia. E também por, no passado, com competência, ter-me repassado os rudimentos do processo de laminação, no curso de “*Tópicos Avançados*”, que muito ajudaram a mim, um Engenheiro Mecânico, a trabalhar e sobreviver no ramo.

À COSIPA – Companhia Siderúrgica Paulista, pelo programa formal de desenvolvimento de seu corpo de engenharia, através do curso MBA-USP de Especialização em Siderurgia, e ao apoio dado pela Gerência de Suporte Técnico da Laminação a Quente.

Ao colega Professor Doutor Antônio Augusto Gorni, pelas conversas e sugestões.

À equipe de automação do Laminador de Tiras a Quente, Engenheiros Domingos Sávio e Rogério Ramos, pelo contínuo trabalho de alto nível prestado, particularmente no que diz respeito à implantação de bancos de dados de processo, e por compartilharem comigo a administração dos modelos de controle do laminador.

À praia, onde reaprendi o que é correr!

"Nada deve ser mais simples do que realmente é..."

A.E.

RESUMO

Aplicações de Redes Neurais Artificiais (RNA), também conhecidas como Redes Neurais Adaptativas, usando multicamadas, fluxo de informações direto à frente, algoritmos de treinamento e retro propagação (*MFB*), são realizadas para calcular duas importantes variáveis da laminação de tiras no Laminador de Tiras a Quente (LTQ). Estas variáveis são a tensão de escoamento a quente (TEQ) e a força específica de laminação (FW). Ambas relacionadas ao caso particular da laminação de tiras a quente de aços C-Mn. As principais características associadas à produção de bobinas de aço no LTQ são descritas e conceitos básicos sobre o passe de laminação são apontados. Fundamentos das redes neurais *MFB*, sua metodologia, coleta e seleção de dados, arquitetura, treinamento, desempenho e precisão são destacados, objetivando a avaliação dos valores de TEQ e FW para cada cadeira do LTQ. Como uma premissa deste trabalho, as variáveis de entrada são mantidas em um nível simples, sem qualquer cálculo sofisticado ou recursivo, em termos da obtenção de seus valores. Sob estas condições, modelos simplificados são apresentados para as duas principais variáveis de entrada, respectivamente a temperatura da tira no passe de laminação e o raio achatado dos cilindros de trabalho.

Palavras-Chave: Redes Neurais, Laminação de Tiras a Quente, Tensão de Escoamento a Quente, Força de Laminação a Quente.

ABSTRACT

Applications of Artificial Neural Networks (ANN), also known as Adaptive Neural Networks, using multilayers, feedforward, training and backpropagation algorithms (MFB), are performed to calculate two important variables of strip rolling in the Hot Strip Mill (HSM). These variables are the hot flow stress (HFS) and the specific rolling force (FW). Both are related to the particular case of the hot strip rolling of the C-Mn steels. The main characteristics associated with the steel coil production in the HSM are described and basic concepts about rolling pass are pointed out. Fundamentals of the neural network MFB, its methodology, data collection and selection, net architecture, training, performance and accuracy are highlighted, aiming at the evaluation of the HFS and FW values for each HSM stand. As a premise of this work, the net input variables are kept at a simple level, without any sophisticated or recursive calculations, in terms of the obtainment of their values. Under these conditions, simplified models are presented for the two main input variables, namely the strip temperature in the rolling pass and the flattened working roll radius.

Key- words: Neural Networks, Hot Strip rolling, Low Carbon Steels, Hot Flow Stress, Hot Rolling Force

LISTA DE FIGURAS

3.1	Representação simplificada de um neurônio e da ligação sináptica.	6
3.2	Representação esquemática de um neurônio matemático	8
3.3	Exemplos de funções de transferência ϕ_j , com respectivas funções derivadas primeiras ϕ'_j , quando aplicáveis.	10
3.4	Exemplo de uma cadeia de neurônios interligados em uma RNA, com respectivas conexões e sinais de entrada e saída.	12
3.5	Exemplos de arquitetura de RNA's.	13
3.6	Representação esquemática do erro global instantâneo E como função do parâmetro livre w, e da sua derivada, tangente à curva $E=f(w)$.	17
3.7	Grafo de fluxo sinal de um neurônio (j) da última camada da rede, para análise da retro propagação a partir da camada de saída.	19
3.8	Grafo de fluxo de sinal de um perceptron para análise da retro propagação do ajuste de neurônios de camadas ocultas.	21
3.9	Diagrama descritivo de exemplos de variações de algoritmos aplicáveis a RNA's <i>Backpropagation</i>	26
3.10	Ilustração de curva com excesso de ajuste (<i>overfitting</i>) aos dados da função $Y=f(x)$, representados pelos pequenos círculos.	31
3.11	Ilustração do conceito de parada antecipada do treinamento de uma RNA, em função do desvio de erro médio quadrático do lote de validação.	32
4.1	Fluxo de processo da linha de Laminação de Tiras a Quente. Na parte inferior da figura, processos posteriores, que possuem como matéria-prima a bobina laminada a quente.	37
4.2	Processo de descamação, ou retirada de óxido de ferro (carepa) da placa.	38
4.3	Conceito de redução de espessura.	39
4.4	Laminador R1 da COSIPA, de uma cadeira quádrupla-reversível, com laminador de bordas vertical (<i>Edger Mill</i>) na entrada.	40
4.5	Equipamentos para conservação da temperatura do esboço no processo de transferência desde a zona dos laminadores esboçadores (RM) até a zona do Laminador de Tiras a Quente (LTQ).	40

4.6	Laminador de Tiras a Quente (LTQ) da COSIPA, de 6 cadeiras quádruplas-contínuas.	41
4.7	Exemplo da configuração das cadeiras do LTQ.	42
4.8	Configuração simplificada uma malha de controle dinâmico do LTQ.	43
4.9	Sistema de resfriamento de tiras a quente.	45
4.10	Exemplo de bobinadeira, equipamento que tem por objetivo a formação de bobinas da tira laminada a quente.	46
4.11	Resumo das solicitações de processo na laminação a quente e o seu resultado.	47
4.12	Configuração geométrica simplificada do passe de laminação e parâmetros básicos (reduções, comprimento e ângulo de contato).	48
4.13	Diagrama de aplicação de pressão de laminação, conceito de deslizamento relativo entre cilindro e tira, ponto neutro, e equação de equilíbrio de forças no passe de laminação.	49
4.14	Exemplo de configuração de um modelo de cálculo de <i>set-up</i> do LTQ.	53

6.1	Esquema da seleção das variáveis de entrada (<i>inputs</i>) da RNA de TEQ.	64
6.2	Diagrama de blocos da arquitetura da RNA <i>MFB (Multilayer, Feedforward, Backpropagation)</i> utilizada para previsão da TEQ	67
6.3	Relação entre a temperatura real da tira no passe de laminação (T_{RP}), calculada pelo modelo de <i>set-up (FSU)</i> do LTQ, em função da temperatura estimada a partir do modelo de regressão múltipla (T_{EP}), válida para aços C-Mn	73
6.4	Desvio relativo e dispersão do desvio relativo do modelo do temperatura da tira no passe de laminação estimado pela regressão linear múltipla (T_{EP}), em relação à temperatura real (T_{RP}), válido para aços C-Mn, por cadeira do LTQ.	74
6.5	Relação entre o raio achatado real dos cilindros de trabalho no passe de laminação (R_{ach_R}), calculada pelo modelo de <i>set-up (FSU)</i> do LTQ, em função do raio achatado estimado a partir do modelo de regressão múltipla (R_{ach}), válida para aços C-Mn.	77
6.6	Desvio relativo e dispersão do desvio relativo do modelo do raio achatado estimado pela regressão linear múltipla (R_{ach}), em relação ao raio achatado real dos cilindros de trabalho no passe de laminação (R_{ach_R}), válido para aços C-Mn, por cadeira do LTQ.	78

6.7	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F1 do LTQ.	81
6.8	Desempenho da RNA de TEQ na cadeira F1 do LTQ.	81
6.9	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F1 do LTQ.	82
6.10	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F1 do LTQ.	82
6.11	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F2 do LTQ.	83
6.12	Desempenho da RNA de TEQ na cadeira F2 do LTQ.	83
6.13	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F2 do LTQ.	84
6.14	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F2 do LTQ.	84
6.15	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F3 do LTQ.	85
6.16	Desempenho da RNA de TEQ na cadeira F3 do LTQ.	85
6.17	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ.	86
6.18	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F3 do LTQ.	86
6.19	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F4 do LTQ.	87
6.20	Desempenho da RNA de TEQ na cadeira F4 do LTQ.	87

6.21	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F4 do LTQ.	88
6.22	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F4 do LTQ.	88
6.23	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F5 do LTQ.	89
6.24	Desempenho da RNA de TEQ na cadeira F5 do LTQ.	89
6.25	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F5 do LTQ.	90
6.26	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F5 do LTQ.	90
6.27	Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de <i>set-up</i> , para casos da cadeira F6 do LTQ.	91
6.28	Desempenho da RNA de TEQ na cadeira F6 do LTQ.	91
6.29	Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de <i>set-up</i> , em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F6 do LTQ.	92
6.30	Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F6 do LTQ.	92
6.31	Análise da precisão e ajuste de dados da TEQ_{RNA} , comparada com a TEQ_{SU} e TEQ_{REAL} , por cadeira do LTQ	94

7.1	Esquema da seleção das variáveis de entrada (<i>inputs</i>) da RNA de FW.	98
7.2	Diagrama de blocos da arquitetura da RNA <i>MFB (Multilayer, Feedforward, Backpropagation)</i> utilizada para previsão da FW.	100
7.3	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F1 do LTQ.	104
7.4	Desempenho da RNA de FW na cadeira F1 do LTQ.	104

7.5	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F1 do LTQ.	105
7.6	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F1 do LTQ.	105
7.7	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F2 do LTQ.	106
7.8	Desempenho da RNA de FW na cadeira F2 do LTQ.	106
7.9	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F2 do LTQ.	107
7.10	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F2 do LTQ.	107
7.11	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F3 do LTQ.	108
7.12	Desempenho da RNA de FW na cadeira F3 do LTQ.	108
7.13	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ.	109
7.14	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F3 do LTQ.	109
7.15	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F4 do LTQ.	110
7.16	Desempenho da RNA de FW na cadeira F4 do LTQ.	110
7.17	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F4 do LTQ.	111
7.18	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F4 do LTQ.	111
7.19	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F5 do LTQ.	112
7.20	Desempenho da RNA de FW na cadeira F5 do LTQ.	112

7.21	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F5 do LTQ.	113
7.22	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F5 do LTQ.	113
7.23	Desvio relativo FW_{SU} , pré-calculada pelo modelo de <i>set-up</i> , e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (<i>same-point</i>), para casos da cadeira F6 do LTQ.	114
7.24	Desempenho da RNA de FW na cadeira F6 do LTQ.	114
7.25	Relação de ajuste da FW_{REAL} , medida no topo da tira (<i>same-point</i>), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F6 do LTQ.	115
7.26	Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F6 do LTQ.	115
7.27	Análise da precisão e ajuste de dados da FW_{RNA} , comparada com a FW_{SU} e FW_{REAL} , por cadeira do LTQ.	117

B1	Diagramas de exemplo simples de aplicação do algoritmo de retro propagação	128 a 131
B2	Gráfico de decaimento do erro da rede em função do número de iterações	132
D1	Lay-out da Linha de Tiras a Quente da COSIPA	137
J1	Referência do software utilizado no desenvolvimento das RNA's	194

LISTA DE TABELAS

4.1	Exemplo de matriz de produtos e rota de processamento clássicas da bobina a quente produzida na Laminação de Tiras a Quente.	36
4.2	Lista de variáveis do passe de laminação de tiras a quente e respectivas expressões de cálculo.	50
5.1	Características do mix de bobinas cujos dados foram utilizados na elaboração das RNA's, por classe dimensional, de teor de Carbono Equivalente (CEQ) e de teor de Cromo (Cr).	60
5.2	Valores médios reais de algumas variáveis de processo por cadeira do LTQ, relacionadas às bobinas do mix utilizado para elaboração das RNA's. As variáveis TEQ e FW são <i>targets</i> das RNA's de TEQ e FW.	61
6.1	Resumo estatístico das variáveis da base de dados original que foram selecionadas para alimentação da RNA de TEQ (<i>inputs</i> e <i>targets</i>).	66
6.2	Detalhes da arquitetura e parâmetros da RNA <i>MFB</i> utilizada na previsão da TEQ.	68
6.3	Resumo da quantidade de parâmetros da RNA <i>MFB</i> utilizada na previsão da TEQ.	69
6.4	Resumo da precisão da TEQ_{SU} e TEQ_{RNA} e do ajuste com a TEQ_{REAL} .	93
7.1	Resumo estatístico das variáveis da base de dados original que foram selecionadas para alimentação da RNA de FW (<i>inputs</i> e <i>targets</i>).	99
7.2	Detalhes da arquitetura e parâmetros da RNA <i>MFB</i> utilizada na previsão da FW.	101
7.3	Resumo da quantidade de parâmetros da RNA <i>MFB</i> utilizada na previsão da FW.	102
7.4	Resumo da precisão da FW_{SU} e FW_{RNA} e do ajuste com a FW_{REAL} .	116
D2	Tabela de dados e características da Linha de Tiras a Quente da COSIPA	138

E	Tabelas de Variáveis de Processo da Base de Dados Utilizada	139
F	Resumo Estatístico dos Valores das Variáveis da Base de Dados	142
G	Tabelas de Valores dos Parâmetros do Algoritmo de Treinamento das RNA's de TEQ e FW	144 a 145
H	Tabelas de Parâmetros Livres das RNA's de TEQ (F1 a F6)	146 a 169
I	Tabelas de Parâmetros Livres das RNA's de FW (F1 a F6)	170 a 193

LISTA DE PRINCIPAIS SIGLAS E SÍMBOLOS

η	Taxa de aprendizado no treinamento da rede
θ	Temperatura da tira laminada a quente
μ	Parâmetro escalar multiplicador da matriz identidade no algoritmo de <i>Levenberg-Marquardt</i>
α	Termo de momento para suavização da correção de peso e <i>bias</i> da rede
γ	Coeficiente de ponderação do erro médio quadrático
ε	Redução logarítmica ou verdadeira de espessura no passe de laminação
$\dot{\varepsilon}$	Taxa ou velocidade de deformação
Δb_j	Correção ou ajuste do <i>bias</i> b de um neurônio (j) de uma dada camada da rede
Δh	Redução de espessura absoluta no passe de laminação
v_j	Função soma do neurônio (j)
φ_j	Função de ativação ou transferência do neurônio (j)
δ_j	Gradiente local do neurônio (j) de uma dada camada da rede
Δw_{ji}	Correção ou ajuste do peso w de uma conexão (i) do neurônio (j) de uma dada camada da rede
AGC	<i>Automatic Gage Control</i> = controle automático de espessura da tira
ANN	<i>Artificial Neural Network</i> = Rede Neural Artificial
APC	<i>Automatic Positioning Control</i> = controle automático de posicionamento do gap
ASR	<i>Automatic Speed Regulator</i> = controle automático de velocidade de cilindros
B	Matriz de <i>bias</i> dos neurônios de uma dada camada da rede neural
b_j	<i>Bias</i> do neurônio (j) de uma dada camada da rede
C	Teor de Carbono
C_{ad}	Cadeira do LTQ
CEQ	Teor de carbono equivalente
$C-Mn$	Aço Carbono-Manganês
COSIPA	Companhia Siderúrgica Paulista

CQ	Composição química
Cr	Teor de Cromo
Cu	Teor de Cobre
DFW_{RNA}	Desvio relativo da força específica de laminação calculada pela rede neural em relação à força específica real
DFW_{SU}	Desvio relativo da força específica de laminação calculada pelo modelo de <i>set-up</i> (FSU) em relação à força específica real
d_j	Valor alvo (<i>target</i>) ou visado na saída da rede, relacionada ao neurônio (j) da camada de saída
DP	Desvio padrão
$DTEQ_{RNA}$	Desvio relativo da tensão de escoamento calculada pela rede neural em relação à tensão de escoamento real
$DTEQ_{SU}$	Desvio relativo da tensão de escoamento calculada pelo modelo de <i>set-up</i> (FSU) em relação à tensão de escoamento real
D_{wr}	Diâmetro dos cilindros de trabalho
e_j	Erro instantâneo, na saída do neurônio (j) da camada de saída da rede
Esp	Espessura da tira
Et	Erro global instantâneo na iteração (t) do treinamento da rede neural
E_T	Erro global médio na época (T) de treinamento da rede neural
F	Força de laminação
f	Fator de deslizamento à vante
F_B	Força de bender para flexão de cilindros de trabalho, por mancal
FSU	<i>Finishing Set-Up Calculation</i> = Modelo de Cálculo de <i>Set-Up</i> do LTQ
FW	Força específica de laminação (força / largura)
FW_{RNA}	Força específica de laminação calculada pela rede neural
FW_{SU}	Força específica de laminação calculada pelo modelo de <i>set-up</i> (FSU)
Fx	Cadeira x (x = 1...6) do LTQ
g	Abertura ou <i>gap</i> entre cilindros de trabalho
Gap	Abertura entre cilindros de trabalho para o passe de laminação
GNO	Aço para fins elétrico de grão não orientado, de laminação ferrítica
H	Matriz Hessiana, de derivadas segundas do erro global da rede

h_f	Espessura de saída da tira no passe de laminação
h_i	Espessura de entrada da tira no passe de laminação
<i>HSM</i>	<i>Hot Strip Mill</i> = Laminador de Tiras a Quente
<i>I</i>	Matriz identidade (diagonal com valor de elemento único e igual a 1)
<i>IF</i>	Aço <i>Interstitial Free</i> , de ultra baixo carbono
<i>J</i>	Matriz Jacobiana, de derivadas primeiras do erro instantâneo da rede
<i>L</i>	Comprimento de contato no passe de laminação
<i>Larg</i>	Largura da tira
<i>LPC</i>	<i>Looper Control</i> = controle automático de fluxo de massa pelos <i>loopers</i>
<i>LtQ</i>	Laminador de Tira a Quente
<i>M</i>	Módulo de rigidez da cadeira
<i>MFB</i>	<i>Multilayer, Feedforward, Backpropagation</i> = tipo de rede neural multicamada, de fluxo direto à frente, com treinamento por retro propagação de erro
<i>Mn</i>	Teor de Manganês
<i>MSE</i>	<i>Mean Square Error</i> = erro médio quadrático da rede neural; o mesmo que E_T .
<i>Nb</i>	Teor de Níbio
PCT_{TREIN} <i>O</i>	Partição ou porcentagem de dados destinados a treinamento da rede em relação ao lote composto por lote de dados de treinamento e de validação somados.
<i>Q</i>	Fator de correção da força de laminação
<i>R</i>	Raio dos cilindros de trabalho
<i>r</i>	Redução relativa convencional de espessura no passe de laminação
R_{ach}	Raio achatado (estimado) dos cilindros de trabalho
<i>RNA</i>	Rede Neural Artificial ou Rede Neural Adaptativa
<i>Set-Up</i>	Conjunto de parâmetros de ajuste da cadeira para o passe de laminação, sendo os principais parâmetros o <i>gap</i> e a velocidade de cilindros de trabalho.
<i>Si</i>	Teor de Silício
<i>T</i>	Época de treinamento da rede neural
<i>t</i>	Iteração de treinamento da rede neural

TA	Temperatura da tira na saída do LTQ, medida por pirômetro.
T_{AR3}	Temperatura de início de transformação de fase, austenítica para ferrítica, no caso dos aços C-Mn
TB	Temperatura de bobinamento da tira, medida na saída do sistema de resfriamento de tiras.
TE	Temperatura do esboço na entrada do LTQ, medida por pirômetro
T_{EP}	Temperatura estimada da tira no passe de laminação
TEQ	Tensão de escoamento a quente
TEQ_{RNA}	Tensão de escoamento real, recalculada pelo modelo de <i>set-up</i> (FSU) a partir de dados reais
TEQ_{SU}	Tensão de escoamento calculada pelo modelo de <i>set-up</i> (FSU)
Ti	Teor de Titânio
ULC	Aço de ultra baixo carbono ($C < 0.01\%$)
V	Teor de Vanádio
v_M	Velocidade da tira
v_P	Velocidade periférica dos cilindros de trabalho
W	Matriz de pesos das conexões de entrada dos neurônios de uma dada camada da rede
w_{ji}	peso da conexões de entrada (i) do neurônio (j) de uma dada camada da rede
X	Vetor de dados do caso ou exemplo de entrada na rede neural (<i>input</i>)
x_i	Elemento (i) do vetor de entrada (<i>input</i>) da primeira camada de neurônios da rede.
X_{norm}	Valor normalizado de uma variável de entrada (<i>input</i>) X da rede
Y	Vetor de saída da rede (<i>output</i>)
y_j	Elemento (j) do vetor de saída (<i>output</i>), relacionado ao neurônio (j) da camada de saída da rede
Y_{norm}	Valor normalizado de uma variável de saída (<i>output</i>) Y da rede

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE PRINCIPAIS SIGLAS E SÍMBOLOS

1	Objetivo	1
2	Introdução	2
2.1	Motivação	2
2.2	Organização do texto	3
3	Fundamentos de Redes Neurais Artificiais Aplicadas à Previsão de Variáveis	4
3.1	Introdução	4
3.2	Modelo aproximado de um neurônio biológico	6
3.3	Modelo de um neurônio matemático	7
3.4	Rede Neural Artificial (RNA)	11
3.5	Arquitetura da RNA	13
3.6	Aprendizagem da RNA	14
3.7	Algoritmo de retro propagação (<i>Backpropagation</i>)	15
3.8	Variações do algoritmo de retro propagação	25
3.9	Pré e pós processamento de variáveis da RNA	29
3.10	Generalização da RNA	30
3.11	Limitações e cuidados relativos às RNA's <i>MFB</i>	34
4	Descrição do Processo de Laminação de Tiras a Quente	35
4.1	Fluxo de produtos e processos	35
4.2	Conceitos básicos das principais variáveis do passe de laminação	47
4.3	Considerações sobre modelos de cálculo de <i>set-up</i> do LTQ	52
5	Condições Gerais de Coleta e Seleção de Dados das Variáveis de Processo	55
5.1	Introdução	55
5.2	Coleta e base de dados	55

5.3	Definição da região de coleta de dados na tira laminada a quente	56
5.4	Condições gerais de coleta e seleção dos dados	56
5.5	Lista geral de variáveis de processo da base de dados utilizada	59
5.6	Características do mix de bobinas da base de dados utilizada	59
5.7	Características das variáveis relacionadas com a cadeira do LTQ	61
6	Aplicação de RNA <i>MFB</i> na Determinação da Tensão de Escoamento a Quente (TEQ) na Laminação de Tiras a Quente	62
6.1	Introdução	62
6.2	Seleção das variáveis de entrada e alvo da RNA de TEQ	63
6.3	Arquitetura da RNA de TEQ	66
6.4	Treinamento da RNA de TEQ	69
6.5	Determinação da temperatura da tira no passe de laminação	70
6.6	Determinação do raio achatado do cilindro de trabalho	75
6.7	Resultados obtidos	78
6.8	Discussão dos resultados	93
7	Aplicação de RNA <i>MFB</i> na Determinação da Força Específica (FW) na Laminação de Tiras a Quente	96
7.1	Introdução	96
7.2	Seleção das variáveis de entrada e alvo da RNA de FW	97
7.3	Arquitetura da RNA de FW	99
7.4	Treinamento da RNA de FW	102
7.5	Resultados obtidos	103
7.7	Discussão dos resultados	116
8	Conclusões	119
9	Sugestões para novos trabalhos	121
	REFERÊNCIAS BIBLIOGRÁFICAS	122

APÊNDICES

A	Resumo do Algoritmo de Retro Propagação (<i>Backpropagation</i>)	125
B	Exemplo Simples de Aplicação do Algoritmo de Retro Propagação	128
C	Conceitos Sobre o Algoritmo de Treinamento Levenberg-Marquardt	133
D	Lay-Out e Características da Linha de Tiras a Quente Número 1 da COSIPA	137
E	Tabelas de Variáveis de Processo da Base de Dados Utilizada	139
F	Resumo Estatístico dos Valores das Variáveis da Base de Dados	142
G	Valores dos Parâmetros do Algoritmo de Treinamento das RNA's de TEQ e FW	144
H	Tabelas de Parâmetros Livres das RNA's de TEQ	146
I	Tabelas de Parâmetros Livres das RNA's de FW	170
J	Referência do software utilizado no desenvolvimento das RNA's	194

1 Objetivo

O objetivo central deste trabalho é mostrar duas aplicações distintas de Redes Neurais Artificiais (RNA's), do tipo *Multilayer, Feedforward, Backpropagation (MFB)*, para cálculo da tensão de escoamento na laminação de tiras a quente (TEQ) e da força específica de laminação (FW), de aços planos comuns do tipo C-Mn, redes estas treinadas e validadas a partir de lotes de dados industriais relacionados com a laminação desse tipo de material no Laminador de Tiras a Quente (LTQ) da Companhia Siderúrgica Paulista - COSIPA.

Para tanto, é adotada a estratégia de desenvolvimento de uma RNA de TEQ e FW para as condições correspondentes de cada uma das 6 cadeiras do laminador, num total de 12 redes individuais treinadas.

Adicionalmente objetiva-se utilizar, nas aplicações das RNA's, variáveis de entrada as mais primárias e imediatas, que não exijam modelos de cálculo complexos ou sofisticados para sua informação.

Como objetivos secundários, são ainda mostradas descrições dos fundamentos de redes neurais, com foco nas do tipo *MFB*, e de um resumo do processo de laminação de tiras a quente, para suporte e apoio ao tema central de aplicação das RNA's.

2 Introdução

2.1 Motivação

A motivação para o desenvolvimento de um tema específico decorre da inspiração aliada (ou não) à necessidade de aplicação prática do assunto abordado.

O objetivo sempre perseguido pelos “operadores de LTQ’s” (Laminadores de Tiras a Quente), é a de um processo estável produzindo com qualidade, dentro do cenário de uma atividade altamente competitiva e lucrativa, de produção de bobinas de aço.

A rede neural artificial é uma ferramenta matemática com inspiração no funcionamento do cérebro humano, que vem atender a necessidade de se conseguir uma alternativa viável na abordagem de um problema complexo, como o da laminação.

Muitos são os trabalhos e livros elaborados para cálculo de previsão das variáveis de processo da laminação de tiras a quente. Com base nas teorias desenvolvidas, sistemas de controle automático do ajuste das cadeiras do laminador foram e são largamente empregados.

Entretanto, limitações na obtenção de precisão de resultados dos modelos clássicos, devido à complexidade do entendimento físico e controle do real fenômeno no passe de laminação, aliada à expansão da capacidade de desempenho dos atuais computadores são um terreno fértil para aplicação de redes neurais.

Após anos da clássica abordagem do processo de laminação a quente, a aplicação do método de redes neurais para a previsão de parâmetros de processo nessa área pode ser considerada como sendo uma realidade no controle de laminadores modernos, e não mais um vislumbre do futuro.

Essa realidade traz a motivação para o aumento do entendimento do assunto redes neurais, buscado através da elaboração deste trabalho.

E é claro, do assunto Laminação de Tiras a Quente.

2.2 Organização do texto

Segue-se ao presente capítulo introdutório, o seguinte de número 3 que descreve fundamentos de redes neurais aplicadas à previsão de variáveis de processo, com foco no entendimento básico das RNA's *MFB*. De forma bem menos detalhada, são comentadas algumas variações mais sofisticadas do algoritmo *backpropagation*, entre os quais o de *Levenberg-Marquardt*, este utilizado no treinamento das RNA's desenvolvidas para a TEQ e FW.

O capítulo 4 traz uma descrição do processo de Laminação de Tiras a Quente, mostrando o seu fluxo de produtos e processos, e os seus principais equipamentos e funções dos mesmos. Traz ainda um resumo mínimo da teoria de laminação, de forma a permitir o entendimento básico do processo de conformação no passe de laminação, e noções sobre o funcionamento de um modelo de controle de *set-up* do laminador.

O capítulo 5 descreve as condições de coleta e seleção dos dados utilizados no desenvolvimentos das RNA's, bem como as características das variáveis de laminação e mix de materiais dos casos selecionados.

No capítulo 6 é mostrada a aplicação da RNA ao cálculo da tensão de escoamento a quente (TEQ), descrevendo-se o processo de seleção e a estatística das variáveis de entrada, arquitetura e treinamento da rede. É mostrado também o desenvolvimento dos modelos de estimativa do valor da temperatura de laminação e raio achatado de cilindros, necessários para simplificar a alimentação da rede com esses dados. São apresentados detalhadamente em tabelas e gráficos os resultados da RNA de TEQ, para cada cadeira do laminador. A discussão dos resultados é mostrada no próprio capítulo.

De forma similar, isso é repetido no capítulo 7 com relação à aplicação da RNA ao cálculo da força específica de laminação (FW).

No capítulo 8 são mostradas as conclusões finais obtidas, enquanto sugestões de possíveis desdobramentos para novos desenvolvimentos são apresentadas no capítulo final, de número 9.

No final deste trabalho, ficam disponibilizadas as referências bibliográficas e os apêndices, ambos mencionados ao longo do texto.

3 Fundamentos de Redes Neurais Artificiais Aplicadas à Previsão de Variáveis

3.1 Introdução

As Redes Neurais Artificiais (RNA's), ou Redes Neurais Adaptativas, modelos matemáticos com inspiração nos cérebros humanos, são um sistema de processamento paralelo e distribuído, com unidades de processamento chamadas de neurônios, que armazenam o conhecimento experimental, disponibilizando-o para uso. Para tanto, uma adequada quantidade dados de entrada é utilizada para treinar a rede, em sucessivas etapas, até que a discrepância entre o resultado esperado e o obtido seja satisfatória, para o objetivo visado. Assim, de forma similar ao cérebro humano, o conhecimento é adquirido pela RNA a partir de seu ambiente, através de um processo de aprendizagem, sendo este conhecimento armazenado em parâmetros internos da rede, que participam das conexões entre neurônios.

As RNA's têm sido aplicadas com sucesso na abordagem de variados tipos de problemas como aproximação de funções, predição e controle de variáveis de processos, classificação de padrões, entre outros. Características como as de tratamento de problemas lineares ou não lineares, adaptabilidade e generalização, com mapeamento de entradas e saídas tornam as RNA's atrativas e extremamente práticas.

A maior parte dos problemas reais possui soluções não lineares, de difícil modelagem, devido ao desconhecimento da forma de relação entre variáveis de entrada e saída. A RNA distribui toda essa não linearidade pela sua malha, de forma bem mais simples. Além disso, parâmetros internos a essa malha da RNA, que são pesos e *bias* definidores das entradas de cada nó da rede, possuem grande capacidade de adaptação ao ambiente.

As RNA's são sistemas de análise com estruturas maciçamente paralelas, e que uma vez tendo sido convenientemente ajustadas, passam a ter a habilidade de produzir saídas adequadas para entradas que não estavam presentes no treinamento, desde que tais entradas sejam oriundas do mesmo tipo de população alvo do problema. Esta nada mais é do que a mencionada qualidade de generalização da rede, ou seja, a capacidade de fornecer respostas coerentes a padrões ou casos novos.

Porém uma vantagem das RNA's também pode ser encarada como sendo sua "maldição", caso se adote essa crítica, quando consideramos o seu aspecto de "caixa-preta". Por exemplo, no projeto de uma RNA dedicada à previsão de uma determinada variável de processo, é exigido algum conhecimento do mesmo de forma a se definir a quantidade e tipo de variáveis de entrada e saída, bem como a faixa de validade e aplicabilidade da rede, em função da população alvo do problema. Mas uma vez obtidas precisão e generalização esperadas, fica um tanto quanto indeterminada a explicação do porque a rede chega ao resultado, ou qual a relevância e o significado físico exato de cada parâmetro de sua malha.

Por outro lado, essa "maldição" pode vir a ser também a benesse das RNA's quando é reconhecido que modelos fenomenológicos que formam a base para compreensão dos processos, muitas vezes são multidimensionais e não lineares para atender a complexidade encontrada, sendo geralmente sua construção uma tarefa difícil, de grande demanda de tempo e, apesar disso, incompleta e não raro conduzindo a resultados não suficientemente precisos e confiáveis. Exemplos desse tipo são comuns na indústria, onde pode ainda ocorrer elevado dispêndio financeiro no desenvolvimento desse tipo de modelo, somado às inconveniências já mencionadas.

Assim, técnicas de inteligência artificial como as de RNA's são alternativas viáveis em substituição às abordagens convencionais, ou combinadas a elas para aumentar sua eficiência, por exemplo em etapas de adaptação de previsão de resultados de processos obtidos de modelos clássicos, sejam eles determinísticos e/ou estatísticos, muito comuns na indústria.

Nesse capítulo são mostrados fundamentos de RNA's, porém ressaltando apenas os conceitos fundamentais que conduzem ao tipo específico de RNA aplicada nesse trabalho, ou seja, RNA multicamada, de sentido único à vante ou direto, sem laços internos de realimentação, treinada com retro propagação (*MFB = Multilayer, Feedforward, Backpropagation*) de erro para atualização de parâmetros internos, e destinada ao ajuste de resultados a dados reais, que se constituem nos alvos (*targets*) a serem previstos com máxima precisão pela rede, em sua configuração final. Portanto, não faz parte desse escopo uma descrição detalhada dos vários tipos de RNA's, como por exemplo daquelas aplicadas a classificação de padrões, ou mesmo detalhes das muitas variações das redes *MFB*.

3.2 Modelo aproximado de um neurônio biológico

O cérebro humano possui cerca de 10 bilhões de neurônios, capaz cada um de estabelecer relações com até 10.000 sinapses com outros neurônios. Assim, sendo cada ligação um bit de informação binária, tem-se $10^{10} \times 10^4 = 10^{14}$, ou 100 trilhões de bits de capacidade máxima de memória (LUDWIG, et al, 2007) (CONSIDERAÇÕES, [2000-2005]).

O neurônio que é a unidade básica do cérebro, isoladamente pode ser considerado análogo a uma unidade de processamento, aceita e combina estímulos de vários outros neurônios (muitas entradas), porém possui somente uma saída, como ilustra a Figura 3.1.




Figura 3.1 - Representação simplificada de um neurônio e da ligação sináptica

A intensidade dos estímulos que o neurônio recebe em suas entradas, denominadas dendritos, depende da proximidade física destas entradas com a saída, denominada axônio, de cada um dos neurônios que mandaram os estímulos.

O soma, ou corpo do neurônio é capaz de funções mais complexas do que uma simples adição dos estímulos que recebeu pelos dendritos, porém considera-se um somatório simples como uma aproximação bem razoável.

O axônio sempre aparece na saída do soma e pode ser considerado um dispositivo não-linear de disparo, que produz um pulso elétrico toda vez que o somatório dos sinais dentro do soma atinge certo limiar. O axônio termina num tipo de contato chamado sinapse, que o conecta com o dendrito de outro soma.

A sinapse libera substâncias químicas, chamadas de neurotransmissores, em função do pulso elétrico disparado pelo axônio, sendo que podem ser necessários vários disparos antes que a sinapse libere os neurotransmissores, que por sua vez, fluem através da fenda e das entradas quimicamente ativas dos dendritos (neuroreceptores), que quando abertos, permitem o fluxo de íons que alteram a carga elétrica dos dendritos, criando uma diferença de potencial, que é conduzida ao próximo soma (corpo do neurônio), e assim sucessivamente. O número de entradas abertas no dendrito vai depender da quantidade de neurotransmissores liberados, como também, cada dendrito pode receber estímulos de várias outras sinapses, permitindo que uma maciça interconectividade seja estabelecida. O fluxo de íons das sinapses sobre os dendritos pode ser excitatório ou inibitório, o que corresponde a uma alteração do potencial local do dendrito positiva ou negativamente.

Dessa forma o sistema é essencialmente não linear, com cada neurônio recebendo sinais através de inúmeros dendritos, sinais esses que ponderados poderão ou não seguir adiante, dependendo de sua intensidade. Na passagem por um neurônio, o sinal poderá ser atenuado ou amplificado, em função do dendrito de origem, ao qual está associado um peso, pelo qual o sinal é multiplicado. Esses pesos são estabelecidos por meio de treinamento recebido pelo cérebro durante sua vida útil, o que define o processo de memorização.

3.3 Modelo de um neurônio matemático

Um neurônio artificial, representado na Figura 3.2, é uma aproximação de um neurônio biológico. É a unidade básica de processamento de informação de uma rede neural, que recebe um ou mais sinais de entrada e devolve um único sinal de saída, que pode ser distribuído como sinal de rede, ou como sinal de entrada para um ou vários neurônios de camadas posteriores (HAYKIN,2001).




Figura 3.2 – Representação esquemática de um neurônio matemático (j), com n_j informações de entrada ou sinais (x_{ji}), e *bias* b_j , sobre os quais são aplicados n_j pesos (w_{ji}), função soma (v_j), função de ativação (ϕ_j) e uma informação ou sinal de saída (y_j).

Podem ser destacados os seguintes elementos constituintes desse neurônio (TAKAHASHI, 2006):

- *Sinapses*, que são conexões de entrada do neurônio, caracterizadas por pesos ou forças próprias, nas quais cada sinal de entrada (x_{ji}) é multiplicado por um peso sináptico (w_{ji}), ou seja, é um produto do peso pelo respectivo sinal de entrada ($w_{ji} \cdot x_{ji}$). Convenciona-se que o sinal de ordem $i = 0$, possui valor unitário (1), sendo essa sinapse conhecida pelo nome *bias*, possibilitando que o neurônio apresente saída não nula, mesmo com valores nulos para todas as demais entradas.
- *Função soma*, a qual realiza a adição de cada o valor resultante de cada sinapse, realizando assim a soma ponderada dos sinais de entrada, mais o valor do *bias*, sendo definida por:

$$v_j = \sum_{i=0}^{n_j} (w_{ji} \cdot x_{ji}) = b_j + \sum_{i=1}^{n_j} (w_{ji} \cdot x_{ji}) \quad (3.1)$$

- *Função de ativação* é uma função de transferência que define a restrição da amplitude do sinal de saída do neurônio. O seu resultado numérico equivale ao valor do sinal de saída do neurônio:

$$\varphi_j(v_j) = y_j \quad (3.2)$$

A função de transferência pode ser linear ou não, contínua ou não, conferindo ao neurônio grande potencial como ferramenta de análise de problemas reais. São vários os tipos de função utilizados, podendo elas ser diferenciáveis ou não.

A seguir são descritas algumas *funções de transferência* comuns, mostradas também graficamente na Figura 3.3:

a) *Função limiar* – descontínua, com valores de saída entre -1 e +1, definida por:

$$\begin{aligned} \varphi_j(v_j) &= +1 \text{ se } v_j \geq 0; \\ &-1 \text{ se } v_j < 0 \end{aligned} \quad (3.3)$$

b) *Função linear* – contínua e derivável, com o coeficiente de inclinação α sendo um número real que define a saída linear dos valores, definida por:

$$\varphi_j(v_j) = \alpha \cdot v_j \quad (3.4)$$

c) *Função linear por partes* – contínua e derivável no intervalo definido por γ , definida por:

$$\begin{aligned} \varphi_j(v_j) &= +1 \text{ se } v_j \geq \gamma; \\ &v_j, \text{ se } |v_j| < \gamma; \\ &-1 \text{ se } v_j \leq -\gamma \end{aligned} \quad (3.5)$$

d) *Função sigmóide logística* – contínua e derivável, definida por:

$$\varphi_j(v_j) = \frac{1}{1 + e^{-v_j}} \rightarrow \varphi'_j(v_j) = \frac{e^{-v_j}}{(1 + e^{-v_j})^2} \quad (3.6)$$

Sendo φ'_j a derivada primeira da função φ_j .




Figura 3.3 – Exemplos de funções de transferência ϕ_j , com respectivas funções derivadas primeiras ϕ'_j : (a) limiar; (b) linear ($\alpha = 0.5$); (c) linear por partes ($\gamma = 1$); (d) sigmóide; (e) tangente hiperbólica; (f) tangente hiperbólica sigmóide.

e) *Função tangente hiperbólica* – contínua e derivável, definida por:

$$\varphi_j(v_j) = \tanh(v_j) = \frac{e^{v_j} - e^{-v_j}}{e^{v_j} + e^{-v_j}} \rightarrow \varphi'_j(v_j) = \text{sech}^2(v_j) \quad (3.7)$$

$$\text{onde } \rightarrow \text{sech}(v_j) = \frac{2}{e^{v_j} + e^{-v_j}}$$

f) *Função tangente hiperbólica sigmóide* – contínua e derivável, definida por:

$$\varphi_j(v_j) = \tanh\text{sig}(v_j) = \frac{1 - e^{-v_j}}{1 + e^{-v_j}} \rightarrow \varphi'_j(v_j) = \frac{2 \cdot e^{-v_j}}{(1 + e^{-v_j})^2} \quad (3.8)$$

As funções descritas, bem como outros tipos de funções podem ser eventualmente customizadas pelo usuário de redes neurais, por exemplo com a adoção de coeficientes multiplicadores da função soma (v_j) ou mesmo com a escolha de outras funções de formato diferente das listadas como exemplo. Além disso, para algumas funções, foi definida uma faixa de variação entre -1 e +1, porém pode ser desejável em alguns casos que essa faixa oscile entre 0 e +1.

3.4 Rede Neural Artificial (RNA)

Combinando os neurônios em uma ou mais camadas, cada uma delas com um ou mais neurônios interligados através de sinapses, é obtida a chamada Rede Neural Artificial (RNA), representada na Figura 3.4, e que genericamente possuem (LUDWIG, et al, 2007):

- Uma *camada de entrada* ou de distribuição, sem nenhum neurônio, com um número de nós correspondente ao número de informações de entrada, onde não se realiza nenhum tipo de cálculo.
- Uma, (ou nenhuma) ou várias *camadas ocultas ou intermediárias*, cada uma delas composta de um ou mais neurônios ocultos, que capacitam a rede a processar as informações de entrada, alimentando com o resultado desse processamento, no caso mais usual, camadas posteriores, ou mesmo eventualmente camadas anteriores, nesse caso em um processo de retro alimentação (feedback).

- Uma *camada de saída*, contendo necessariamente um número de neurônios igual ao número de sinais de saída da rede.




Figura 3.4 – Exemplo de uma cadeia de neurônios interligados em uma RNA multicamadas, com respectivas conexões e sinais de entrada e saída. Neste caso, o fluxo de informações é sempre à vante (*feedforward*), com os neurônios de uma camada inteiramente conectados aos da seguinte (*fully connected*).

Com o progressivo ajuste de valores dos pesos sinápticos, a rede neural pode representar (ou memorizar) as relações entre os dados de entrada e saída, assumindo uma característica de memória associativa.

3.5 Arquitetura da RNA

Por arquitetura de rede entende-se que seja a maneira pela qual os neurônios de uma RNA estão organizados em uma estrutura, podendo fundamentar esta última em três tipos básicos (TAKAHASI, 2006):

a) Redes alimentadas à vante (*feedforward*) com uma única camada de entrada e uma única camada de saída. Esse tipo de rede é conhecida pelo nome *perceptron*, e aplica-se apenas em estruturas de decisão mais simples, não muito avançadas, apresentando problemas específicos, como no caso de separação de classes ou padrões que não sejam linearmente separáveis.

b) Redes diretas (alimentadas à vante) com múltiplas camadas (*Multilayer Feedforward Networks*), também são chamadas de *perceptron multicamadas*.

c) Redes *recorrentes*, que são assim denominadas por apresentarem pelo menos um laço de realimentação de camadas, a partir de neurônios de saída, ou de neurônios de camadas ocultas.

Os neurônios podem ainda estar total ou parcialmente conectados entre camadas. A Figura 3.5 ilustra a tipificação básica da arquitetura de RNA's.




Figura 3.5 – Exemplos de arquitetura de RNA's: (a) sem camada oculta, fluxo somente à vante; (b) multicamada, ou seja, com camada oculta, fluxo somente à vante; (c) multicamada recorrente, com retro alimentação do fluxo de informação, no caso da camada de saída para a de entrada.

3.6 Aprendizagem da RNA

Aprendizagem de RNA é um processo pelo qual os parâmetros livres da rede neural, que são os seus pesos sinápticos, são adaptados através de um mecanismo de estímulo iterativo, pelo ambiente no qual ela está inserida. O tipo de aprendizagem é determinado pela maneira na qual a modificação de parâmetros ocorre. Em resposta a essas adaptações em sua estrutura interna, a rede modifica e idealmente aperfeiçoa sua resposta aos estímulos do ambiente.

Destacam-se duas formas principais de aprendizado de RNA's:

- Aprendizado supervisionado, no qual a rede é treinada com pares de conjuntos de entrada (*inputs*) e de saída desejada (*targets*). Para cada um desses conjuntos, o erro ou diferença entre a saída obtida e a desejada serve de base para o ajuste dos pesos e *bias*, objetivando a redução desse erro. A repetição desse processo para os demais os pares de entrada e saída constituem a essência o treinamento da rede, até que o acerto do sinal de saída seja considerado adequado.
- Aprendizado não supervisionado ou auto-supervisionado, no qual a rede é treinada somente com a informação dos conjuntos de entrada, inexistindo, portanto, a informação dos conjuntos de saída desejada. Nesse caso, essas informações de entrada servem para a classificação de seus valores em grupos. Esta auto-organização se dá por processos de competição e cooperação entre os neurônios. Assim, esse tipo de rede visa classificação de dados pelo reconhecimento de padrões, através do reconhecimento de características em comum entre conjuntos de dados.

Já o algoritmo de aprendizagem é o conjunto de regras que resulta no aprendizado da rede, dentro de uma precisão objetivada e suficiente.

Foge ao escopo desse texto enumerar e descrever os vários tipos de algoritmos, com exceção do consagrado algoritmo por correção de erros conhecido como regra delta de *Widrow e Hoff*, utilizado amplamente em RNA's destinadas à previsão de variáveis a partir de ajuste de dados conhecidos, e que contempla os seguintes aspectos (HAIKIN, 2001) (LUDWIG, et al, 2007):

- O valor da modificação da intensidade da conexão sináptica (pesos w_{ij}), para as mesmas excitações dos neurônios pode variar com o tempo.
- A modificação da intensidade da conexão sináptica (Δw_{ij}) pode depender do valor dessa conexão (w_{ij}), num efeito não linear.
- Imagina-se que a modificação da intensidade da conexão sináptica (Δw_{ij}) dependa também dos neurônios da vizinhança.

Como será visto adiante, a regra delta de aprendizado implementa uma otimização do erro médio quadrático, considerando a informação de saída obtida em relação à objetivada, visando a minimização desse erro.

A seguir, será enfocado o bem conhecido algoritmo generalizado da regra delta para RNA's de múltiplas camadas, conhecido como algoritmo de retro propagação de erro (*Backpropagation*), que utiliza o aprendizado do tipo supervisionado.

3.7 Algoritmo de retro propagação (*Backpropagation*)

Consideremos uma RNA à qual se aplica a seguinte notação:

- m camadas de neurônios, desde $k = 1 \dots m$
- cada camada k com n_k neurônios, desde $j = 1 \dots n_k$
- camada de entrada ($k = 0$), com n sinais de entrada x_i , desde $i = 1 \dots n$

Aplicando-se à camada de entrada da rede o vetor de sinais de entrada x_{ji} , obtêm-se os valores de soma v_j , para cada neurônio (j) da primeira camada oculta ($k = 1$). Esses sinais são processados pelas respectivas funções de transferência de cada neurônio $\phi_j = f(v_j)$, sendo dessa forma obtidos os sinais de entrada para a segunda camada oculta ($k = 2$), sendo esse processo repetido para as demais camadas da rede, até a última camada de saída ($k = m$). Esta é então a fase de propagação (*propagation*) dos sinais de entrada, que resultam nos sinais de saída, na última camada de neurônios da rede.

Uma vez obtido os resultados y_j , de cada neurônio (j) da camada de saída, esses sinais são comparados com os valores alvo, ou desejados, d_j , obtendo-se o erro de ajuste e_j correspondente. A soma quadrática desses *erros instantâneos* fornece o *erro global instantâneo* da iteração (t), E_t . Assim, utilizando o conceito da *distância euclidiana* entre a resposta desejada e a calculada pela rede, têm-se:

$$(e_j)_t = (d_j - y_j)_t \rightarrow E_t = \left(\frac{1}{2} \cdot \sum_{j=1}^{n_m} (e_j^2) \right)_t \quad (3.9)$$

Para um número N equivalente ao número total de iterações (t), igual à quantidade total de casos constituintes do lote de dados para treinamento da rede, calcula-se um correspondente *erro global médio* $\bar{E}_T$, representativo desse ciclo de treinamento. Esse ciclo é definido como sendo uma *época* (T) do processo de ajuste, e o erro nada mais é do que a média aritmética dos erros globais instantâneos, definido por:

$$\bar{E}_T = \left(\frac{1}{N} \cdot \sum_{t=1}^N E_t \right)_T \quad (3.10)$$

Para uma dada época (T), o erro global instantâneo E_t é função de todos os parâmetros livres (pesos sinápticos e *bias*) da rede, ou seja:

$$\begin{aligned} E_t &= \left(\frac{1}{2} \cdot \sum_{j=1}^{n_m} (d_j - (\varphi_j(v_j))_{k=m})^2 \right)_t \\ (v_j)_{k=m} &= \sum_{i=1}^{n_{m-1}} (w_{ji} \cdot (\varphi_j(v_j))_{m-1}) \\ &\dots \\ (v_j)_k &= \sum_{i=1}^{n_k} (w_{ji} \cdot (\varphi_j(v_j))_{k-1}) \\ &\dots \\ (v_j)_{k=1} &= \sum_{i=1}^{n_1} (w_{ji} \cdot x_{ji}) \end{aligned}$$

Desta forma, a questão relevante passa a ser como atribuir a cada parâmetro livre, pesos e *bias*, sua respectiva parcela de culpa ou crédito pelo erro global instantâneo, para assim definir que ajuste se faz necessário para, na época seguinte, aplicá-lo a cada parâmetro livre na direção de um erro global mínimo. Trata-se então de um problema de *atribuição de crédito*, que minimize a função $E=f(w)$, genericamente representada na Figura 3.6.




Figura 3.6 – Representação esquemática do erro global instantâneo E como função do parâmetro livre w , e da sua derivada, tangente à curva $E=f(w)$.

Com base na Figura 3.6, percebe-se que *para se caminhar para o mínimo da função de erro E* , cabem as seguintes observações:

- Caso o valor da derivada da função $E=f(w)$ seja positivo, a correção do parâmetro livre Δw deverá ser negativa.
- Sendo o valor dessa derivada negativo, Δw deverá ser positivo.
- Se o valor absoluto dessa derivada é alto, isso indica a não proximidade de um ponto de mínimo, devendo o valor absoluto da correção, $|\Delta w|$, também ser alto.
- Se o valor absoluto dessa derivada é baixo, isso indica a proximidade de um ponto de mínimo, indicando que o valor $|\Delta w|$ deve ser menor.

Para cada iteração (t), esses pressupostos são conceitualmente atendidos pela regra delta, expressa por:

$$(\Delta w_{ji})_t = \left(-\eta \cdot \frac{\partial E}{\partial w_{ji}} \right)_t \quad (3.11)$$

Nesse caso o coeficiente adicional η introduz uma *taxa de aprendizado* ao valor da correção Δw_{ji} do peso w_{ji} , com o sinal negativo indicando valor de Δw_{ji} é sempre simétrico ao do gradiente do erro global instantâneo, como desejado.

Com a continuidade de cada ciclo (t) de iteração, ocorre então a fase de retro propagação (*backpropagation*) de sinais, em sentido inverso ao da fase de propagação, e na qual se realizará o ajuste para correção de todos os pesos e *bias*.

No caso do modo seqüencial ou *on-line* de aprendizado, o ajuste de pesos ocorre ao final de cada iteração (t). Ou seja, após o final de uma época (T) de treinamento composta por um dado número de iterações, terá ocorrido um número igual de ciclos de correção dos parâmetros livres.

Já no caso do modo de aprendizado por lote ou em *batch*, o ajuste de pesos ocorre ao final de cada época (T), instante no qual é finalizado um ciclo de apresentação de todos os casos do lote de treinamento. Ou seja, ao final de cada época (T) terá ocorrido apenas um ajuste de pesos, porém ajuste esse que leva em conta os erros instantâneos de cada iteração (t).

As iterações (t) continuam durante o treinamento da RNA, até que um critério de parada seja atendido. Um critério inicial considera uma das seguintes alternativas de parada do processo de treinamento da RNA:

- o erro global médio E_T inferior a um limite especificado.
- o numero de épocas (T) superior a um limite especificado.
- capacidade de generalização da rede, através de sua validação, dependendo nesse caso de um conjunto ou lote adicional de dados, segregado do conjunto de treinamento, sobre o qual se aplica a RNA, para avaliação paralela do ajuste da rede, simultaneamente ao seu treinamento.

Para cada ajuste por retro propagação faz-se necessário a determinação das derivadas parciais do erro global instantâneo E_t , tanto para a última camada da rede, como também para as camadas ocultas.

A Figura 3.7 mostra um grafo de fluxo que considera a configuração de um neurônio da última camada da rede. Nesse caso, a derivada parcial do erro global instantâneo em relação ao peso sináptico, para uma iteração (t), pode ser expressa pela regra da cadeia por:

$$\left(\frac{\partial E}{\partial w_{ji}} \right)_t = \left(\left(\frac{\partial E}{\partial e_j} \cdot \frac{\partial e_j}{\partial y_j} \cdot \frac{\partial y_j}{\partial v_j} \right) \cdot \frac{\partial v_j}{\partial w_{ji}} \right)_t = \left(\delta_j \cdot \frac{\partial v_j}{\partial w_{ji}} \right)_t \quad (3.12)$$




Figura 3.7 – Grafo de fluxo sinal de um neurônio (j) da última camada da rede, para análise da retro propagação a partir da camada de saída.

O termo δ_j é definido como sendo o gradiente local do neurônio (j), nesse caso da última camada da rede, sendo igual a:

$$(\delta_j)_t = \left(\frac{\partial E}{\partial e_j} \cdot \frac{\partial e_j}{\partial y_j} \cdot \frac{\partial y_j}{\partial v_j} \right)_t = \left(\frac{\partial E}{\partial v_j} \right)_t \quad (3.13)$$

Como, de (3.9):

$$(e_j)_t = (d_j - y_j)_t \rightarrow E_t = \left(\frac{1}{2} \cdot \sum_{j=1}^{n_m} (e_j^2) \right)_t \quad (3.9)$$

$$\rightarrow \left(\frac{\partial E}{\partial e_j} \right)_t = (e_j)_t$$

$$\rightarrow \left(\frac{\partial e_j}{\partial y_j} \right)_t = (-1)_t$$

De (3.2):

$$(y_j)_t = (\varphi_j(v_j))_t \rightarrow \left(\frac{\partial y_j}{\partial v_j} \right)_t = (\varphi'_j(v_j))_t$$

Da definição de função soma (3.1):

$$(v_j)_t = \left(\sum_{i=0}^n (w_{ji} \cdot y_i) \right)_t \rightarrow \left(\frac{\partial v_j}{\partial w_{ji}} \right)_t = (y_i)_t$$

Assim, após substituições devidas, temos para o gradiente local δ_j :

$$(\delta_j)_t = \left(\frac{\partial E}{\partial v_j} \right)_t = (-e_j \cdot \varphi'_j(v_j))_t \quad (3.14)$$

E para a derivada parcial do erro global instantâneo E_t , na iteração (t):

$$\left(\frac{\partial E}{\partial w_{ji}} \right)_t = (\delta_j \cdot y_i)_t \quad (3.15)$$

Com estes resultados, a correção do peso sináptico da última camada de neurônios, ou camada de saída, por retro propagação, a cada iteração (t) fica sendo:

$$(\Delta w_{ji})_t = -\eta \cdot \left(\frac{\partial E}{\partial w_{ji}} \right)_t = (-\eta \cdot \delta_j \cdot y_i)_t = (\eta \cdot e_j \cdot y_i \cdot \varphi'_j(v_j))_t \quad (3.16)$$

Com a correção do peso sináptico preliminarmente dada por:

$$(w_{ji})_{t+1} = (w_{ji} + \Delta w_{ji})_t \quad (3.17)$$

Resta então repetir o procedimento de determinação da correção dos parâmetros livres das demais camadas da rede, o que é feito de forma análoga ao da camada de saída. Isto é feito com o auxílio da Figura 3.8 que mostra além de um neurônio da camada de saída, também um neurônio da camada oculta anterior.

Para a determinação da derivada do erro global instantâneo E_t , em relação a um peso sináptico de um neurônio da camada anterior à de saída w_{zi} , parte-se da análise da influência provocada por uma correção infinitesimal adicionada a esse referido peso na variação do erro, a cada iteração (t). Ou seja:

$$(w_{zi} + \Delta w_{zi})_t \xrightarrow{\text{Efeito}} \partial E$$




Figura 3.8 – Grafo de fluxo de sinal de um *perceptron* para análise da retropropagação do ajuste de neurônios de camadas ocultas.

Considera-se a então influência dessa correção em cada nó do grafo. Assim, para o nó da função soma de ativação do neurônio (i), da camada oculta ($k=m-1$), temos:

$$(\Delta w_{zi})_t \rightarrow (\partial v_i)_t = \left(\frac{\partial v_i}{\partial w_{zi}} \cdot \partial w_{zi} \right)_t = (y_z \cdot \partial w_{zi})_t$$

Passando para um nó referente a uma saída y_i , da camada oculta ($k=m-1$), utilizando o resultado anterior, temos:

$$(\Delta w_{zi})_t \rightarrow (\partial v_i)_t \rightarrow (\partial y_i)_t = \left(\frac{\partial y_i}{\partial v_i} \cdot \partial v_i \right)_t = (\phi'_i(v_i) \cdot y_z \cdot \partial w_{zi})_t$$

Sendo a rede amplamente conectada, essa variação infinitesimal na saída y_i , na saída da camada oculta ($k=m-1$), entrada da camada seguinte ($k=m$), será propagada de forma distribuída, ponderada pelos pesos w_{ji} , nos neurônios da camada seguinte ($k=m$).

Assim cada neurônio da camada ($k=m$) irá gerar um acréscimo infinitesimal em sua função de soma ativação.

$$(\Delta w_{zi})_t \rightarrow (\partial v_i)_t \rightarrow (\partial y_i)_t \rightarrow (\partial v_j)_t = (\partial y_i \cdot w_{ji})_t = (\varphi'_i(v_i) \cdot y_z \cdot w_{ji} \cdot \partial w_{zi})_t \quad (3.18)$$

Foi determinado anteriormente (3.15), para um neurônio (j) da camada de saída, os seguintes resultados:

$$\left(\frac{\partial E}{\partial w_{ji}} \right)_t = (\delta_j \cdot y_i)_t \rightarrow (\partial E)_t = (\delta_j \cdot y_i \cdot \partial w_{ji})_t$$

$$\left(\frac{\partial v_j}{\partial w_{ji}} \right)_t = (y_i)_t$$

Assim obtendo-se, após substituições devidas:

$$(\partial E)_t = (\delta_j \cdot \partial v_j)_t$$

Esta variação do erro E_t é devida apenas a um dos neurônios (j) da camada ($k=m$). Para considerar a influência de todos os neurônios dessa camada, é necessário que seja considerado o somatório dado por:

$$(\partial E)_t = \left(\sum_{j=1}^{n_m} \partial E_j \right)_t = \left(\sum_{j=1}^{n_m} (\delta_j \cdot \partial v_j) \right)_t \quad (3.19)$$

Substituindo o valor do acréscimo diferencial na função soma v_j já determinado em (3.18) e após manipulação algébrica, chega-se ao valor da variação do erro global instantâneo E_t , na saída da camada ($k=m$), devido à variação infinitesimal no peso sináptico w_{zi} , da camada oculta ($k=m-1$), anterior:

$$\begin{aligned} (\partial E)_t &= \left(\sum_{j=1}^{n_m} (\delta_j \cdot \varphi'_i(v_i) \cdot y_z \cdot w_{ji} \cdot \partial w_{zi}) \right)_t = \left(\varphi'_i(v_i) \cdot y_z \cdot \partial w_{zi} \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \rightarrow \\ &\left(\frac{\partial E}{\partial w_{zi}} \right)_t = \left(\varphi'_i(v_i) \cdot y_z \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \end{aligned} \quad (3.20)$$

Levando esse resultado à expressão da regra delta, para retro propagação da correção dos pesos da camada ($k=m$), na iteração (t), temos:

$$(\Delta w_{zi})_t = \left(-\eta \cdot \frac{\partial E}{\partial w_{zi}} \right)_t = \left(-\eta \cdot \varphi'_i(v_i) \cdot y_z \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.21)$$

Desta forma fica atribuída a correção de cada peso w_{zi} , da camada ($k=m-1$), anterior à camada ($k=m$), devida pelo erro global instantâneo E_t , que ocorre na saída da rede, com a comparação dos valores obtidos y_j na saída de cada neurônio (j) com os respectivos valores alvo d_j .

Para facilitar o cálculo dessa correção para camadas ainda mais anteriores, é interessante explicitar o gradiente local δ_i , da camada (l), que na continuidade da retro propagação da correção em camada anterior à mesma será utilizado de forma análoga ao gradiente δ_j .

$$\left(\frac{\partial E}{\partial w_{zi}} \right)_t = (\delta_i \cdot y_z)_t \rightarrow (\delta_i)_t = \left(\frac{1}{y_z} \cdot \frac{\partial E}{\partial w_{zi}} \right)_t = \left(\varphi'_i(v_i) \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.22)$$

Isso permite reescrever a equação de correção dos pesos w_{zi} , da camada oculta ($k=m-1$), como sendo:

$$(\Delta w_{zi})_t = \left(-\eta \cdot \frac{\partial E}{\partial w_{zi}} \right)_t = (-\eta \cdot \delta_i \cdot y_z)_t = \left(-\eta \cdot \varphi'_i(v_i) \cdot y_z \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.23)$$

Aplicado preliminarmente a:

$$(w_{zi})_{t+1} = (w_{zi} + \Delta w_{zi})_t \quad (3.24)$$

Para outras camadas ocultas adicionais ($k < m-1$), o procedimento de ajuste dos parâmetros livres se repete, com a adequada troca de índices representativos de cada camada. Nota-se a similaridade das duas últimas expressões, relativas ao ajuste de uma camada oculta (3.23) e (3.24), com aquelas anteriores relativas ao ajuste de pesos da camada de saída (3.16) e (3.17).

Ou seja, genericamente, para um neurônio da camada (Q), recebendo sinais de entrada que são sinais de saída da camada (P), temos que: [Correção de peso (Δw_{qp})] = -[Taxa de aprendizagem (η)] x [Gradiente local (δ_q)] x [Sinal de entrada do neurônio (y_p)]

Pode ser percebido na expressão que o valor da taxa de aprendizagem (η) tem influência crítica na eficiência (velocidade e precisão) de busca do erro global mínimo, dentro do espaço de pesos (w). Altos valores dessa taxa resultam em maior variação dos pesos, de uma iteração para outra, com risco de oscilação em torno do ponto ótimo de mínimo erro. Baixos valores da taxa conduzem a um ajuste mais suave e preciso, porém mais lento.

Uma forma de atenuar esse tipo de problema, tornando mais estável essa busca pelo erro mínimo, consiste na adoção de um coeficiente de suavização ou amortecimento da correção do parâmetro livre, sendo esse parâmetro adicional conhecido como termo de momento (α) da regra delta, conforme mostrado na equação a seguir:

$$(\Delta w_{zi})_t = \left(-\eta \cdot \frac{\partial E}{\partial w_{zi}} + \alpha \cdot (\Delta w_{zi})_{t-1} \right)_t = \left(-\eta \cdot \phi'_i(v_i) \cdot y_z \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) + \alpha \cdot (\Delta w_{zi})_{t-1} \right)_t$$

com : $0 \leq \alpha \leq 1$

3.25)

Com esta última consideração final fica consolidada o que seria uma base de fundamentos do algoritmo de ajuste por retro propagação de uma RNA multicamada com fluxo direto à vante, do tipo *multilayer perceptron* (HAIKIN, 2001) (LUDWIG, et al, 2007).

No Apêndice A é mostrado um resumo do algoritmo de retro propagação (*backpropagation*). No Apêndice B é mostrado em detalhe um exemplo simples de aplicação do método, na forma de diagrama de blocos, explicitando o fluxo e as equações de propagação e retro propagação dos sinais pela rede, com um único caso ou exemplo de treinamento, de forma que cada iteração corresponde a uma época de treinamento. São mostrados os diagramas das épocas 1, 2, 10 e 20, e o gráfico de decaimento do erro da saída da rede após 20 épocas, após as quais esse é reduzido para 32% do valor obtido na primeira iteração.

3.8 Variações do algoritmo de retro propagação

O algoritmo mais simples de RNA *Backpropagation* a cada iteração atualiza pesos e *bias* na direção de minimização mais rápida da função de performance da rede. Essa direção é a do valor negativo do gradiente da função de erro global instantâneo, conforme abaixo reescrito a partir das equações da seção anterior, sem o termo de momento para maior simplicidade.

$$(w_{ji})_{t+1} = (w_{ji} + \Delta w_{ji})_t = \left(w_{ji} - \eta \cdot \frac{\partial E}{\partial w_{ji}} \right)_t \rightarrow (W)_{t+1} = (W - \eta \cdot G)_t \quad (3.25)$$

Muitas outras variações e alternativas ao algoritmo de gradiente descendente foram desenvolvidas visando principalmente maior velocidade e estabilidade de convergência na adaptação dos parâmetros livres e minimização do erro da rede. Além disso, do ponto de vista computacional, também aspectos do consumo de memória foram melhorados em algumas implementações, no sentido de sua redução.

Esse capítulo do trabalho não tem o objetivo de aprofundar detalhes desses algoritmos melhorados, disponíveis em textos especializados e tornados acessíveis para uso pelos softwares dedicados de RNA's. Entretanto, é apropriado mencionar alguns exemplos das variações do algoritmo *backpropagation*.

A Figura 3.9 mostra um quadro geral de exemplos dessas variações, baseado nas descrições que aparecem no manual do *software MATLAB* (DEMUTH, et al, 2007), no capítulo dedicado à RNA *backpropagation*, apenas como referência indicativa da amplitude de opções de implementação desse tipo de rede.

Métodos matematicamente mais simples como os do gradiente descendente, com ou sem o termo de momento, são considerados mais lentos para problemas de ordem prática. Algoritmos mais sofisticados resultam em processamento mais rápido, com aumento de sua velocidade de convergência da ordem de dez a mil vezes.




Figura 3.9 – Diagrama descritivo de exemplos de variações de algoritmos aplicáveis a RNA's *Backpropagation*, baseado em descrições disponibilizadas no manual de software comercial *MATLAB* (DEMUTH, et al, 2007).

Algoritmos definidos como heurísticos são aqueles de caráter exploratório para definição de problemas em que as soluções são descobertas pela avaliação do progresso obtido na busca de um resultado final. São métodos em que, embora a exploração seja feita de forma algorítmica, o progresso é obtido pela avaliação puramente empírica do resultado. São exemplos de algoritmos *backpropagation* heurísticos (DEMUTH, et al, 2007) (HAIKIN, 2001):

- **Métodos de gradiente descendente com ou sem momento:** conforme mostrado anteriormente. O termo de momento suaviza a busca do erro mínimo, amortecendo a atualização de pesos e *bias*.

- **Método do fator adaptativo variável (*variable learning rate*):** basicamente, se o erro atual da rede excede o erro da iteração anterior, de um valor pré-definido, pesos e *bias* não são atualizados, e a taxa de adaptação (η) é reduzida, para a nova iteração, após a qual, ocorrendo decréscimo do erro, η é aumentada. Variando-se a taxa de adaptação, evita-se oscilação excessiva na busca do erro mínimo.

- **Método da retro propagação resiliente (*resilient backpropagation*):** próximos a valores extremos de funções de ativação sigmóides dos neurônios, os valores de correção de parâmetros livres resultam ser de baixa magnitude, mesmo quando os valores de pesos e *bias* estão longe do ideal. O algoritmo da retro propagação resiliente utiliza o sinal da função sigmóide, para indicar a direção de atualização, porém utiliza valores separados para atualizar pesos e *bias*. Caso ocorra oscilação, a magnitude da correção é diminuída. Caso contrário, se os pesos continuam a mudar no mesmo sentido após várias iterações, a quantidade de correção é aumentada. Isso contribui para a aceleração do aprendizado da rede.

Os algoritmos mais sofisticados incorporam o conceito de otimização, visando a minimização da função custo $E=f(\mathbf{w})$, ou seja, do erro da rede como função da variável vetor de parâmetros livres. Alguns exemplos desse tipo de algoritmo são:

- **Métodos do gradiente conjugado:** nessa variação, a busca do erro mínimo é realizada ao longo de direções conjugadas, resultando em convergência mais rápida do que a direção de descida mais íngreme. Assim, a cada iteração, temos que ao invés de se adotar a direção expressa pelo negativo do gradiente $(-\mathbf{g})_t$, é adotada uma combinação de direção entre aquela da descida mais íngreme e uma nova direção calculada, ou seja: $(\mathbf{w})_t = (-\mathbf{g})_t + \beta \cdot (\mathbf{w})_{t-1}$, sendo o fator β uma função do gradiente, que depende da teoria de atualização adotada (por exemplo: Fletcher-Reeves, Polak-Ribière, Powell-Beale; entre outros).

- **Métodos Quasi-Newton:** o método original de Newton visa uma otimização mais rápida do que as dos métodos de gradiente conjugado, levando a uma atualização do tipo $(\mathbf{w})_{t+1} = (\mathbf{w} - \mathbf{H}^{-1} \cdot \mathbf{g})_t$, onde $\mathbf{H}^{-1}$ é a inversa da matriz das derivadas segunda da função de erro, ou seja $\mathbf{H} = \nabla^2 E(\mathbf{w})$, também chamada matriz Hessiana. Modificações desse método de Newton visam superar dificuldades de computação da matriz de derivadas segunda, adotando uma aproximação da matriz Hessiana, como função do gradiente, originando daí o nome Quasi-Newton para tais métodos, sendo exemplos o de BFGS (Broyden, Fletcher, Goldfarb and Shano) e o de BFGS com aproximação pela secante.

- **Método de Levenberg-Marquardt:** de forma similar aos algoritmos Quasi-Newton, o de Levenberg-Marquardt também supera a dificuldade de computação da matriz Hessiana, aproximando-a por uma expressão que leva em conta a matriz de derivadas primeira da função erro com relação aos parâmetros livres, ou seja o seu Jacobiano: $\mathbf{J} = \nabla E(\mathbf{w})$.

Assim, a matriz Hessiana $\mathbf{H} \equiv \mathbf{J}^T \cdot \mathbf{J}$, e o gradiente $\mathbf{g} = \mathbf{J}^T \cdot \mathbf{e}$, levam a $(\mathbf{w})_{t+1} = (\mathbf{w} - [\mathbf{J}^T \cdot \mathbf{J} + \mu \cdot \mathbf{I}]^{-1} \cdot \mathbf{J}^T \cdot \mathbf{e})_t$, sendo μ um escalar positivo, e $\mathbf{I}$ = matriz identidade. Embora o produto $(\mathbf{J}^T \cdot \mathbf{J})$ seja sempre positivo, não há garantia que seja não singular, o que leva à conveniência da adição do termo $(\mu \cdot \mathbf{I})$. O fator μ sofre redução a cada iteração (t), caso o erro da rede venha sendo continuamente minimizado. Se em alguma iteração (t) o erro da rede sofre aumento, μ é aumentado, garantindo a continuidade da redução do erro. Porém caso μ sofra aumento para um valor acima de $\mu_{\text{máx}}$, o algoritmo deixa de ser processado. Ou seja, $\mu \geq \mu_{\text{máx}}$ constitui-se em um critério adicional de parada do treinamento da RNA.

Computacionalmente, no processamento do algoritmo de *Levenberg-Marquardt* o consumo de memória pode ser reduzido, se houver subdivisão da matriz $\mathbf{J}$ em submatrizes, o que permite não ser necessário o armazenamento e processamento de toda a matriz Jacobiana, já que cada subtermo calculado, a correspondente submatriz pode ser descartada.

O algoritmo de *Levenberg-Marquardt* é bastante veloz se aplicado em RNA's *backpropagation* destinadas a ajuste de funções. Tomando exemplos do manual do *software MATLAB* (DEMUTH, et al, 2007), RNA's aplicadas a aproximação da função seno resultou em tempos de processamento médios 5 vezes menores com a utilização do algoritmo *Levenberg-Marquardt* se comparado aos algoritmos BFG (Quasi-Newton) e RP (*Resilient Backpropagation*). Para outro exemplo de aproximação de função não linear, o algoritmo *Levenberg-Marquardt* resultou ser entre 1.4 e 10 vezes mais rápido do que 8 outras variações de algoritmos aplicados a RNA's *backpropagation*. Considerações conceituais adicionais sobre esse algoritmo são mostradas no Apêndice C.

3.9 Pré e Pós-processamento de variáveis da RNA:

É recomendável, para uma melhor eficiência de processamento da RNA que as variáveis de entrada, ou seja os *inputs*, tenham seus valores normalizados. Da mesma forma, os valores de saída da rede devem também sofrer conversão correspondente dos valores normalizados para o valores absolutos.

Um ponto importante é que com a rede treinada, assim como a sua arquitetura, pesos e funções internas, também os parâmetros que definiram o pré-processamento e o pós-processamento de *inputs* e *targets* passam a ser integrantes da própria rede.

Isso quer dizer que no caso de simulação dessa RNA com outro lote de dados, aqueles parâmetros de pré e pós-processamento deverão ter os mesmos valores obtidos a partir do lote de treinamento da rede.

Duas formas comuns é realizar a mencionada normalização, para valores usualmente dentro da faixa [-1 a 1], envolve a adoção de um dos seguintes métodos:

- A partir de valores mínimos e máximos de cada variável de entrada e de cada variável de saída constituintes do lote de treinamento da rede.

$$X_{norm} = 1 - 2 \cdot \frac{X_{max} - X}{X_{max} - X_{min}} \rightarrow X_{norm} \in [-1:1] \quad (3.25)$$

$$Y_{norm} \in [-1:1] \rightarrow Y = Y_{max} - \frac{(Y_{norm} - 1) \cdot (Y_{max} - Y_{min})}{2} \quad (3.26)$$

- A partir da média e desvio padrão de cada variável de entrada e de cada variável de saída constituintes do lote de treinamento da rede. Neste caso, os valores das entradas e saídas normalizadas terão uma distribuição com média zero e desvio padrão unitário.

$$X_{norm} = \frac{X - \bar{X}}{\sigma_X} \rightarrow X_{norm} [\mu = 0, \sigma = 1] \quad (3.27)$$

$$Y_{norm} [\mu = 0, \sigma = 1] \rightarrow Y = \bar{Y} + Y_{norm} \cdot \sigma_Y \quad (3.28)$$

Outro recurso utilizado para pre-processamento é a análise de componentes principais quando o vetor ($\mathbf{X}$) de entrada tem dimensão grande, com alto índice de correlação entre componentes (x_i) do vetor. Com esta técnica os componentes são ortogonalizados, descorrelacionando-os, e são priorizados aqueles com maior influência na variabilidade do lote, eliminando-se aqueles com menor contribuição para a variação do conjunto de dados, menos úteis ao treinamento da rede. Detalhes sobre a análise de componentes principais são discutidos com mais propriedade em fontes especializadas (HAINKIN, 2001).

3.10 Generalização da RNA

Uma situação possível é quando, embora uma RNA treinada apresente um baixo erro global médio (E_T) relativo ao conjunto de dados de treinamento, essa mesma RNA vem a apresentar um maior valor de erro global médio, quando simulada com um novo conjunto de dados distinto do lote de treinamento, porém extraído da mesma população. Essa é uma ocorrência típica de sobreajuste, ou do excesso de ajuste (*overfitting*), que é quando a RNA adere bem aos dados de treinamento, porém não adquire generalização suficiente para reproduzir a mesma performance com dados de novos lotes. A Figura 3.10 mostra de forma esquemática o problema.




Figura 3.10 – Ilustração de curva com excesso de ajuste (*overfitting*) aos dados da função $Y=f(x)$, representados pelos pequenos círculos. A curva ajustada apresenta uma oscilação excessiva entre pontos consecutivos de ajuste da função, levando à inexatidão da estimativa de $f(x)$ para valores de x diferentes daqueles utilizados no ajuste.

As causas do *overfitting* de RNA's mais comumente mencionadas são: o tamanho (N) do conjunto de treinamento insuficiente e uma arquitetura da RNA demasiado complexa, por exemplo com um número exagerado de neurônios.

Com relação ao lote de treinamento, uma regra prática citada em Hainkin (HAINKIN, 2001) é a que estabelece que a ordem de grandeza de N , número total de casos, deva ser da mesma ordem de grandeza da quantidade total de neurônios da rede dividida pela fração de erros esperada no lote de treinamento. Assim, para por exemplo 10% de erros, N deverá ser da ordem de 10 vezes a quantidade total de neurônios.

Para melhorar a generalização da rede duas técnicas conhecidas são as da parada antecipada e a de regularização.

Na técnica da parada antecipada (*early stopping*), a totalidade dos casos disponíveis, conjuntos de dados de entrada e alvos de saída, são divididos em três lotes, sendo o primeiro utilizado para o treinamento da RNA, o segundo utilizado para validação do treino e um terceiro para teste da rede. A Figura 3.11 auxilia a compreensão do conceito de lote de validação.




Figura 3.11 – Ilustração do conceito de parada antecipada do treinamento de uma RNA, em função do desvio de erro médio quadrático do lote de validação.

Após um período de estimação do treinamento, são avaliados tanto o erro global médio desse lote de treino, como também monitorado o erro do lote de validação, nesse caso obtido com a simulação dos dados desse lote com a RNA fixada nos parâmetros até então estimados. Quando ocorre o sobreajuste da RNA, o erro de validação começa a subir. Caso suba acima de um limite estipulado após um certo número de iterações, o treinamento é interrompido, sendo mantidos os pesos e *bias* relacionados ao mínimo erro de validação registrado até aquele momento. Caso contrário, o treinamento é continuado, juntamente com o processo de validação. O lote de teste não é utilizado para parada antecipada, servindo apenas para comparar diferentes modelos.

Algumas possibilidades de divisão do número total de casos disponíveis em lotes de treino, validação e teste são (DEMUTH, et al, 2007):

- Divisão indexando sucessivos casos de forma sequencial para os lotes de treino, validação e teste sucessivamente. Ou seja ciclos de um caso para treino, caso seguinte para validação, caso subsequente para teste.

- Divisão randômica dos lotes, sendo por exemplo 60% dos casos para treino, 20% para validação e 20% para teste.
- Divisão em blocos sequenciais, sendo por exemplo, os primeiros 60% dos casos para treino, os seguintes 20% para validação e os ultimos 20% para teste.
- Divisão intervalada em ciclos, por exemplo ciclos de 6 casos para treino, seguido de 2 para validação e 2 para teste.

Com relação à necessidade ou não do processo de validação, há uma referência em Haikin (HAIKIN, 2001) em que são sugeridos dois modos de comportamento, dependendo do tamanho do lote de treinamento e da quantidade de parâmetros livres da rede: modo não assintótico e modo assintótico ou exaustivo.

- Modo não assintótico: se $N < (30 \cdot N_w)$, sendo N_w o número total de parâmetros livres da rede, sugere-se o modo não-assintótico, sendo a partição dos dados, em termos da porcentagem de casos destinados a treinamento, conforme Haikin (HAIKIN, 2001), dada por:

$$PCT_{TREINO} = 1 - \frac{\sqrt{2 \cdot N_w} - 1}{2 \cdot (N_w - 1)} \quad (3.29)$$

- Modo assintótico: Se $N \geq (30 \cdot N_w)$, é sugerido o modo assintótico, ou exaustivo, sem lote de validação. Neste caso, a melhoria de desempenho de generalização pela utilização da parada antecipada com lote de validação é pequena. Ou seja, quando a quantidade de casos do lote total é significativamente mais alta comparada com o número total de parâmetros livres da rede, o treinamento até a exaustão é satisfatório para garantir a generalização.

Um outro recurso de melhoria da generalização da rede, é a técnica da regularização, que consiste numa modificação no cálculo da função de performance, usualmente definida com sendo o erro médio quadrático (*Mean Square Error* – *MSE*). Através dessa mudança ocorre uma suavização da função de erro, ponderando o seu valor com uma nova parcela relativa à média da soma quadrática dos pesos, através do coeficiente de ponderação γ , ou seja:

$$MSE_{REG} = \gamma \cdot MSE_T + (1 - \gamma) \cdot MSW_T = \left(\frac{\gamma}{N} \cdot \sum_{i=1}^N (e_i)^2 \right)_T + \left(\frac{1 - \gamma}{N_w} \cdot \sum_{i=1}^{N_w} (w_i)^2 \right)_T \quad (3.30)$$

Tal alteração da função de performance resulta em menores valores de pesos e *bias*, forçando a resposta da rede ser mais suave e menos sujeita ao excesso de ajuste (DEMUTH, et al, 2007) (HAIKIN, 2001).

3.11 Limitações e cuidados relativos às RNA's *MFB*

Com base em autores dedicados a descrição de RNA's *MFB* (DEMUTH, et al, 2007) (HAIKIN, 2001) (LUDWIG, et al, 2007), devem ser observados alguns cuidados gerais e limitações no seu uso.

Para redes de tamanho pequeno a médio, recomenda-se a utilização do algoritmo de *Levenberg-Marquardt*, havendo disponibilidade de memória, pela velocidade de eficiência no treinamento da RNA. Métodos do gradiente descendente com ou sem termo de momento são lentos, para aplicações de ordem prática.

Redes multicamadas retro propagadas são capazes de aproximar funções lineares ou não, razoavelmente bem, com o seu processo de treinamento. Porém pode não ser possível encontrar sempre uma solução, devido por exemplo a problemas de ocorrência de mínimos locais.

A escolha de taxas de adaptação (η) para redes não lineares é um desafio. Valores altos de (η) podem levar a um processo de adaptação instável. Valores pequenos resultam em lentidão no treinamento.

Funções de transferência não lineares introduzem muitos mínimos locais na superfície de erro da rede, que podem ser uma armadilha no processo de busca do erro mínimo.

Um recurso para se obter pesos corretos para uma solução ótima ainda é o processo de repetição da reinicialização da rede e novo treinamento, várias vezes, de forma a se ter alguma garantia de ter encontrado uma solução satisfatória e válida.

As RNA's são muito sensíveis ao número de neurônios e ao número de camadas ocultas. Poucos neurônios causam ajuste deficiente (*underfitting*). Um número excessivo de neurônios pode contribuir para o sobreajuste (*overfitting*). Generalização da rede ajuda a minimizar o problema.

4 Descrição do Processo de Laminação de Tiras a Quente

4.1 Fluxo de produtos e processos

Dentro de uma usina integrada de produção de produtos planos de aço, na forma de bobinas e chapas, a Laminação de Tiras a Quente (*Hot Strip Mill Rolling*) constitui-se em uma etapa de importância crítica, já que recebendo placas de aço do processo anterior da aciaria, como matéria-prima, produz produtos acabados, de entrega direta a clientes, as chamadas bobinas a quente, ou produz bobinas que são matéria prima para processamentos em linhas posteriores, que agregam ainda mais valor ao produto.

Nesse último caso, na seqüência de produção posterior à produção de bobinas na laminação de tiras a quente, variados processos originam muitos tipos de produtos que são função da rota de processamento seguida ou combinação delas. Classicamente, tais processos posteriores são: decapagem da bobina a quente para remoção de óxidos superficiais (*Pickling Line*), laminação de acabamento (*Hot Skin Pass*), inspeção e corte de bobinas em chapas, laminação de tiras a frio (*Cold Mill Rolling*), recozimento de bobinas (*Annealing*), laminação de encruamento (*Temper Mill Rolling*), inspeção e corte em chapas de bobina a frio. Além desses, processos mais atuais de revestimento da tira a frio também podem fazer parte da configuração de produção das bobinas e chapas a frio.

Bobinas e chapas de aço, produtos a quente ou a frio, são base da vida humana moderna, sendo sua aplicação em estruturas e componentes de automóveis, trens, navios, aviões, eletrodomésticos, edificações, tubulações, embalagens e todo tipo de máquina apenas alguns exemplos mais evidentes de sua quase infinita utilidade.

A Tabela 4.1 mostra um exemplo da matriz de distribuição de produtos em função da rota seguida pelas bobinas de tiras a quente.

Tabela 3.4 – Exemplo de matriz de produtos e rota de processamento clássicas da bobina a quente produzida na Laminação de Tiras a Quente.

Processo → Produto ↓	Laminação de Tiras a Quente (Hot Rolling)	Laminação de Acabamento (Hot Skin Rolling)	Inspeção e corte em chapas de bobinas a quente	Decapagem (Pickling Line)	Laminação de Tiras a Frio (Cold Rolling)	Recozimento de Bobinas (Annealing)	Laminação de Encruamento (Temper Rolling)	Inspeção de Bobinas a Frio	Corte de bobinas a frio em chapas
Bobina a quente	1								
Chapas a quente	1		2						
Bobina de piso	1								
Chapa de piso	1		2						
Bobina a quente acabada	1	2							
Chapa a quente acabada	1	2	3						
Bobina a quente decapada	1			2					
Chapa a quente decapada	1		3	2					
Bobina a quente decapada e acabada	1	3		2					
Chapa a quente decapada e acabada	1	3	4	2					
Bobina a frio full-hard	1			2	3				
Bobina a frio	1			2	3	4	5	6	
Chapa a frio	1			2	3	4	5	6	7

Embora de caráter específico, a tabela citada demonstra a importância da etapa de produção das bobinas a quente, ficando a evidente a dependência dos clientes, diretos e indiretos, da produtividade e qualidade dos processos da Linha de Laminação de Tiras a Quente. *Todos os processos posteriores disso dependem.*

Um enfoque também clássico de uma Linha de Tiras a Quente mostra configuração de fluxo de processo similar à mostrada na Figura 4.1.




Figura 4.1 – Fluxo de processo da linha de Laminação de Tiras a Quente. Na parte inferior da figura, processos posteriores, que possuem como matéria-prima a bobina laminada a quente.

Placas de aço produzidas na aciaria são a matéria-prima da Linha de Tiras a Quente, sendo recebidas e estocadas em pátios, para serem a seguir enfileiradas em fornos de reaquecimento de placas que descarregam as mesmas em temperaturas da ordem de 1200 a 1250 °C. Faixas típicas de espessura, largura e comprimento das placas são (210 a 260) x (600 a 2100) x (5200 a 12500) mm.

Já na saída da zona dos fornos de reaquecimento, as placas sofrem um primeiro processo de descamação para retirada da camada superficial de óxido de ferro, ou carepa primária, que se forma continuamente, ao longo da linha de laminação de tiras a quente, devido às altas temperaturas de processamento do material.

Equipamentos de descamação são compostos por coletores dotados de bicos de jatos de água com alta pressão, da ordem de 180-200 kgf/mm². Por ação mecânica, o impacto do jato de água sobre a superfície da tira quebra e remove a camada de carepa. O processo de descamação é repetido na entrada dos laminadores esboçadores e de tiras a quente, já mais adiante. A Figura 4.2 mostra a entrada de uma placa em uma estação de descamação.




Figura 4.2 – Processo de descamação, ou retirada de óxido de ferro (carepa) da placa.

O processo seguinte ao da remoção de carepa primária é o da laminação de esboçamento ou desbaste, realizada através de um ou mais laminadores esboçadores (*Roughing Mills*), através dos quais a espessura da placa é reduzida para cerca de 30 mm no chamado esboço, produto intermediário, matéria-prima para o processo seguinte de laminação de tiras. Os passes de esboçamento são efetuados por laminadores quádruplo reversíveis, com passes de redução de espessura consecutivos de sentido alternado. Porém algumas linhas possuem laminador tipo RM com várias cadeiras que reduzem a espessura em passes seqüenciais contínuos sempre no sentido da linha. A Figura 4.3 ilustra esses conceitos.




Figura 4.3 – Conceito de redução de espessura em (a) passes reversíveis, comuns em laminadores esboçadores tipo RM e (b) passes contínuos de laminação, típico de Laminadores de Tiras a Quente (LTQ) convencionais.

Na figura 4.3 aparece ainda a ferramenta de conformação de da laminação, que são os cilindros de laminação. A cada passe de redução de espessura, são ajustadas uma abertura entre cilindros, por onde vai ser conformado o material e a velocidade de rotação dos mesmos. A este conjunto de valores de abertura ou *gap* e velocidade dos cilindros no passe é dada a denominação de *set-up* de ajuste da cadeira. Usualmente a velocidade linear periférica dos cilindros é utilizada de forma equivalente no lugar da velocidade de rotação. A Figura 4.4 mostra uma foto do laminador esboçador R1 da COSIPA.

Após a laminação de esboçamento, o material é transferido, em mesas de rolos, para a zona do Laminador de Tiras a Quente. Nesse processo de transferência, visa-se conservar a temperatura do material, através da adoção de túneis isolados (*Heat Cover*) ou de bobinadeira intermediária (*Coil Box*), conforme visualizado na Figura 4.5.





Figura 4.4 – Laminador R1 da COSIPA, de uma cadeira quádrupla-reversível, com laminador de bordas vertical (*Edger Mill*) na entrada.



(a)

(b)

Figura 4.5 – Equipamentos para conservação da temperatura do esboço no processo de transferência desde a zona dos laminadores esboçadores (RM) até a zona do Laminador de Tiras a Quente (LTQ): (a) túnel de cobertura térmica (*Heat Cover*); (b) bobinadeira intermediária (*Coil Box*).

Antes da chegada ao LTQ, o esboço sofre duas preparações. A primeira delas é a de corte de pontas do esboço, no equipamento de tesoura volante (*Crop Shear*), que possui um tambor dotado de navalhas diametralmente opostas que cortam as extremidades inicial e final do material de forma automática e otimizada. A segunda preparação é a de uma nova descamação para a retirada de carepa da superfície do esboço, usualmente referida como descamação secundária.

A etapa seguinte é a da laminação de tiras a quente, sendo a configuração mais comum do LTQ (*HSM = Hot Strip Mill; FM = Finishing Mill*) a de um laminador contínuo, de 6 a 7 cadeiras quádruas, cada uma delas com um conjunto cilindros de trabalho e encosto, superiores e inferiores. A função dos cilindros de trabalho é a de conformar o material, reduzindo sua espessura no passe, e receber o torque e rotação dos motores de acionamento, transferindo assim movimento à tira. A função dos cilindros de encosto é a de transferir a força de laminação aplicada em seus mancais, ao corpo dos cilindros de trabalho, ao mesmo tempo restringindo a flexão dos mesmos, de menor diâmetro. A Figura 4.6 a seguir mostra o aspecto de um LTQ.





Figura 4.6 – Laminador de Tiras a Quente (LTQ 1) da COSIPA, de 6 cadeiras quádruas-contínuas: perspectiva a partir das cadeiras iniciais, com os cilindros de trabalho reserva posicionados em frente ao laminador, para a próxima troca rápida, ao final de um programa de laminação.


A Figura 4.7 mostra configurações frontais de cadeiras redutoras ou iniciais, e de cadeiras acabadoras ou finais do LTQ.

Cadeira iniciais (F1 - F4) do LTQ, de menor velocidade e maior torque



(a)

Cadeiras finais (F5 - F6, F7) do LTQ, de maior velocidade e menor torque



(b)

Figura 4.7 – Exemplo da configuração das cadeiras do LTQ: (a) cadeiras iniciais F1 a F4, com maior potência, maior torque e menor velocidade; (b) cadeiras finais, F5 e F6 (F7), de menor potência, menor torque e maior velocidade.

A redução da espessura da tira em cada passe de laminação envolve duas etapas distintas de ajuste do *gap* e velocidade. A primeira delas é o pré-ajuste necessário para o início da tira, o que decorre da previsão fornecida pelo cálculo do modelo de *set-up*. Uma vez laminada a região inicial de *set-up*, na ponta da tira, dados reais de processo passam a ser captados, como o da força de laminação medida por células de carga em cada cadeira e espessura real medida por equipamento de raio-x na saída do laminador. A partir desse instante e com base nos dados reais captados pelos medidores, passa a funcionar o controle dinâmico do laminador, que automaticamente ajusta o *gap* e velocidade dos cilindros de forma a manter constantes a espessura visada, e o fluxo de massa que garanta a estabilidade operacional do laminador e qualidade da tira (espessura, largura, temperatura). A Figura 4.8 exemplifica uma malha de controle dinâmico, responsável pelo ajuste contínuo do laminador durante a laminação da tira no LTQ.




Figura 4.8 – Configuração simplificada uma malha de controle dinâmico do LTQ. O principais controles são: APC = *Automátic Positioning Control* (*gap*); ASR = *Automátic Speed Control* (*velocidade*); LPC = *Looper Control* (*fluxo de massa*). Demais siglas das são funções específicas do AGC (*Automatic Gage Control*) para controle cruzado da espessura da tira, ao longo do comprimento da tira.

Assim como a informação de *set-up* (*gap* e velocidade de cilindros) das cadeiras do LTQ, as temperaturas de processo são importantes parâmetros de laminação. Entre as temperaturas do material medidas por pirômetros ao longo da linha, a temperatura de entrada na zona do LTQ (T_E = temperatura de entrada) e de saída do laminador (T_A = temperatura de acabamento) são fundamentais para a definição do processo do LTQ, e devem estar de acordo com as limitações de potência e velocidade do laminador, bem como atender os requisitos metalúrgicos do projeto do material laminado. Usualmente, a T_A fica acima da temperatura de transformação de fase T_{AR3} do aço, a partir da qual, com o decréscimo de temperatura, ocorre a transformação do constituinte austenita (γ) em ferrita (α) e perlita, considerando os aços C-Mn comuns, o que caracteriza a laminação com sendo austenítica. Porém nas laminações ferríticas, menos comuns, a T_E é especificada já abaixo da T_{AR3} , com a laminação ocorrendo abaixo da temperatura de transformação do aço (GINZBURG, 1989) (HONEYCOMBE, 1985) (PLAUT, 1986) (ROBERTS, 1983).

Seguido ao processo de laminação, ocorre o resfriamento do material no Sistema de Resfriamento de Tira, composto de vários bancos de resfriamento. O projeto mais comum de cada uma desses bancos é o de um conjunto de coletores, por sua vez dotados de vários tubos que fornecem um fluxo contínuo de água, em regime laminar, sobre a superfície superior da tira, que se movimenta do LTQ para as bobinadeiras, sobre uma mesa de rolos. A face inferior da tira é resfriada por coletores dotados de bicos de jatos de água. O processo de resfriamento da tira desde a temperatura T_A , de saída do LTQ, até a temperatura de bobinamento (T_B), medida na saída do sistema de resfriamento, bem como o perfil desse resfriamento e sua taxa, definem as propriedades metalúrgicas e mecânicas finais da tira laminada a quente (BRANCO, 2004).

Sistemas de resfriamento de tira são controlados por modelos de *set-up*, e de controle dinâmico *feedforward* baseado na medição da TA, e de *feedback*, baseado na medição da TB. A função desses modelos é determinar e ajustar continuamente o padrão de abertura e fechamento do fluxo de água de bancos de resfriamento ao longo do comprimento da tira, de forma a se obter o valor de TB e curva de resfriamento dentro de tolerâncias especificadas. A Figura 4.9 mostra o conceito e o aspecto de um sistema de resfriamento.




Figura 4.9 – Sistema de resfriamento de tiras a quente: (a) conceito e objetivo; (b) aspecto de um sistema real.

O último processo por que passa o material na linha do LTQ é o de bobinamento, no qual a tira é enrolada sobre mandris que expandem durante o bobinamento para segurar a bobina em formação, e se retraem ao final do processo, para permitir a liberação da bobina já formada. Tais bobinas são transferidas então da zona das bobinadeiras para pátios de estocagem de bobinas de onde seguem diretamente para clientes externos, como produto acabado, ou para clientes internos, para sofrer novos processamentos. A Figura 4.10 mostra a foto de uma bobinadeira, como ilustração.




Figura 4.10 – Exemplo de bobinadeira, equipamento que tem por objetivo a formação de bobinas da tira laminada a quente.

Uma vez completado o processo de bobinamento, são obtidas as bobinas de tiras laminadas a quente, com peso de 12 a 40 toneladas, de espessuras que variam tipicamente de 1.2 a 25 mm e larguras de 600 a 2100 mm, valores esses tomados apenas como referências, e que variam de acordo com a capacidade dos equipamentos da linha.

A inspeção da superfície da tira laminada ocorre logo antes do seu bobinamento, através de equipamento automático de inspeção superficial, de todas as tiras produzidas, ou logo após a formação da bobina, por amostragem, desenrolando um trecho da bobina selecionada para a inspeção visual por inspetores treinados.

A linha de laminação de tiras a quente da COSIPA é uma linha com partida na década de 1960, com capacidade de produção de 2,2 milhões de toneladas por ano. Desde o ano de 2001 conta com atualização tecnológica do seu sistema de automação, envolvendo principalmente a utilização de modelos matemáticos de cálculo de *set-up* e novos sistemas de controle dinâmico no LTQ e Sistema de Resfriamento de Tiras, sendo este último totalmente renovado também com a montagem de um novo projeto mecânico. No Apêndice D são mostrados o *layout*, características principais dos equipamentos e especificações gerais dos materiais produzidos na linha do LTQ número 1 da COSIPA.

4.2 Conceitos básicos das principais variáveis do passe de laminação

Embora não seja um objetivo desta seção fornecer uma descrição profunda e abrangente das complexas relações das variáveis de processo envolvidas na laminação de tiras a quente, é necessário, para uma melhor compreensão dos desenvolvimentos das aplicações de RNA's descritas nos próximos capítulos, mostrar conceitos básicos sobre o tema.

A vasta literatura disponível em geral aborda o assunto da laminação a quente sob duas perspectivas. A primeira delas diz respeito aos fenômenos que ocorrem na estrutura metalúrgica do material laminado. A segunda descreve as solicitações mecânicas e térmicas envolvidas na conformação da tira no passe de laminação, com a redução de sua espessura. A metalurgia mecânica é o campo que faz a ligação entre as duas abordagens. A Figura 4.11 serve para ilustrar o conceito.




Figura 4.11 – Resumo das solicitações de processo na laminação a quente e o seu resultado. O aquecimento ocorre nos fornos de rea aquecimento de placas; a deformação ou redução de espessura ocorre nas cadeiras dos laminadores e o resfriamento forçado do material, para a transformação de fase $\gamma \rightarrow \alpha$ ocorre no sistema de resfriamento de tiras. O conceito é geral refere-se à laminação usual de aços comuns, como os C-Mn.

Aplicações de RNA's a problemas reais acabam por exigir um conhecimento muitas vezes apenas básico do processo, no sentido de definir de forma adequada as variáveis de entrada (*inputs*) e de saída (*output*) da rede. Novamente, isso pode ser encarado como uma "maldição" ou uma "benesse" das RNA's, dependendo do ponto de vista adotado. Por isso, de uma forma bastante prática, nesta seção apenas conceitos básicos de laminação de tiras a quente são apresentados, de forma suficiente ao entendimento dessas aplicações. Informações detalhadas e estendidas sobre a origem das equações e suas variações podem ser obtidas em textos especializados de laminação listados na seção de referências bibliográficas. Assim, uma geometria simplificada do passe de laminação é mostrada na Figura 4.12.





Figura 4.12 – Configuração geométrica simplificada do passe de laminação e parâmetros básicos (reduções, comprimento e ângulo de contato).

Com a figura apresentada, definem-se parâmetros básicos do passe de laminação, como os das reduções absoluta, convencional e verdadeira, ângulo e comprimento de contato.

Da mesma forma, a Figura 4.13 mostra o conceito de ponto neutro e deslizamento relativo entre cilindro e tira laminada, bem como a equação de equilíbrio de forças, expressa através da pressão de laminação, que é igual à força dividida pela área do contato (largura da tira multiplicada pelo comprimento de contato).



α_N = ângulo neutro, tal que $0 \leq \alpha_x \leq \alpha$;
 Para $\alpha_x < \alpha_N$ $V_{material} < V_{cilindro}$
 Para $\alpha_x = \alpha_N$ $V_{material} = V_{cilindro}$
 Para $\alpha_x > \alpha_N$ $V_{material} > V_{cilindro}$
 h_N = espessura no ponto neutro
 p_x = pressão em um ponto x do arco de contato
 τ_x = tensão de atrito oposta ao movimento relativo material x cilindro
 T_{re} , T_{av} = tensões devido às forças de tração à ré e à vante

$$\int_0^{\alpha} p_x \sin \alpha_x R d\alpha_x = \int_{\alpha_N}^{\alpha} \tau_x \cos \alpha_x R d\alpha_x - \int_0^{\alpha_N} \tau_x \cos \alpha_x R d\alpha_x + \left(\frac{T_{av} - T_{re}}{2b} \right)$$

Figura 4.13 – Diagrama de aplicação de pressão de laminação, conceito de deslizamento relativo entre cilindro e tira, ponto neutro, e equação de equilíbrio de forças no passe de laminação.

Com base nas duas últimas figuras apresentadas, a Tabela 4.2, a seguir mostra de forma seqüencial e resumida, outros parâmetros ou variáveis de processo do passe de redução de espessura, já direcionadas ao caso da laminação de tiras a quente.

Tabela 4.2 – Lista de variáveis do passe de laminação de tiras a quente e respectivas expressões de cálculo. Baseada e adaptada de várias referências (HELMAN, 1983) (GINZBURG, 1989) (PLAUT, 1986), (ROBERTS, 1983) (TSELIKOV, 1967 e 1980)

Variável	Unidade	Equação
1. Redução absoluta (Δh)	mm	$\Delta h = h_i - h_f$
2. Ângulo de contato (α)	rad	$\alpha = \sqrt{\frac{\Delta h}{R_{ach}}}$
3. Comprimento de contato (L)	mm	$L = \sqrt{R_{ach} \cdot \Delta h}$
4. Redução convencional (r)	-----	$r = \frac{\Delta h}{h_i} = 1 - \frac{h_f}{h_i}$
5. Redução verdadeira (ε)	-----	$\varepsilon = Ln\left(\frac{h_i}{h_f}\right) = Ln\left(\frac{1}{1-r}\right)$
6. Velocidade periférica dos cilindros (v_p)	m/min	$v_p = \frac{\pi \cdot (2 \cdot R) \cdot n}{1000}$, sendo n = velocidade de rotação dos cilindros (rpm), R = raio dos cilindros de trabalho
7. Velocidade do material laminado (v_M)	m/min	$v_M = v_p \cdot (1 + f)$
8. Fator de deslizamento (f)	-----	f = função ($h_i, h_f, R, \text{atrito}$), e depende da teoria adotada. Como exemplo, empiricamente: $f = (a_{f1} \cdot r^2 + a_{f2} \cdot r + a_{f3}) + (b_{f1} \cdot r^2 + b_{f2} \cdot r + b_{f3}) \cdot \sqrt{\frac{h_f}{R}}$ onde a_{fi} e b_{fi} são constantes empíricas
9. Espessura ao longo do arco de contato (h_x)	mm	$h_x = h_f + 2 \cdot R \cdot (1 - \cos(\alpha_x))$, com $0 \leq \alpha_x \leq \alpha$
10. Definição de ponto neutro	-----	Define-se ponto neutro como sendo o ponto no arco de contato, com posição angular $\alpha_x = \alpha_N$, tal que a velocidade do material (v_M) em relação à do cilindro v_p é: $\alpha_x < \alpha_N \rightarrow v_M < v_p$ deslizamento a ré (backward slip) $\alpha_x = \alpha_N \rightarrow v_M = v_p$ $\alpha_x > \alpha_N \rightarrow v_M > v_p$ deslizamento a vante (forward slip)
11. Espessura no ponto neutro (h_N)	mm	$h_N = h_f + 2 \cdot R \cdot (1 - \cos(\alpha_N))$, onde α_N é obtido igualando-se a equação de pressão de laminação anterior ao ponto de aplicação da força com a pressão de laminação adiante ao ponto de aplicação da força (saída do passe).
12. Condição de estabilidade de fluxo de massa entre cadeiras	-----	Formulação básica: $(v_M \cdot h_f)_{CAD} = (v_p \cdot h_N)_{CAD} = \text{constante}$
13. Velocidade ou taxa de deformação ($\dot{\varepsilon}$)	s ⁻¹	$\dot{\varepsilon} = \frac{\partial \varepsilon}{\partial t} = \frac{1}{h} \cdot \frac{dh}{dt} = \frac{v_y}{h}$, e que depende da teoria adotada. Por exemplo, para atrito de agarramento, comum na laminação a quente, a taxa de deformação média é dada por:

Variável	Unidade	Equação
		$\dot{\varepsilon} = \frac{v_p \cdot \varepsilon}{\sqrt{R \cdot \Delta h}}$
14. Raio achatado (R_{ach})	mm	$R_{ach} = R \cdot \left(1 + \frac{16 \cdot (1 - \nu^2)}{\pi \cdot E} \cdot \frac{F}{L_{arg} \cdot \Delta h} \right)$, sendo ν = coeficiente de Poisson; E = módulo de elasticidade, ambos do material do cilindro de laminação.
15. Força de laminação (F)	Tf	$F = \sigma_{LAM} \cdot L_{arg} \cdot L \cdot Q$ Sendo o fator de correção Q = função(h_i, h_f, R, atrito), e que depende da teoria adotada. Por exemplo, empiricamente: $Q = q_1(r) + q_2(r) \cdot \sqrt{\frac{R_{ach}}{h_f}}$, sendo q_1 e q_2 funções empíricas da redução convencional r . Para outras abordagens mais conhecidas, ver referências listadas na bibliografia, especialmente as equações de Sims e Ekelund, entre outros.
16. Tensão de escoamento a quente de laminação (TEQ)	Kgf/mm ²	$TEQ = \sigma_{LAM} = \frac{2}{\sqrt{3}} \cdot \sigma_{UNIX}$, sendo σ_{UNIX} a tensão de escoamento a quente uniaxial, dada por expressões ajustadas empiricamente a partir de resultados de ensaios de tração ou torção a quente, ou dados industriais. Uma abordagem típica para aços pode ser exemplificada pela seqüência de expressões abaixo: $\sigma_{UNIX} = k_T \cdot k_\varepsilon \cdot k_\bullet \cdot k_{CQ}$, onde $k_T = \exp\left(\rho(C) + \frac{a_{k2}}{T_{k2}}\right)$, é a influência da temperatura absoluta $T_{k2} = \theta_{k2} + 273$, sendo θ_{k2} a temperatura do material $k_\varepsilon = \varepsilon^{ak3}$, é a influência da deformação verdadeira $k_\bullet = \left(\dot{\varepsilon}\right)^{ak4}$, é a influência da taxa de deformação $k_{CQ} = \text{função}(C, Mn, Si, Ni, Cr, Cu, Nb, Ti, V, Mo, Bo, etc.)$, é uma função empírica dos teores dos elementos químicos definidores do aço (MISAKA, et al, 1967) (SHIDA, 1969) (MURAO, et al 1996).
17. Força específica de laminação (FW)	Tf/mm	$FW = \frac{F}{L_{arg}} = TEQ \cdot \sqrt{R_{ach} \cdot (h_i - h_f)} \cdot Q$
18. Gap ou abertura entre cilindros (g)	mm	Formulação básica: $g = h_f - \frac{F}{M}$ onde M = módulo de rigidez da cadeira, coeficiente angular da parte reta da relação empírica Força x gap, da cadeira.

Variável	Unidade	Equação
		<i>Nota: em modelos aplicáveis à processos industriais, são adicionados à formulação básica do gap contribuições da expansão térmica e desgaste dos cilindros, expansão térmica do material laminado, flexão de cilindros devido à aplicação de força de bender, e da espessura de filme de óleo dos mancais de encosto. Deve ainda ser considerada a influência da largura do material no módulo de rigidez.</i> <i>O gap final é relativo à posição dos cilindros no instante da calibração ("zeragem") da cadeira, usualmente feita com uma carga de referência, sendo usual por exemplo a força de 1000 Tf.</i>

Entre os conceitos listados na Tabela 4.2, estão os dos parâmetros que serão objeto da aplicação das redes neurais, ou seja, respectivamente a tensão de escoamento a quente (TEQ, item 15) do material laminado e a força específica de laminação (FW, item 16).

Embora o resumo apresentado na tabela seja suficiente para as necessidades conceituais desse trabalho, cabe porém ressaltar que as simplificações e descrições mostradas não mostram toda a abrangência do assunto, *obviamente bem mais vasto e sofisticado do que descrito nos tópicos listados*.

Uma observação complementar, é a de que embora modelos de cálculo de tiras a quente calculem a força de laminação e a velocidade do material, o *set-up* efetivamente é o conjunto de parâmetros de *gap* (item 18) e velocidade dos cilindros (itens 6,7 e 8). Na prática industrial a esse conceito restrito de *set-up* é ampliado, considerando-se a adição de outras variáveis como as de abertura das guardas entre cadeiras, ângulos e ganhos de *loopers*, pressões e vazões de coletores de refrigeração entre cadeiras (*inter-stand cooling*), parâmetros e ganhos de controles dinâmicos, como os de AGC, parâmetros e ganhos de adaptação ou aprendizado (*learning*), entre outros.

4.4 Considerações sobre modelos de cálculo de *set-up* do LTQ

Modelos de controle de *set-up* de Laminadores de Tiras a Quente devem possuir um algoritmo de controle implementado sob a forma de um programa ou *software*, suportado por equipamentos de automação ou *hardware* adequados.

As variações do algoritmo de controle de *set-up* são tantas quanto o número de LTQ's em operação. Para exemplificar o assunto, o modo de funcionamento de um desses algoritmos é mostrado a seguir, na Figura 4.14, na forma de diagrama esquemático de um modelo de cálculo de *set-up* de LTQ.




Figura 4.14 – Exemplo de configuração de um modelo de cálculo de *set-up* do LTQ (MURAO, et al).

Nesse modelo, a referência de *set-up* é determinada para todas as cadeiras do LTQ, antes da chegada do material à primeira cadeira, com um cálculo inicial realizado na saída do laminador RM, e que é atualizado com a chegada do esboço na zona do LTQ, e a medição e definição da temperatura de entrada (TE) do esboço a ser laminado.

Na etapa do esquema de reduções das cadeiras, é sempre realizada a verificação se o mesmo respeita limites do equipamento, como os de força, potência e velocidade de cada cadeira.

Uma vez definido o esquema de reduções, é realizada a definição do *set-up* final das cadeiras, com base no resultado de cálculo do modelo e seleção de parâmetros armazenados em tabelas de *hierárquicas*.

Com o controle *feedforward*, após a laminação da ponta inicial da tira nas primeiras cadeiras, o *set-up* das últimas cadeiras é atualizado para a tira em laminação, considerando os dados reais obtidos nas cadeiras iniciais.

Uma vez realizada a laminação da tira e obtido todos os dados reais desse processo, o controle adaptativo (*learning*) ajusta parâmetros das equações do *FSU* a serem aplicadas no cálculo de *set-up* da tira seguinte, *de mesma hierarquia*.

Entende-se por *hierarquia*, um conjunto de propriedades que definem um lote de material de características similares, por exemplo, dentro de uma faixa de resistência à quente (*steel grade*), faixa dimensional de espessura e largura do produto, e mesmo faixa de temperaturas de processo, em alguns casos. Com isso, tanto parâmetros das equações do modelo, assim como ganhos de controles dinâmicos e parâmetros de adaptação podem ser armazenados de forma tabelada. A cada laminação de uma tira, o modelo é alimentado com os parâmetros diferenciados e armazenados da hierarquia correspondente.

A performance do modelo de controle de *set-up* do LTQ é avaliada tanto com base no atendimento das características do produto obtido, como sua espessura, largura e temperatura de processo, como também pela estabilidade operacional conseguida.

5 Condições Gerais de Coleta e Seleção dos Dados das Variáveis Processo

5.1 Introdução

É bastante relevante considerar que os dados de entrada (*inputs*) e também os de alvo (*targets*), utilizados para o treinamento e validação das RNA's, no caso desse trabalho, são de origem industrial, e não laboratorial.

Assim, inconsistência de dados pode ocorrer devido a vários fatores como erros e ruídos de medição de instrumentos de campo, erros na gravação *on-line* (automática) dos dados ou na sua digitação manual, erros no tratamento dos dados, intervenção manual do operador do equipamento, operação fora do padrão usual de processo (por exemplo, com uma ou mais cadeiras fora de operação), e outros fatores desconhecidos.

Por outro lado, dados industriais usualmente ficam disponibilizados em grande número de casos, contrapondo assim às fontes de erro citadas a força do tamanho do lote e sua tendência majoritária.

5.2 Coleta e base de dados

As informações necessárias ao trabalho foram coletadas em tempo real para todas as tiras laminadas, e armazenadas em tabelas de bancos de dados relacionais de nível-2 (*Oracle Database*) do sistema de automação do LTQ da COSIPA.

Tais informações corresponderam tanto a dados pré-calculados pelo modelo matemático de *set-up* do LTQ (*Finishing Mill Set-Up Calculation Model – FSU*), como também a valores reais medidos por instrumentos de campo, ou a valores reversamente pós-calculados a partir de dados reais diretamente medidos.

Para os dados de *set-up*, do qual foram extraídos os casos dos *inputs* das RNA's, foram utilizadas duas tabelas: uma com respectivamente mais de 800 campos para dados por cadeira, sendo exemplos as variáveis de força e resistência de laminação; e outra com mais de 300 campos para dados gerais, sendo exemplo desse tipo de dado a composição química do aço e as dimensões do material.

Essas tabelas englobam a maior parte das variáveis manipuladas pelo modelo de *FSU*, e relacionam-se entre si através do código ou número da bobina produzida, e do instante de sua laminação, o que garante a rastreabilidade das informações.

5.3 Definição da região de coleta de dados na tira laminada a quente

Os valores reais *same-point* de cada variável são coletados na mesma região sob controle do *set-up*, na ponta inicial da tira, definida segundo a seguinte regra geral: 0.5 s após a mordida da tira pelos cilindros, 5 são pontos medidos a cada 0.2 s, num período total de 1 s, sendo 2 valores, respectivamente mínimo e máximo, descartados. A média dos pontos restantes fornecem o valor real do parâmetro medido.

A tomada de dados reais, *same-point*, ocorre assim antes da ação dos sistemas de controle dinâmico (nível-1, a partir do *feedback* de dados reais) que executam a correção automática do *gap* (*Automatic Gage Control – AGC*), da velocidade dos cilindros (*Automatic Speed Regulator – ASR*) e do controle do fluxo de massa entre cadeiras (*Looper Process Control – LPC*), e que assumem o controle do processo ao longo do restante do comprimento da tira, imediatamente após a região de *set-up*, conforme visto na seção 3.1.

Essa rotina está consolidada e incorporada nos sistemas de nível-1 e nível-2 de automação do laminador, e atende à necessidade de obtenção de dados reais para comparação com os dados calculados, permitindo assim a execução da adaptação (*learning*) do modelo matemático de *set-up* (*FSU*) do laminador.

5.4 Condições gerais de coleta e seleção dos dados

Os dados selecionados para uso, foram objeto de várias verificações das condições de processamento, visando sua validação, em sintonia com o objetivo do trabalho.

- Dados obtidos com operação normal dos instrumentos de medição aferidos e etiquetados, dentro do prazo previsto pelo sistema de garantia de qualidade da empresa, sem a ocorrência de qualquer anormalidade registrada ou percebida nesses instrumentos.

- Dados obtidos nas faixas usuais de temperaturas de processo, medidas na entrada e saída do LTQ, dentro ou muito próximas às faixas de valores programados.
- Excluídos dados de materiais que por opção operacional tenham sido laminados sem atualização do *set-up* causada por eventual falha de *tracking*, ainda que com resultados satisfatórios.
- Dados obtidos sob modo de operação automática do LTQ, ou seja, com *set-up* calculado pelo FSU em nível-2, e executado através do nível-1 nas cadeiras do laminador.
- Dados coletados *on-line* de forma automática, e armazenados nas tabelas de dados do nível-2 do sistema de automação do LTQ, sem nenhum registro manual.
- Operação sem intervenção do operador no *gap* das cadeiras do LTQ, exceto para nivelamento dos cilindros, operação esta totalmente manual.
- Intervenção do operador nos sucessivos de ajuste fino de velocidade das cadeiras não ocorre antes da mordida e na região do *set-up*, não influenciando o resultado.
- Zeragens e calibrações atualizadas em todas as cadeiras de forma automática, a cada troca de cilindros, sem nenhuma anormalidade.
- Dados de todas as seis cadeiras do LTQ expurgados em casos de ocorrência de desvio de força acima de $\pm 15\%$, em pelo menos uma das cadeiras. Isso correspondeu a menos de 1.5% dos dados, concentrados principalmente na cadeira F1. As causas mais comuns dessa fonte de erro são usualmente: (a) interferência de carepa (óxido de ferro) formada na superfície do esboço na medição de temperatura de entrada do LTQ, por alguma deficiência dos processos de descarepação; (b) desvio da espessura calculada em relação à espessura real do esboço, na entrada do LTQ, por provável deficiência da zeragem nas cadeiras esboçadoras (*roughing mills*); (c) alguma variação de composição química da placa. Dessa forma buscou-se minimizar a influência de *outliers* no universo de dados.
- Laminação apenas de material liso (*smooth material*), não sendo considerada a laminação de material destinado a chapas de piso (*floor plate*), tiras estas com superfície superior não lisa e com relevo anti-aderente.

- Operação com todas as cadeiras do LTQ, sem ocorrência de qualquer cadeira fora de operação, quer isto ocorresse de forma programada ou não (*dummy stand*).

- Para o LTQ do qual foram obtidos os conjuntos de dados, acima de 7.5 mm de espessura de tira a laminação é praticada com apenas com 5 das 6 cadeiras do laminador, evitando-se dessa forma trabalhar dentro da região de acomodação de folgas na curva de rigidez das cadeiras. Por esse motivo, neste trabalho inicial, optou-se por se considerar a laminação de materiais de espessura máxima igual a 7.5 mm, o que corresponde a mais de 97% do mix normal de produção atual.

- Temperaturas de laminação dentro da na zona austenítica dos aços, acima da temperatura de início de transformação de fase T_{AR3} , ou pelo menos não significativamente distantes dessa zona, dessa forma excluindo-se por exemplo aços de grão não orientado (GNO) destinados a fins elétricos, se laminados no LTQ na com temperaturas de zona ferrítica (HONEYCOMBE, 1985).

- Dentro do objetivo proposto e que visa a laminação de material C-Mn comuns, os elementos químicos dos aços dos conjuntos de dados, tiveram seu teor restringido segundo as seguintes regras gerais:

⇒ Teor mínimo de carbono: $C > 0.01\%$, o que exclui aços do tipo ULC (*Ultra Low Carbon*), do tipo IF (*Interstitial Free*) e GNO (Grão Não Orientado) (HONEYCOMBE, 1985).

⇒ Quantidade máxima de elementos microligantes Nióbio, Titânio e Vanádio: $Nb + Ti + V < 0.010\%$, excluindo-se dessa forma aços microligados destinados a tubos (alguns tipos de aços API) e aços para componentes estruturais de maior resistência, como longarinas (do tipo de norma LN). Tais aços apresentam maior complexidade nos fenômenos metalúrgicos relacionados ao amaciamento térmico (recuperação, recristalização) e encruamento (precipitação de partículas, não recristalização), durante a laminação, e que têm influência diferenciada na resistência a quente e na força de laminação (BRANCO, 2004) (GORNÍ, et al, 2001 e 2004) (JONAS, 2005) (SICILIANO, et al, 1996 e 2000) (MACCANO, et al, 1994).

⇒ Quantidade máxima de Silício: $Si \leq 0.80\%$, evitando-se aços com TAR_3 muito elevada, com laminação austenítica nas cadeiras iniciais, porém tendendo a ser ferrítica nas cadeiras finais. Tais aços são usualmente destinados a aplicações estruturais, resistentes à corrosão (GORNÍ, et al, 2007).

5.5 Lista geral das variáveis de processo da base de dados utilizada

Neste trabalho define-se caso como sendo um conjunto ou vetor de dados das variáveis de processo, relacionado à laminação de uma tira no LTQ. Cada caso é assim um exemplo a ser apresentado à RNA, a cada iteração durante o seu treinamento.

Cada caso conta com informações sobre dois tipos de conjuntos de variáveis. O tipo 1 relaciona-se com o material laminado, por exemplo, a composição química do aço, a temperatura de entrada no LTQ. O tipo 2 é característico da cadeira de laminação, como a força e a temperatura do material no passe da cadeira.

No Apêndice E, é mostrada a lista geral todas variáveis da tabela de casos formada a partir da base de dados de nível-2. Nela já aparece a indicação de variável de entrada (*input*) ou variável alvo (*target*) para as RNA's de tensão de escoamento a quente (TEQ) e de força específica (FW). Os capítulos referentes às aplicações de RNA's mostram em detalhe as justificativas para a seleção de variáveis das redes. No Apêndice F é disponibilizado um resumo estatístico dos valores das mesmas variáveis da base de dados.

5.6 Características do mix de bobinas da base de dados utilizada

A Tabela 5.1 mostra distribuições da quantidade de bobinas e da sua participação por classe de espessura, classe de largura, e classe de teor de carbono equivalente (CEQ). Como já mencionado, no mix de aços C-Mn, o teor somado dos microligantes Nb, Ti e V é inferior a 0.10%, portanto não merecendo estratificação.

Tabela 5.1 – Características do mix de bobinas cujos dados foram utilizados na elaboração das RNA's, por classe dimensional, de teor de Carbono Equivalente (CEQ): (a) distribuição do número de bobinas; (b) distribuição da participação relativa.

Quantidade de bobinas		Classe de Largura (mm)			Largura TOTAL
Classe de Espessura (mm)	Classe de CEQ (%)	(1) Larg < 1140	(2) 1140 <= Larg < 1380	(3) Larg >= 1380	
(1) Esp < 2.91	(1) CEQ < 0.19%	1086	1717	81	2884
	(2) CEQ >= 0.19%	172	285	17	474
(2) 2.91 <= Esp < 4.61	(1) CEQ < 0.19%	669	1701	225	2595
	(2) CEQ >= 0.19%	120	336	33	489
(3) Esp >= 4.61	(1) CEQ < 0.19%	151	300	81	532
	(2) CEQ >= 0.19%	67	260	171	498
Espessura Total		2265	4599	608	7472

(a)

Mix de bobinas		Classe de Largura (mm)			Largura TOTAL
Classe de Espessura (mm)	Classe de CEQ (%)	(1) Larg < 1140	(2) 1140 <= Larg < 1380	(3) Larg >= 1380	
(1) Esp < 2.91	(1) CEQ < 0.19%	14.53%	22.98%	1.08%	38.60%
	(2) CEQ >= 0.19%	2.30%	3.81%	0.23%	6.34%
(2) 2.91 <= Esp < 4.61	(1) CEQ < 0.19%	8.95%	22.76%	3.01%	34.73%
	(2) CEQ >= 0.19%	1.61%	4.50%	0.44%	6.54%
(3) Esp >= 4.61	(1) CEQ < 0.19%	2.02%	4.01%	1.08%	7.12%
	(2) CEQ >= 0.19%	0.90%	3.48%	2.29%	6.66%
Espessura Total		30.31%	61.55%	8.14%	100.00%

Nota: CEQ = C + (Mn/2) + (Si/24); com teores em (%)

(b)

As classes mais freqüentes no mix correspondem assim a:

- Espessura menor que 2.91 mm 44.94%
- Espessura entre 2.91 e 4.61 mm 41.27%
- Largura entre 1140 e e 1380 mm 61.55%
- CEQ abaixo de 0.19% 80.45%

O limite de CEQ escolhido, da ordem de 0.19%, corresponde a aproximadamente uma divisão entre aços considerados de baixa resistência (BR), e os de média (MR) a alta resistência (AR), no caso de aços C-Mn comuns. Tal conceito *não leva em conta considerações sobre a potência disponível do laminador.*

5.7 Características das variáveis relacionadas com a cadeira do LTQ

Da mesma forma como foi analisado o mix de material, variáveis de tipo 1, relacionadas ao material laminado, pode-se ter uma idéia da magnitude de algumas variáveis de tipo 2 da base de dados, estas atreladas à cadeira do LTQ, como definido. Assim, para o mix em questão, a Tabela 5.2 mostra valores médios por cadeira de algumas variáveis mais relevantes.

Tabela 5.2 – Valores médios reais de algumas variáveis de processo por cadeira do LTQ, relacionadas às bobinas do mix utilizado para elaboração das RNA's. As variáveis TEQ e FW são *targets* das RNA's de TEQ e FW. A dimensão média das bobinas é 3.303 x 1185.7 mm na saída do laminador.

Variável	Unidade	Temperatura de entrada	Cadeira do LTQ						Temperatura de saída
			F1	F2	F3	F4	F5	F6	
Espessura de entrada	(mm)	-----	30.014	16.649	10.350	6.899	5.035	3.991	-----
Espessura de saída	(mm)	-----	16.649	10.350	6.899	5.035	3.991	3.361	-----
Velocidade dos cilindros	(mpm)	-----	63.7	110.1	172.0	247.3	321.7	392.5	-----
Temperatura do material	(oC)	1041.2	966.5	951.2	936.2	921.5	906.7	891.9	869.5
Força de bender	(Tf/mancal)	-----	41.58	38.42	37.40	40.96	36.89	36.03	-----
Tensão de Escoamento a Quente (TEQ)	(kgf/mm ²)	-----	18.4	21.0	23.3	24.9	24.9	23.3	-----
Força de laminação	(Tf)	-----	1618.2	1367.4	1444.6	1210.2	952.3	856.1	-----
Força / Largura (FW)	(Tf/mm)	-----	1.3661	1.1563	1.2205	1.0211	0.8019	0.7220	-----

6 Aplicação de RNA *MFB* na Determinação da Tensão de Escoamento a Quente (TEQ) na Laminação de Tiras a Quente

6.1 Introdução

O conhecimento da resistência à deformação do material expressa pela tensão de escoamento (TEQ) na sua laminação em tiras a quente é básico para as análises prévia ou posterior do processo, visando o aprimoramento de sua produtividade e qualidade.

Mais ainda, é fundamental quando se opera laminadores dotados de sistemas automáticos de cálculo de esquemas de passe, que fornecem valores adequados de abertura (*gap*) e de velocidade dos cilindros, antes da chegada do material ao ponto de sua mordida na cadeira. Ou seja, é uma variável primária para o conhecimento do *set-up*, (*gap* e velocidade de cilindros) de cada cadeira do LTQ, já que a TEQ é uma das variáveis da qual depende a força, e consequentemente a potência necessária para reduzir a espessura do material no passe de laminação, conforme visto na seção 4.2, Tabela onde é descrito o processo de Laminação em Tiras a Quente.

Usualmente, no cálculo dos parâmetros de *set-up* do LTQ são empregados modelos de caráter misto (MISAKA, et al, 1967) (SHIDA, 1969), determinístico e empírico, ou semi-empírico, sendo o da TEQ obtido com o ajuste de dados de laboratório, resultantes de testes de torção a quente ou de laminadores pilotos, ou mesmo com o ajuste de dados reais de laminadores industriais. Tais modelos matemáticos são mais ou menos complexos, quer se considere ou não, por exemplo, aspectos de transformações metalúrgicas do material e da não homogeneidade das condições da deformação ao longo do arco de contato (GORNÍ, et al, 2003, 2005).

Já as aplicações de RNA na previsão da TEQ visam acomodar tanto as não linearidades envolvidas, como a falta de conhecimento total das formas de relação entre todas as variáveis de processo, mantendo-se ainda o resultado dentro do nível de precisão adequado.

O objetivo desse capítulo é mostrar uma aplicação de Rede Neural Artificial (RNA), do tipo *MFB (Multilayer, Feedforward, Backpropagation)*, para cálculo da tensão de escoamento na laminação de tiras a quente (TEQ), de aços planos comuns do tipo C-Mn, treinada e validada a partir de dados industriais relativos à laminação desse tipo de material no Laminador de Tiras a Quente (LTQ) da Companhia Siderúrgica Paulista - COSIPA.

Assim, neste trabalho, a TEQ real, alvo da RNA, é obtida de forma indireta, pós-calculada, a partir, entre outros, do dado de força real medida pela célula de carga da cadeira, na região da ponta inicial da tira (região de *set-up*).

6.2 Seleção das variáveis de entrada e alvo da RNA de TEQ

Neste trabalho, a seleção de variáveis de entrada da RNA contempla as que têm obviamente relação teórica com a TEQ. Porém, de forma intencional, tais variáveis possuem um alto grau de primariedade, evitando-se desta maneira ao máximo a necessidade do pré-processamento delas em outras secundárias para *input* na RNA. Ou seja, com isso evita-se a eventualidade da necessidade de cálculos mais complexos, ou até mesmo a adição de novas variáveis, com informação de muitas vezes de difícil obtenção.

O capítulo 3, no qual é descrito o processo de laminação de tiras a quente, estabelece as definições e relações entre variáveis envolvidas na deformação do material no passe de redução de espessura do material em cada cadeira do LTQ. Esses conceitos e relações serão comentados e utilizados agora para justificar a seleção das variáveis de entrada na RNA.

Assim, resistência à deformação de laminação a quente é definida como sendo algum tipo de função conforme a expressão abaixo:

$$TEQ = função(CQ, \varepsilon, \dot{\varepsilon}, \theta) \quad (6.1)$$

Essa expressão mostra a dependência da TEQ do material, durante a laminação em determinada cadeira do LTQ, com a composição química do aço (CQ em %), com a deformação verdadeira (ε), com a taxa de deformação ($\dot{\varepsilon}$ em s^{-1}), e com a temperatura da tira (θ em $^{\circ}C$) no passe.

Com base nesse modelo de TEQ, podem ser levadas em conta algumas considerações que suportam a seleção das variáveis primárias de processo para alimentação da rede, conforme esquematizado na Figura 6.1.




Figura 6.1 – Esquema da seleção das variáveis de entrada (*inputs*) da RNA de TEQ.

Assim, a primeira consideração diz respeito à composição química do aço (CQ). Tratando-se de aços C-Mn comuns, a escolha dos elementos químicos resulta na seguinte escolha: carbono (C), manganês (Mn), silício (Si), cromo (Cr) e cobre (Cu). Deve ser lembrado o fato que pela definição do tipo de aço C-Mn, elementos microligantes como o nióbio (Nb), titânio (Ti) e vanádio (V), altamente endurecedores a quente, foram limitados a baixos teores, tornando nula ou muito baixa sua influência.

A segunda consideração aborda a deformação verdadeira (ϵ) que ocorre no passe de laminação, reduzindo a espessura de entrada (h_i) para um valor menor (h_f) na saída da cadeira. Ou seja, ela é função dessas duas variáveis primárias que a definem.

O terceiro ponto relaciona-se com a taxa de deformação ($\dot{\epsilon}$), que é função da quantidade de deformação (ϵ) e do tempo (t) gasto para sua realização. Ou seja, também depende das espessuras de entrada e saída do material na cadeira, mas também da variável tempo de passagem do material pela zona de contato. Este tempo por sua vez é função do comprimento do arco de contato na zona de deformação (L) e da velocidade de laminação da tira.

O comprimento de contato é um parâmetro geométrico que depende novamente das espessuras de entrada e saída no passe, e também do *raio achatado* (R_{ach}) dos cilindros. A velocidade de laminação depende da velocidade dos cilindros (v_p), e do deslizamento relativo entre cilindro e tira (f), sendo este último intensamente relacionado com redução de espessura no passe.

Portanto, com boa aproximação, a taxa de deformação ($\dot{\epsilon}$) pode ser considerada fortemente dependente das seguintes variáveis: espessuras de entrada (h_i) e de saída (h_f), velocidade periférica dos cilindros (v_p) e do *raio achatado de cilindros* (R_{ach}).

A última consideração diz respeito à *temperatura de laminação* (θ), que influencia bastante no valor da resistência do aço, reduzindo-a quanto mais alta for o valor de temperatura no passe.

Portanto, pode-se transformar a relação funcional inicial de TEQ em outra mais conveniente para a definição de entradas da RNA, conforme abaixo mostrado:

$$TEQ = função(CQ, \epsilon, \dot{\epsilon}, \theta) \rightarrow TEQ_{RNA} = função(C, Mn, Si, Cr, Mn, R_{ach}, v_p, h_i, h_f, \theta) \quad (6.2)$$

A Tabela 6.1 mostra a lista de variáveis selecionadas para entrada e saída da RNA de TEQ, com respectivos resumos estatísticos.

Tabela 6.1 – Resumo estatístico das variáveis da base de dados original que foram selecionadas para alimentação da RNA de TEQ (*inputs* e *targets*). Variável tipo 1 significa característica do aço; tipo 2 significa característica dependente de uma das 6 cadeiras do LTQ.

Tipo	Descrição	Unidade	Símbolo	Média	Desvio padrão	Mínimo	Máximo	Contagem	TEQ
1	Teor de carbono	(%)	C	0.0718	0.0488	0.0230	0.4810	7472	Input 01
1	Teor de manganês	(%)	Mn	0.3776	0.2175	0.1100	1.6500	7472	Input 02
1	Teor de silício	(%)	Si	0.0415	0.0877	0.0000	0.4300	7472	Input 03
1	Teor de cobre	(%)	Cu	0.0081	0.0202	0.0000	0.2700	7472	Input 04
1	Teor de cromo	(%)	Cr	0.0217	0.0409	0.0100	0.5400	7472	Input 04
2	Raio achatado estimado	(mm)	R_{ach}	372.4	40.24	314.0	507.1	6 x 7472	Input 06
2	Velocidade periférica dos cilindros de trabalho	(mpm)	v_p	217.9	126.0	46.6	548.8	6 x 7472	Input 07
2	Espessura de entrada na cadeira	(mm)	h_i	12.16	9.15	2.30	34.00	6 x 7472	Input 08
2	Espessura de saída da cadeira	(mm)	h_f	7.71	4.87	1.93	21.97	6 x 7472	Input 09
2	Temperatura estimada no passe	(°C)	θ_{EP}	929	26.6	841	1002	6 x 7472	Input 10
2	TENSÃO DE ESCOAMENTO A QUENTE REAL	(Kgf/mm ²)	TEQ_R	22.6	3.00	15.4	33.7	6 x 7472	Target

6.3 Arquitetura da RNA de TEQ

Neste trabalho, por razões de ordem computacional e prática, principalmente relacionadas ao tamanho da rede, a opção é pelo desenvolvimento de seis RNA's *MFB* individuais de TEQ, todas porém de arquitetura e parametrização similares, cada uma delas correspondendo a uma das cadeiras do LTQ, e com uma saída que é a TEQ do passe.

A Figura 6.2 mostra um diagrama de blocos da arquitetura da RNA adotada para cálculo da TEQ. Nos blocos são indicadas as matrizes de entrada (*inputs*) X , *bias* B , pesos W , funções de soma v , funções de ativação ϕ , e de saída (*outputs*) Y , para cada uma das 4 camadas da rede. A matriz X da primeira camada é formada pelo conjunto ou vetor de dados de cada caso. A matriz Y da última camada corresponde à saída ou resposta da rede ao caso ou exemplo apresentado.




Figura 6.2 – Diagrama de blocos da arquitetura da RNA MFB (Multilayer, Feedforward, Backpropagation) utilizada para previsão da TEQ.

A Tabela 6.2 mostra com mais detalhes a arquitetura e parâmetros indexados que compõe a RNA de TEQ, indicando também os *targets* e erro da rede, enquanto a Tabela 6.3 complementa as informações sobre o tamanho da rede.

Tabela 6.2 – Detalhes da arquitetura e parâmetros da RNA *MFB* utilizada na previsão da TEQ.

RNA de RDQ			Entrada	Camada k				Saída
Parâmetro				1	2	3	4	
ENTRADA →	Variável	X_{ijk}	$[X_{i00}] =$ <i>inputs</i>	$[X_{i01}] =$ $[X_{i00}]$	$[X_{i02}] =$ $[Y_{1j1}]$	$[X_{i03}] =$ $[Y_{1j2}]$	$[X_{i04}] =$ $[Y_{1j3}]$	
	Entrada	i	1:10	1:10	1:10	1:25	1:13	
	Neurônio	j	0	1:10	1:25	1:13	1	
BIAS →	Variável	B_{ijk}		$[b_{1j1}]$	$[b_{1j2}]$	$[b_{1j3}]$	$[b_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:10	1:25	1:13	1	
PESOS →	Variável	W_{ijk}		$[w_{ij1}]$	$[w_{ij2}]$	$[w_{ij3}]$	$[w_{ij4}]$	
	Entrada	i		1:10	1:10	1:25	1:13	
	Neurônio	j		1:10	1:25	1:13	1	
FUNÇÃO SOMA →	Variável	$v_{ijk} =$ $\Sigma(b_{ijk} + w_{ijk})$		$[v_{1j1}]$	$[v_{1j2}]$	$[v_{1j3}]$	$[v_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:10	1:25	1:13	1	
FUNÇÃO DE ATIVAÇÃO →	Variável	$\phi_{ijk} =$ $f(v_{ijk})$		$[\phi_{1j1}] =$ $f(v_{1j1})$	$[\phi_{1j2}] =$ $f(v_{1j2})$	$[\phi_{1j3}] =$ $f(v_{1j3})$	$[\phi_{1j4}] =$ $f(v_{1j4})$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:10	1:25	1:13	1	
	Função	f		Tangente sigmóide	Tangente sigmóide	Tangente sigmóide	Linear	
SAÍDA →	Variável	$Y_{ijk} =$ $\phi_{ijk}(v_{ijk})$		$[y_{1j1}] =$ $[\phi_{1j1}(v_{1j1})]$	$[y_{1j2}] =$ $[\phi_{1j2}(v_{1j2})]$	$[y_{1j3}] =$ $[\phi_{1j3}(v_{1j3})]$	$[y_{1j4}] =$ $[\phi_{1j4}(v_{1j4})]$	$[y_{0j0}] =$ $[y_{1j4}]$
	Entrada	i		1	1	1	1	1
	Neurônio	j		1:10	1:25	1:13	1	1
ALVO →	Variável	D_{ijk}						$[d_{0j0}] =$ <i>targets</i>
	Entrada	i						0
	Neurônio	j						1
ERRO →	Variável	E_{ijk}						$[e_{0j0}] =$ $[d_{0j0} - y_{0j0}]$
	Entrada	i						0
	Neurônio	j						1

Tabela 5.3 – Resumo da quantidade de parâmetros da RNA *MFB* utilizada na previsão da TEQ.

Ítem da rede	Entrada	Camadas				Saída	Total
		1	2	3	4		
Input (x)	10	-----	-----	-----	-----	-----	10
Neurônios	-----	10	25	13	1	-----	49
<i>Bias</i> (b)	-----	10	$1 \times 25 = 25$	$1 \times 13 = 13$	1	-----	49
Pesos (w)	-----	$10 \times 10 = 100$	$10 \times 25 = 250$	$25 \times 13 = 325$	$13 \times 1 = 13$	-----	688
Parâmetros livres = Pesos (w) + <i>bias</i> (b)	-----	110	275	338	14	-----	737
Output (y)	-----	-----	-----	-----	-----	1	1

A arquitetura descrita, válida para a RNA de cada uma das cadeiras do LTQ, foi selecionada após várias simulações nas quais se variou o número de camadas e de neurônios por camada, sendo a que, de forma consistente, levou a um menor *MSE*, sem comprometimento do tempo de processamento da rede.

6.4 Treinamento da RNA de TEQ

A etapa de treinamento de uma RNA é importante tanto sobre o aspecto de convergência da busca pelo resultado, nesse caso a TEQ, como também pela rapidez com que se processa essa pesquisa, até que seja obtida a precisão visada, medida pelo seu erro médio quadrático - *MSE*. A generalização da RNA é conseguida através da avaliação de resultados de *MSE* obtidos em cada etapa do treinamento, com a rede sendo aplicada simultaneamente a um lote de validação, conforme descrito no capítulo 3, seção 3.10.

Neste trabalho, opta-se pelo algoritmo de treinamento *Levenberg-Marquardt*, com lote de validação e treinamento. O algoritmo de treinamento *Levenberg-Marquardt*, como mencionado na seção 3.8, é eficiente e adequado para redes de porte pequeno a médio, destinadas ajuste de funções. Parâmetros específicos do algoritmo, listados no Apêndice G, correspondem a valores padrão do software utilizado, comuns para as RNA's de TEQ de todas as cadeiras.

Com relação à partição da quantidade total de casos entre lotes de treino, validação e teste, visa-se atender ao critério descrito na seção 3.10. Nesse caso, a quantidade $(30 \times N_w) = (30 \times 737 \text{ parâmetros livres}) = 22.110$ casos, excede a quantidade de 7098 casos disponíveis para lotes de treino e validação (95% do total de 7.472 casos, com 5% já destinados a lote de teste), o que determina a escolha do método não assintótico e a necessidade do lote de validação.

Para a determinação da partição de lote de treino e validação, a partir da expressão 3.29, obtêm-se a porcentagem máxima do lote de treinamento da ordem de 97.5% da quantidade de casos destinada a treino e validação.

Assim, partição final adotada é a de 90% dos casos destinados a lote de treino, 5% destinados a lote de validação e 5% a lote de teste.

Para que o perfil do mix de informações de alimentação e resposta da rede fosse o mesmo para cada lote, a seqüência de seleção dos casos para compor os lotes de treino, validação e teste, foi tornada propositalmente aleatória.

6.5 Determinação da temperatura da tira no passe de laminação

No item 6.2 foi definido o conjunto de variáveis de entrada e a de saída da RNA de TEQ. As variáveis de entrada são extremamente primárias e de fácil obtenção, com exceção da *temperatura no passe de laminação* (θ) e do *raio achatado de cilindros* (R_{ach}).

A temperatura no passe de laminação de cada cadeira do LTQ (T_{RP}) é uma informação que pode ser considerada não primária, já que sua determinação prévia envolve a manipulação de modelos físicos de transferência de calor que forneçam a evolução de temperatura do material desde a entrada até a saída do laminador.

Tais modelos envolvem a transferência de calor com o material em regiões distintas da zona do laminador em que a tira esteja em contato com: (a) ar na entrada, entre cadeiras e saída do laminador; (b) água, seja do processo de remoção de carepa (*descalling*) do esboço na entrada do LTQ, de refrigeração da tira entre cadeiras (*inter-stand cooling*), de resfriamento por canhões limpa-tiras na saída das cadeiras (*side-spray*) e mesmo água residual do sistema de refrigeração de cilindros (*roll cooling*) caindo sobre a tira, entre outros; (c) cilindros de trabalho (*work rolls*), sendo que neste caso deve ser considerada a perda de temperatura pela transferência de calor por condução da tira para o cilindro, mas também a do calor gerado pela deformação plástica e pelo atrito entre cilindro e tira no passe (. Esses modelos de temperatura da tira podem ser mistos ou semi-empíricos, com ou sem utilização de métodos matematicamente mais complexos como os de diferenças finitas ou mesmo elementos finitos (GINZBURG, 1989) (ROBERTS, 1983) (TSELIKOV, 1967 e 1980).

Uma dificuldade adicional reside ainda no fato que certos sub-modelos como os de calor gerado pela deformação plástica, e o de calor gerado pela fricção entre cilindro de tira dependerem também da TEQ, o que dá um caráter recursivo a esse tipo de cálculo.

Para superar essas dificuldades, e atender a proposta inicial do trabalho de aplicação de rede neural para determinação da TEQ, com utilização de variáveis de fácil disponibilidade, foi elaborada uma regressão linear múltipla com variáveis primárias para obtenção de uma estimativa da temperatura da tira no passe de laminação (T_{EP}), como uma alternativa à temperatura real.

A temperatura real (T_{RP}) do material no passe é na verdade o resultado de um recálculo executado pelo modelo de *set-up* (FSU) do LTQ (MURAO, et al, 1996), a partir de dados reais coletados após a passagem da tira pelo laminador, como força, temperaturas de entrada e saída do LTQ, velocidades, reduções, entre outros, já que em nenhuma cadeira é realizada a medição de temperatura da tira durante o passe de laminação.

O modelo simplificado, obtido por regressão linear múltipla (SPIEGEL, 1978), válido para os aços C-Mn, apresenta bom ajuste, mostrado-se adequado para a aplicação, sendo dado por:

$$[T_{EP}]_{Cad} = \left[k_1 \cdot \left(258.50 - 16.145 \cdot Cad + 3.0524 \cdot Esp + \dots \right. \right. \\ \left. \left. \dots 0.54147 \cdot TE + 0.17151 \cdot TA + 0.018570 \cdot v_{p6} \right) + k_2 \right]_{Cad} \cong [T_{RP}]_{Cad} \quad (6.3)$$

Onde:

$[T_{EP}]_{Cad}$ = temperatura estimada do material no passe de laminação na cadeira Cad (°C)

Cad = 1...6 = número da cadeira do LTQ

Esp = espessura final da tira na saída do laminador (mm)

TE = temperatura do esboço na entrada no laminador (°C)

TA = temperatura da tira na saída do laminador (°C)

v_{p6} = velocidade periférica do cilindro de trabalho da última cadeira (mpm)

k_1, k_2 = parâmetros de ajuste em função da cadeira, conforme abaixo:


Cadeira	1	2	3	4	5	6
k_1	1.448	1.264	1.1349	0.9479	0.7484	0.478
k_2	-434.36	-249.97	-124.33	50.272	229.11	463.74

$[T_{RP}]_{Cad}$ = temperatura real do material no passe na cadeira Cad, resultado do recálculo do modelo de *set-up* (FSU) a partir de dados reais de laminação (°C)


O ajuste da regressão apresentou o seguinte resultado:

R múltiplo	0.981
R-Quadrado	0.963
R-quadrado ajustado	0.963
Erro padrão	5.6 °C
Contagem	16383

A Figura 6.3 mostra o gráfico de ajuste geral da T_{RP} em função da T_{EP} , e erro relativo de cada caso válido para todas as cadeiras do laminador.



(a)



(b)

Figura 6.3 – Relação entre a temperatura real da tira no passe de laminação (T_{RP}), calculada pelo modelo de *set-up* (FSU) do LTQ, em função da temperatura estimada a partir do modelo de regressão múltipla (T_{EP}), válida para aços C-Mn: (a) reta de ajuste; (b) erro relativo de cada caso.

Com este procedimento, simplifica-se, embora com alguma perda de precisão, a informação de temperatura do material no passe, agora estimada a partir de variáveis primárias. Evita-se assim a complexidade do cálculo recursivo por modelos físicos, o que facilita a condição de novas simulações da TEQ a partir da RNA desenvolvida. Na Figura 6.4 é mostrada a precisão do modelo linear de temperatura estimada no passe, em função do seu desvio relativo em relação à temperatura real.




Figura 6.4 – Desvio relativo e dispersão do desvio relativo do modelo do temperatura da tira no passe de laminação estimado pela regressão linear múltipla (T_{EP}), em relação à temperatura real (T_{RP}), válido para aços C-Mn, por cadeira do LTQ. Nota: DP é o desvio padrão dos desvios relativos.

Cabe observar que embora a dispersão do erro esteja dentro de $\pm 1.5\%$, a resposta de modelos físicos de TEQ a pequenas variações da temperatura de laminação da tira no passe é significativa. Como se verá adiante, o mesmo acontece com a sensibilidade de resposta da TEQ calculada por RNA à essa mesma variável.

6.6 Determinação do raio achatado do cilindro de trabalho

De forma análoga ao que foi descrito no item anterior (5.5) com relação à temperatura da tira no passe de laminação (θ), o raio achatado de cilindros (R_{ach}), outra variável de entrada da RNA, também é calculado pelo modelo de *set-up* (MURAO, et al, 1996) através de funções que utilizam nesse caso a força da laminação de forma recursiva, força esta que também é função da TEQ (GINZBURG, 1989) (ROBERTS, 1983) (TSELIKOV, 1967 e 1980).

Para novamente se evitar tal recursividade foi desenvolvida, por regressão linear múltipla (SPIEGEL, 1978), uma simplificação que permite a estimação do raio achatado dos cilindros, na laminação a quente de aços C-Mn, com o objetivo de manter o cálculo final da TEQ independente de uma etapa de cálculo mais complexa (ZHOU, et al, 1996, 2000), e dada pela equação a seguir:

$$[X]_{Cad} = \begin{bmatrix} a_0 + a_1 \cdot Cad + a_2 \cdot Esp + a_3 \cdot Larg + ... \\ ...a_4 \cdot C + a_5 \cdot Mn + a_6 \cdot Si + a_7 \cdot Cu + a_8 \cdot Cr + ... \\ ...a_9 \cdot T_{RP} + a_{10} \cdot D_{wr} + a_{11} \cdot h_i + a_{12} \cdot h_f + a_{13} \cdot v_p \end{bmatrix}_{Cad} \rightarrow$$

$$\rightarrow [R_{ach}]_{Cad} = [u_0 + u_1 \cdot X + u_2 \cdot X^2]_{Cad} \cong [R_{ach-R}]_{Cad} \quad (6.4)$$

Onde :

$[R_{ach}]_{Cad}$	=	raio achatado estimado dos cilindros de trabalho da cadeira
Cad (mm)		
Cad =	1...6 =	número da cadeira do LTQ
$[X]_{Cad}$	=	parâmetro intermediário do cálculo (mm)
Esp =		espessura final da tira na saída do laminador (mm)
Larg =		largura final da tira na saída do laminador (mm)
C =		teor de carbono do aço da tira laminada (%)
Mn =		teor de manganês do aço da tira laminada (%)
Si =		teor de silício do aço da tira laminada (%)
Cr =		teor de cromo do aço da tira laminada (%)
Cu =		teor de cobre do aço da tira laminada (%)
T_{RP} =		temperatura real da tira no passe de laminação (°C) (*)
D_{wr} =		diâmetro médio dos cilindros de trabalho da cadeira (mm)

- h_i = espessura da tira na entrada no passe na cadeira (mm)
 h_f = espessura da tira na saída no passe na cadeira (mm)
 v_p = velocidade periférica dos cilindros de trabalho no passe (mpm)
 $[R_{ach_R}]_{Cad}$ = raio achatado real dos cilindros de trabalho da cadeira Cad (mm) (*)
 $a_0, a_1, \dots, a_{13}$ = constantes da regressão, dadas conforme abaixo:

Cadeira 1 a 5 →	a_0	a_1	a_2	a_3	a_4	a_5	a_6
	-305.88	6.8131	-4.8592	0.0018330	70.769	9.7281	32.876
	a_7	a_8	a_9	a_{10}	a_{11}	a_{12}	a_{13}
	11.715	9.7281	-0.049525	0.022206	-0.16669	3.9343	0.35422
Cadeira 6 →	a_0	a_1	a_2	a_3	a_4	a_5	a_6
	-395.23	0	1.8629	0.0019970	90.114	13.571	57.3374
	a_7	a_8	a_9	a_{10}	a_{11}	a_{12}	a_{13}
	-6.1265	26.066	0	0.83115	-5.4049	15.718	0.59488

u_0, u_1, u_2 = parâmetros de ajuste em função da cadeira, conforme abaixo:


Cadeira	1	2	3	4	5	6
u_2	-0.0057	-0.0058	-0.001	0.0025	0.0034	0.0089
u_1	3.9391	4.1499	1.212	-1.1985	-1.7217	-6.5373
u_0	-355.55	-398.73	51.616	463.58	546.18	1.5782

O ajuste da regressão apresentou o seguinte resultado:


R múltiplo	0.9645
R-Quadrado	0.9302
R-quadrado ajustado	0.9302
Erro padrão	11.0 mm
Contagem	44832

Nota : (*) resultado do recálculo do modelo de *set-up* (FSU) a partir de dados reais de laminação, para a análise de regressão efetuada.

A Figura 6.5 mostra o gráfico de ajuste geral do R_{ach_R} em função do R_{ach} , e o correspondente erro relativo, considerando todas as cadeiras do laminador.



(a)



(b)

Figura 6.5 – Relação entre o raio achatado real dos cilindros de trabalho no passe de laminação (R_{ach_R}), calculada pelo modelo de *set-up* (FSU) do LTQ, em função do raio achatado estimado a partir do modelo de regressão múltipla (R_{ach}), válida para aços C-Mn: (a) reta de ajuste; (b) erro relativo de cada caso.

Com a adoção da estimativa do raio achatado dos cilindros, consegue-se a facilidade objetivada para a obtenção dessa variável, em função de outras variáveis primárias, embora novamente com o custo da diminuição da precisão da informação, precisão esta que se reduz à medida que aumenta a diferença entre o raio achatado e o raio do cilindro, ou seja da cadeira inicial F1 no sentido da cadeira final F6, conforme evidenciado na Figura 6.6.




Figura 6.6 – Desvio relativo e dispersão do desvio relativo do modelo do raio achatado estimado pela regressão linear múltipla (R_{ach}), em relação ao raio achatado real dos cilindros de trabalho no passe de laminação (R_{ach_R}), válido para aços C-Mn, por cadeira do LTQ. Nota: DP é o desvio padrão dos desvios relativos.

6.7 Resultados obtidos

No Apêndice G estão disponibilizados valores dos parâmetros do algoritmo de treinamento *Levenberg-Marquardt*, utilizados no processamento da RNA de TEQ. No Apêndice H estão os valores de *bias* e pesos obtidos.

Os resultados do processamento e simulação das RNA's de TEQ, para os casos de laminação de aços C-Mn, são mostrados nas Figuras 6.7 a 6.30, para cada uma das seis cadeiras, F1 a F6, do LTQ.

Para cada cadeira, é exibida uma sequência de quatro figuras, compostas por gráficos relacionados às características de performance e precisão das RNA's de TEQ.

Para cada sequência, a primeira figura mostra gráficos de acerto, com o desvio relativo da TEQ calculada pelo modelo de *set-up* e respectivo histograma de valores do desvio, seguidos dos gráficos de desvio relativo da TEQ calculada pela RNA e respectivo histograma.

O desvio ou erro relativo das TEQ's ($DTEQ_{SU}$ e $DTEQ_{RNA}$), para cada caso do lote, é calculado conforme as expressões abaixo:

$$DTEQ_{SU} = 100 \cdot \left(\frac{TEQ_{SU}}{TEQ_{REAL}} - 1 \right) \quad (6.5)$$

$$DTEQ_{RNA} = 100 \cdot \left(\frac{TEQ_{RNA}}{TEQ_{REAL}} - 1 \right) \quad (6.6)$$

Nas expressões, TEQ_{SU} , TEQ_{RNA} e TEQ_{REAL} são resultados do cálculo da tensão de escoamento a quente, respectivamente do modelo de *set-up*, da rede neural e do modelo de *set-up* a partir de dados reais (MURAO, et al, 1996).

A figura seguinte, relacionada à performance de treinamento e precisão da rede, exibe o gráfico do *MSE* em função da quantidade de épocas de processamento dos lotes. Intencionalmente, objetiva-se um baixo valor de *MSE* para alvo, do forma que o final do treinamento ocorre em função da avaliação da simulação do lote de validação com a RNA da época, obtendo-se assim sempre o menor valor de *MSE* final permitido por esse mecanismo de generalização por parada antecipada (*early stop*).

Nessa mesma figura a comparação da precisão do cálculo da TEQ_{SU} e da TEQ_{RNA} pode ser vista em um mesmo gráfico que sobrepõe as curvas de desvio relativo acumulado, respectivamente dos valores de $DTEQ_{SU}$ e $DTEQ_{RNA}$.

A próxima figura da sequência de cada cadeira é composta por um conjunto de quatro gráficos que mostram o ajuste ou a aderência dos dados de TEQ_{REAL} aos dados de TEQ_{RNA} , através da correlação linear entre essas duas variáveis, respectivamente alvo e saída da RNA.

Um parâmetro que expressa o grau de ajuste é dado pelo coeficiente de correlação linear (SPIEGEL, 1978) mostrado em cada gráfico. Os três primeiros gráficos correspondem individualmente aos lotes de treinamento, validação e teste da rede. O quarto gráfico corresponde ao lote total, que inclui a totalidade dos casos dos três lotes anteriores.

Completando a sequência de quatro figuras, por cadeia, a última delas mostra mais dois gráficos. O primeiro deles é relacionado à sensibilidade de resposta da rede a cada variável de entrada.

A avaliação da sensibilidade da RNA, nesse trabalho, considera o seguinte procedimento: para cada caso do lote total, é imposto para uma determinada variável de entrada uma variação adicional ou excitação positiva de +1% sobre o seu valor original, mantendo-se inalterado o valor das demais variáveis, com o que se obtém uma correspondente variação relativa da variável de saída, no caso a TEQ_{RNA} , devido unicamente à influência da variável excitada (TAKAHASI, 2006).

Considera-se então a resposta ou sensibilidade da rede a essa variável de entrada excitada como sendo a média do módulo da variação relativa da variável de saída, considerando todos os casos do lote. A repetição do procedimento para cada uma das variáveis de entrada da RNA de TEQ permite obter o gráfico que estratifica o grau de influência de cada variável na resposta da rede, embora não o seu sentido, já que foi adotado o valor absoluto da variação de TQE_{RNA} para cada caso.

O segundo gráfico da última figura mostra a variação relativa entre o mínimo e o máximo valor de cada variável, considerando todos os casos apresentados à rede, para uma complementação e contraponto ao conceito de sensibilidade anteriormente descrito. Com ele é possível identificar aquelas variáveis com baixo fator de sensibilidade que no entanto podem apresentar alta variação relativa, ou vice-versa.




Figura 6.7 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F1 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.8 – Desempenho da RNA de TEQ na cadeira F1 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.9 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F1 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.10 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F1 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.11 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F2 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.12 – Desempenho da RNA de TEQ na cadeira F2 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.13 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F2 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.14 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F2 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.15 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F3 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.16 – Desempenho da RNA de TEQ na cadeira F3 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.17 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.18 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F3 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.19 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F4 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.20 – Desempenho da RNA de TEQ na cadeira F4 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.21 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F4 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.22 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F4 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.23 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F5 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.24 – Desempenho da RNA de TEQ na cadeira F5 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.25 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F5 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.26 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F5 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.27 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F6 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.28 – Desempenho da RNA de TEQ na cadeira F6 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.29 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F6 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.30 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F6 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.

6.8 Discussão dos resultados

De forma geral os procedimentos descritos conduziram a um bom ajuste no resultado das RNA's de TEQ para todas as cadeiras do LTQ, com resultado mais preciso do que o da TEQ calculada pelo atual modelo de *set-up* (FSU) para todas as cadeiras do LTQ.

Isto é evidenciado na Tabela 6.4, que traz o resumo dos dados de precisão tanto da TEQ_{SU} , como da TEQ_{RNA} , além do resultado do ajuste da TEQ_{REAL} em relação à TEQ_{RNA} , para cada cadeira do LTQ.

Tabela 6.4 – Resumo da precisão da TEQ_{SU} e TEQ_{RNA} e do ajuste com a TEQ_{REAL}

TEQ	Parâmetro	F1	F2	F3	F4	F5	F6	Unidade
Modelo de set-up (FSU)	Desvio Médio (FSU)	0.65	0.27	0.14	0.23	0.23	0.40	(%)
	DP (FSU)	1.25	1.38	1.53	1.66	2.02	2.42	(%)
RNA	Desvio Médio (RNA)	0.01	0.04	-0.07	0.00	0.03	0.01	(%)
	DP (RNA)	0.98	1.23	1.29	1.05	1.60	1.85	(%)
Ajuste TEQ Real x RNA	Número de épocas	38	28	51	23	48	55	-----
	MSE (lote de treinamento)	0.032	0.066	0.088	0.109	0.155	0.190	(Kgf/mm ²) ²
	Correlação linear (lote total)	0.984	0.979	0.980	0.977	0.985	0.990	-----
	Erro padrão da estimativa (lote total)	0.186	0.259	0.300	0.344	0.404	0.435	Kgf/mm ²
Nota : DP = desvio padrão dos desvios relativos								

O grau de ajuste pode ser considerado bom, com coeficiente de correlação linear entre a TEQ_{RNA} e a TEQ_{REAL} acima de 0.975 em todas as cadeiras. Também o desvio ou erro relativo médio da TEQ_{RNA} é menor em todas as cadeiras, comparado ao desvio relativo médio da TEQ_{SU} , sendo em média 99% inferior. A dispersão dos desvios relativos da TEQ_{RNA} em torno do desvio médio também é inferior em todas as cadeiras, sendo na média 22% menor.

A Figura 6.31 mostra graficamente o resultado de precisão e ajuste da RNA de TEQ. Nota-se um aumento da dispersão dos desvios relativos no sentido da primeira cadeira F1 até a última cadeira F6, tanto para o resultado de TEQ do modelo de *set-up*, como para o da RNA. O aumento de dispersão da TEQ_{RNA} , da cadeira F1 até a F6, também é evidenciado pelo aumento do erro padrão do ajuste.




Figura 6.31 – Análise da precisão e ajuste de dados da TEQ_{RNA} , comparada com a TEQ_{SU} e TEQ_{REAL} , por cadeira do LTQ: (a) desvio relativo médio e desvio padrão (DP) do desvio relativo da TEQ_{RNA} e TEQ_{SU} ; (b) coeficiente de correlação linear entre a TEQ_{REAL} e a TEQ_{RNA} , e erro padrão da relação, ambos para a totalidade dos casos (lote total).

Este fato coincide com o aumento da dispersão do cálculo do raio achatado estimado (R_{ach}) de cilindros, desde a cadeira F1 até a F6, especialmente nesta última, conforme mostrado na Figura 5.6, da seção (6.6).

Outras possíveis fontes de erro podem ser o atrito entre cilindro e tira, e a tensão de tração da tira entre cadeiras, cujo valor aumenta dos vãos iniciais (F1-F2) para os vãos finais (F5-F6), entre cadeiras do LTQ. Tais variáveis entretanto não são consideradas neste trabalho.

Além das fontes de erro citadas, variáveis de ordem metalúrgica como algum amaciamento térmico, como o proporcionado pela recristalização da estrutura do aço, e mesmo a proporção do constituinte ferrita em relação à fase austenita, caso ocorra alguma transformação de fase, especialmente nos aços com carbono e manganês mais baixos, com temperatura de transformação T_{AR3} maior, podem eventualmente exercer alguma influência na TEQ, e também não são consideradas neste trabalho.

Apesar disso, com as variáveis de entrada e RNA adotadas, o resultado global da TEQ_{RNA} mantêm-se mais preciso do que o mesmo resultado da TEQ_{SU} , com baixo valor do erro padrão da estimativa da relação $TEQ_{REAL} \times TEQ_{RNA}$, em todas as cadeiras.

Embora na investigação do grau de sensibilidade da RNA de TEQ seja constatado um maior peso das variáveis tipo 2, que são R_{ach} , v_P , h_f , h_i , T_{EP} , relacionadas à cadeira do laminador, em relação às variáveis tipo 1, que são C, Mn, Si, Cu e Cr, relacionadas ao material laminado, deve-se notar que a amplitude da variação relativa dos valores dessas variáveis tipo 1 no lote são bem maiores do que a mesma amplitude de variação das variáveis de tipo 2, o que de certa forma equilibra a importância da influência de todas as variáveis. Isso com exceção das variáveis Si e Cu, ambas com baixa amplitude de variação no lote de casos e baixo grau de sensibilidade. Por exemplo, nota-se que a temperatura da tira no passe (T_{EP}) e o raio achatado estimado (R_{ach}) do cilindro possuem ambos alto grau de sensibilidade, porém baixa variação relativa entre o mínimo e máximo valor. O mesmo acontece porém de maneira inversa com as variáveis carbono (C) e manganês (Mn).

7 Aplicação de RNA na Determinação da Força Específica (FW) na Laminação de Tiras a Quente

7.1 Introdução

Modelos de controle de Laminadores de Tiras a Quente devem possuir um algoritmo que forneça uma previsão de *set-up*, ou seja, *gap* e velocidade de cilindros de cada cadeira do LTQ, antes da chegada da tira à zona do laminador. Porém, de fato, um modelo físico de laminação calcula a força necessária para laminar a tira no passe e a velocidade dessa tira que atenda, entre outros, principalmente o equilíbrio do fluxo de massa entre as cadeiras do laminador. A informação de *set-up* é obtida com a aplicação de funções de transferência que fornecem, fundamentalmente a partir da velocidade da tira e força de laminação, respectivamente, a velocidade e o *gap* dos cilindros, conforme mostrado na Tabela 4.2, da seção 4.2.

Define-se a força específica de laminação como sendo a força total, ou soma das forças aplicadas nos mancais lado motor e lado operação da cadeira do laminador, necessária para a redução da espessura da tira no passe de laminação, dividida pela largura da tira laminada. Para o processo de laminação de tiras a quente, no LTQ, é razoável assumir que essa largura da tira é aproximadamente constante, ao longo de sua passagem pelas cadeiras do laminador (PLAUT, 1986) (TSELIKOV, et al 1967, 1980). Assim sendo F a força de laminação, $Larg$ a largura da tira, temos para a força específica FW a seguinte expressão de definição:

$$FW = \frac{F}{Larg} \quad (7.1)$$

Ou seja, a força específica FW é dada em unidade de força por unidade de comprimento de largura da tira laminada. Sendo a largura assumida como constante, o cálculo da FW é proporcional ao cálculo da força de laminação F .

O objetivo desse capítulo é mostrar uma aplicação de Rede Neural Artificial (RNA), do tipo *MFB (Multilayer, Feedforward, Backpropagation)*, para cálculo da força específica de laminação de tiras a quente a quente, de aços planos comuns do tipo C-Mn, treinada e validada a partir de dados industriais relativos à laminação desse tipo de material no Laminador de Tiras a Quente (LTQ) da Companhia Siderúrgica Paulista - COSIPA.

Assim, neste trabalho, a FW real, alvo da RNA, é obtida de forma direta, a partir do dado de força total real, obtida pela soma das forças medidas pela célula de carga em cada lado, operação e motor da cadeira, na região da ponta inicial da tira (região de *set-up*), conforme definida na seção 5.3, dividida pela largura da tira.

7.2 Seleção das variáveis de entrada e alvo da RNA de FW

Como no caso da TEQ, descrito na seção (6.2), a seleção de variáveis de entrada da RNA de FW contempla as que têm relação teórica com a força de laminação, porém, intencionalmente mantendo-se o conceito de primariedade e facilidade da informação de cada variável de entrada.

A partir da expressão básica de cálculo da força específica de laminação no passe, temos:

$$FW = \frac{F}{Larg} = TEQ \cdot \sqrt{Rach \cdot (h_i - h_f)} \cdot Q + \frac{\alpha \cdot F_B}{Larg} \rightarrow FW = função(CQ, \epsilon, \dot{\epsilon}, \theta, F_B) \quad (7.2)$$

O significado de cada variável relacionada com a TEQ já está descrito na seção (6.2). Já a variável adicional Q é um fator de correção genérico, que depende da teoria de cálculo de laminação adotada, muito comumente função das variáveis h_i , h_f e R_{ach} (GINZBURG, 1989) (PLAUT, 1986) (ROBERTS, 1983) (TSELIKOV, 1967, 1980).

Outra variável adicional é a F_B , força de bender, em unidades de força aplicada a cada mancal de cilindro de trabalho, que influi na força total de laminação, o que é evidenciado de forma simplificada através da constante de influência (α) (MURAO, et al, 1996).

As considerações que suportam a seleção das variáveis primárias de processo para alimentação da rede de FW estão esquematizadas na Figura 7.1., através da qual é mostrada que a relação funcional inicial de FW é transformada em outra mais conveniente para a definição de entradas da RNA, conforme a expressão dada a seguir:

$$FW = função(CQ, \epsilon, \dot{\epsilon}, \theta, F_B) \rightarrow FW_{RNA} = função(C, Mn, Si, Cr, Mn, R_{ach}, v_p, h_i, h_f, \theta, F_B) \quad (7.2)$$




Figura 7.1 – Esquema da seleção das variáveis de entrada (inputs) da RNA de FW.

Com base nas argumentações e modelos descritos nas seções (6.5) e (6.6), são novamente utilizadas estimativas para a *temperatura da tira no passe de laminação*, θ , aproximada para T_{EP} , e para o *raio achatado de cilindros* (R_{ach}).

A Tabela 7.1 mostra a lista de variáveis selecionadas para entrada e saída da RNA de TEQ, com respectivos resumos estatísticos.

Tabela 7.1 – Resumo estatístico das variáveis da base de dados original que foram selecionadas para alimentação da RNA de FW (*inputs* e *targets*). Variável tipo 1 significa característica do aço; tipo 2 significa característica dependente de uma das 6 cadeiras do LTQ.

Tipo	Descrição	Unidade	Símbolo	Média	Desvio padrão	Mínimo	Máximo	Contagem	TEQ
1	Teor de carbono	(%)	C	0.0718	0.0488	0.0230	0.4810	7472	Input 01
1	Teor de manganês	(%)	Mn	0.3776	0.2175	0.1100	1.6500	7472	Input 02
1	Teor de silício	(%)	Si	0.0415	0.0877	0.0000	0.4300	7472	Input 03
1	Teor de cobre	(%)	Cu	0.0081	0.0202	0.0000	0.2700	7472	Input 04
1	Teor de cromo	(%)	Cr	0.0217	0.0409	0.0100	0.5400	7472	Input 05
2	Raio achatado estimado	(mm)	R_{ach}	372.4	40.24	314.0	507.1	6 x 7472	Input 06
2	Velocidade periférica dos cilindros de trabalho	(mpm)	v_P	217.9	126.0	46.6	548.8	6 x 7472	Input 07
2	Força de bender	(Tf/mancal)	F_B	38.55	19.63	0.00	103.60	6 x 7472	Input 08
2	Espessura de entrada na cadeira	(mm)	h_i	12.16	9.15	2.30	34.00	6 x 7472	Input 09
2	Espessura de saída da cadeira	(mm)	h_f	7.71	4.87	1.93	21.97	6 x 7472	Input 10
2	Temperatura estimada no passe	(°C)	θ_{EP}	929	26.6	841	1002	6 x 7472	Input 11
2	FORÇA ESPECÍFICA REAL	(Tf/mm)	FW_R	1.0480	0.2653	0.3284	2.0352	6 x 7472	Target

7.3 Arquitetura da RNA de FW

Analogamente à RNA de TEQ, a opção é por seis RNA's *MFB* individuais de FW, todas porém de arquitetura e parametrização similares, cada uma delas correspondendo a uma das cadeiras do LTQ, e com uma saída que é a FW do passe.

A Figura 7.2 mostra o diagrama de blocos da arquitetura da RNA adotada para cálculo da FW. Nos blocos são indicadas as matrizes de entradas (*inputs*) X , *bias* B , pesos W , funções de soma v , funções de ativação ϕ , e saída (*output*) Y , para cada uma das 4 camadas da rede. A matriz de dados X é formada pelo conjunto de dados de cada caso e alimenta a primeira camada da rede. A matriz Y da última camada corresponde à saída ou resposta da rede ao caso ou exemplo apresentado.




Figura 7.2 – Diagrama de blocos da arquitetura da RNA MFB (Multilayer, Feedforward, Backpropagation) utilizada para previsão da FW.

A Tabela 7.2 mostra com mais detalhes a arquitetura e parâmetros indexados que compõe a RNA de FW, indicando também os *targets* e erro da rede, enquanto a Tabela 7.3 complementa as informações sobre o tamanho da rede.

Tabela 7.2 – Detalhes da arquitetura e parâmetros da RNA *MFB* utilizada na previsão da FW.

RNA de FW			Entrada	Camada k				Saída
Parâmetro				1	2	3	4	
ENTRADA →	Variável	X_{ijk}	$[X_{i00}] = inputs$	$[X_{i01}] = [X_{i00}]$	$[X_{i02}] = [Y_{1j1}]$	$[X_{i03}] = [Y_{1j2}]$	$[X_{i04}] = [Y_{1j3}]$	
	Entrada	i	1:11	1:11	1:11	1:25	1:13	
	Neurônio	j	0	1:11	1:25	1:13	1	
BIAS →	Variável	B_{ijk}		$[b_{1j1}]$	$[b_{1j2}]$	$[b_{1j3}]$	$[b_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:11	1:25	1:13	1	
PESOS →	Variável	W_{ijk}		$[w_{ij1}]$	$[w_{ij2}]$	$[w_{ij3}]$	$[w_{ij4}]$	
	Entrada	i		1:11	1:11	1:25	1:13	
	Neurônio	j		1:11	1:25	1:13	1	
FUNÇÃO SOMA →	Variável	$v_{ijk} = \Sigma(b_{ijk} + w_{ijk})$		$[v_{1j1}]$	$[v_{1j2}]$	$[v_{1j3}]$	$[v_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:10	1:25	1:13	1	
FUNÇÃO DE ATIVAÇÃO →	Variável	$\phi_{ijk} = f(v_{ijk})$		$[\phi_{1j1}] = f(v_{1j1})$	$[\phi_{1j2}] = f(v_{1j2})$	$[\phi_{1j3}] = f(v_{1j3})$	$[\phi_{1j4}] = f(v_{1j4})$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:11	1:25	1:13	1	
	Função	f		Tangente sigmóide	Tangente sigmóide	Tangente sigmóide	Linear	
SAÍDA →	Variável	$Y_{ijk} = \phi_{ijk}(v_{ijk})$		$[Y_{1j1}] = [\phi_{1j1}(v_{1j1})]$	$[Y_{1j2}] = [\phi_{1j2}(v_{1j2})]$	$[Y_{1j3}] = [\phi_{1j3}(v_{1j3})]$	$[Y_{1j4}] = [\phi_{1j4}(v_{1j4})]$	$[y_{0j0}] = [Y_{1j4}]$
	Entrada	i		1	1	1	1	1
	Neurônio	j		1:11	1:25	1:13	1	1
ALVO →	Variável	D_{ijk}						$[d_{0j0}] = targets$
	Entrada	i						0
	Neurônio	j						1
ERRO →	Variável	E_{ijk}						$[e_{0j0}] = [d_{0j0} - y_{0j0}]$
	Entrada	i						0
	Neurônio	j						1

Tabela 7.3 – Resumo da quantidade de parâmetros da RNA *MFB* utilizada na previsão da FW.

Ítem da rede	Entrada	Camadas				Saída	Total
		1	2	3	4		
Input (x)	11	----	----	----	----	----	11
Neurônios	----	11	25	13	1	----	50
Bias (b)	----	11	$1 \times 25 = 25$	$1 \times 13 = 13$	1	----	50
Pesos (w)	----	$11 \times 11 = 121$	$11 \times 25 = 275$	$25 \times 13 = 325$	$13 \times 1 = 13$	----	734
Parâmetros livres = Pesos (w) + bias (b)	----	132	300	338	14	----	784
Output (y)	----	----	----	----	----	1	1

Essa arquitetura de RNA de FW é a aplicada para cada uma das cadeiras do LTQ, e tendo sido selecionada após várias simulações nas quais se variou o número de camadas e de neurônios por camada. De forma consistente, é a que levou a um menor *MSE*, sem comprometimento do tempo de processamento da rede.

7.4 Treinamento da RNA de FW

Também para a RNA de FW, opta-se neste trabalho pelo algoritmo de treinamento *Levenberg-Marquardt*, com lote de validação e treinamento. Parâmetros específicos do algoritmo correspondem a valores padrão do software utilizado, comuns para as RNA's de FW de todas as cadeiras.

A partição da quantidade total de casos entre lotes de treino, validação e teste, atende novamente ao critério descrito na seção 3.10.

Nesse caso, a quantidade $(30 \times N_w) = (30 \times 784 \text{ parâmetros livres}) = 23.520$ casos, excede a quantidade de 7098 casos disponíveis para lotes de treino e validação (95% do total de 7.472 casos, com 5% já destinados a lote de teste), o que determina a escolha do método não assintótico e a necessidade do lote de validação.

A partir da expressão 3.29, obtêm-se a porcentagem máxima do lote de treinamento da ordem de 97.5% da quantidade de casos destinada a treino e validação, ficando a partição final igual a 90% dos casos destinados a lote de treino, 5% destinados a lote de validação e 5% a lote de teste.

Para que o perfil do mix de informações de alimentação e resposta da rede fosse o mesmo para cada lote, a seqüência de seleção dos casos para compor os lotes de treino, validação e teste, foi tornada propositalmente aleatória.

7.5 Resultados obtidos

No Apêndice G estão disponibilizados valores dos parâmetros do algoritmo de treinamento *Levenberg-Marquardt* utilizados no processamento da RNA de FW. No Apêndice I estão os valores de *bias* e pesos obtidos.

Os resultados do processamento e simulação da RNA de FW, de aços C-Mn, são mostrados nas Figuras 7.3 a 7.26, para cada uma das seis cadeiras, F1 a F6, do LTQ.

Para cada cadeira, é exibida uma seqüência de quatro figuras, compostas por gráficos relacionados às características de performance e precisão das RNA's de FW. No Apêndice H estão os respectivos valores de *bias* e pesos das RNA's de FW.

A descrição de cada figura da seqüência por cadeira é similar à realizada na seção (5.7) relativa aos resultados das RNA's de TEQ, e aplica-se integralmente a esta seção sobre resultados das RNA's de FW, com a ressalva que o conceito de desvio ou erro relativo das FW's (DFW_{SU} e DFW_{RNA}), para cada caso do lote, é conforme as expressões dadas a seguir:

$$DFW_{SU} = 100 \cdot \left(\frac{FW_{SU}}{FW_{REAL}} - 1 \right) \quad (7.3)$$

$$DFW_{RNA} = 100 \cdot \left(\frac{FW_{RNA}}{FW_{REAL}} - 1 \right) \quad (7.4)$$

Nas expressões, FW_{SU} , FW_{RNA} e FW_{REAL} são resultados do cálculo da força específica de laminação a quente, respectivamente do modelo de *set-up*, da rede neural e da medição real da força no passe.




Figura 7.3 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F1 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.4 – Desempenho da RNA de FW na cadeira F1 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.5 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F1 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.6 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F1 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.7 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F2 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.8 – Desempenho da RNA de FW na cadeira F2 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.9 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F2 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.10 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F2 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.11 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F3 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (d) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.12 – Desempenho da RNA de FW na cadeira F3 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.13 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.14 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F3 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.15 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F4 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.16 – Desempenho da RNA de FW na cadeira F4 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 6.19 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F4 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (d) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.20 – Desempenho da RNA de TEQ na cadeira F4 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.21 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F4 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.22 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F4 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.23 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F5 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.24 – Desempenho da RNA de TEQ na cadeira F5 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.25 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F5 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.26 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F5 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 6.27 – Desvio relativo TEQ_{SU} , pré-calculada pelo modelo de *set-up*, e da TEQ_{RNA} , fornecida pela rede neural, ambos em relação à TEQ_{REAL} , pós-calculada com dados reais de processo pelo modelo de *set-up*, para casos da cadeira F6 do LTQ: (a) desvio relativo da TEQ_{SU} para cada caso e (b) correspondente histograma dos desvios; (d) desvio relativo da TEQ_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 6.28 – Desempenho da RNA de TEQ na cadeira F6 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da TEQ_{SU} e da TEQ_{RNA} , ambas em relação à TEQ_{REAL} .




Figura 6.29 – Relação de ajuste da TEQ_{REAL} , fornecida pelo modelo de *set-up*, em função da TEQ_{RNA} fornecida pela rede neural, para casos da cadeira F6 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 6.30 – Análise da sensibilidade da TEQ_{RNA} à cada variável de entrada da rede, para a cadeira F6 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.

6.8 Discussão dos resultados

De forma geral os procedimentos descritos conduziram a um bom ajuste no resultado das RNA's de TEQ para todas as cadeiras do LTQ, com resultado mais preciso do que o da TEQ calculada pelo atual modelo de *set-up* (FSU) para todas as cadeiras do LTQ.

Isto é evidenciado na Tabela 6.4, que traz o resumo dos dados de precisão tanto da TEQ_{SU} , como da TEQ_{RNA} , além do resultado do ajuste da TEQ_{REAL} em relação à TEQ_{RNA} , para cada cadeira do LTQ.

Tabela 6.4 – Resumo da precisão da TEQ_{SU} e TEQ_{RNA} e do ajuste com a TEQ_{REAL}

TEQ	Parâmetro	F1	F2	F3	F4	F5	F6	Unidade
Modelo de set-up (FSU)	Desvio Médio (FSU)	0.65	0.27	0.14	0.23	0.23	0.40	(%)
	DP (FSU)	1.25	1.38	1.53	1.66	2.02	2.42	(%)
RNA	Desvio Médio (RNA)	0.01	0.04	-0.07	0.00	0.03	0.01	(%)
	DP (RNA)	0.98	1.23	1.29	1.05	1.60	1.85	(%)
Ajuste TEQ Real x RNA	Número de épocas	38	28	51	23	48	55	-----
	MSE (lote de treinamento)	0.032	0.066	0.088	0.109	0.155	0.190	(Kgf/mm ²) ²
	Correlação linear (lote total)	0.984	0.979	0.980	0.977	0.985	0.990	-----
	Erro padrão da estimativa (lote total)	0.186	0.259	0.300	0.344	0.404	0.435	Kgf/mm ²
Nota : DP = desvio padrão dos desvios relativos								

O grau de ajuste pode ser considerado bom, com coeficiente de correlação linear entre a TEQ_{RNA} e a TEQ_{REAL} acima de 0.975 em todas as cadeiras. Também o desvio ou erro relativo médio da TEQ_{RNA} é menor em todas as cadeiras, comparado ao desvio relativo médio da TEQ_{SU} , sendo em média 99% inferior. A dispersão dos desvios relativos da TEQ_{RNA} em torno do desvio médio também é inferior em todas as cadeiras, sendo na média 22% menor.

A Figura 6.31 mostra graficamente o resultado de precisão e ajuste da RNA de TEQ. Nota-se um aumento da dispersão dos desvios relativos no sentido da primeira cadeira F1 até a última cadeira F6, tanto para o resultado de TEQ do modelo de *set-up*, como para o da RNA. O aumento de dispersão da TEQ_{RNA} , da cadeira F1 até a F6, também é evidenciado pelo aumento do erro padrão do ajuste.




Figura 6.31 – Análise da precisão e ajuste de dados da TEQ_{RNA} , comparada com a TEQ_{SU} e TEQ_{REAL} , por cadeira do LTQ: (a) desvio relativo médio e desvio padrão (DP) do desvio relativo da TEQ_{RNA} e TEQ_{SU} ; (b) coeficiente de correlação linear entre a TEQ_{REAL} e a TEQ_{RNA} , e erro padrão da relação, ambos para a totalidade dos casos (lote total).

Este fato coincide com o aumento da dispersão do cálculo do raio achatado estimado (R_{ach}) de cilindros, desde a cadeira F1 até a F6, especialmente nesta última, conforme mostrado na Figura 5.6, da seção (6.6).

Outras possíveis fontes de erro podem ser o atrito entre cilindro e tira, e a tensão de tração da tira entre cadeiras, cujo valor aumenta dos vãos iniciais (F1-F2) para os vãos finais (F5-F6), entre cadeiras do LTQ. Tais variáveis entretanto não são consideradas neste trabalho.

Além das fontes de erro citadas, variáveis de ordem metalúrgica como algum amaciamento térmico, como o proporcionado pela recristalização da estrutura do aço, e mesmo a proporção do constituinte ferrita em relação à fase austenita, caso ocorra alguma transformação de fase, especialmente nos aços com carbono e manganês mais baixos, com temperatura de transformação T_{AR3} maior, podem eventualmente exercer alguma influência na TEQ, e também não são consideradas neste trabalho.

Apesar disso, com as variáveis de entrada e RNA adotadas, o resultado global da TEQ_{RNA} mantêm-se mais preciso do que o mesmo resultado da TEQ_{SU} , com baixo valor do erro padrão da estimativa da relação $TEQ_{REAL} \times TEQ_{RNA}$, em todas as cadeiras.

Embora na investigação do grau de sensibilidade da RNA de TEQ seja constatado um maior peso das variáveis tipo 2, que são R_{ach} , v_P , h_f , h_i , T_{EP} , relacionadas à cadeira do laminador, em relação às variáveis tipo 1, que são C, Mn, Si, Cu e Cr, relacionadas ao material laminado, deve-se notar que a amplitude da variação relativa dos valores dessas variáveis tipo 1 no lote são bem maiores do que a mesma amplitude de variação das variáveis de tipo 2, o que de certa forma equilibra a importância da influência de todas as variáveis. Isso com exceção das variáveis Si e Cu, ambas com baixa amplitude de variação no lote de casos e baixo grau de sensibilidade. Por exemplo, nota-se que a temperatura da tira no passe (T_{EP}) e o raio achatado estimado (R_{ach}) do cilindro possuem ambos alto grau de sensibilidade, porém baixa variação relativa entre o mínimo e máximo valor. O mesmo acontece porém de maneira inversa com as variáveis carbono (C) e manganês (Mn).

7 Aplicação de RNA na Determinação da Força Específica (FW) na Laminação de Tiras a Quente

7.1 Introdução

Modelos de controle de Laminadores de Tiras a Quente devem possuir um algoritmo que forneça uma previsão de *set-up*, ou seja, *gap* e velocidade de cilindros de cada cadeira do LTQ, antes da chegada da tira à zona do laminador. Porém, de fato, um modelo físico de laminação calcula a força necessária para laminar a tira no passe e a velocidade dessa tira que atenda, entre outros, principalmente o equilíbrio do fluxo de massa entre as cadeiras do laminador. A informação de *set-up* é obtida com a aplicação de funções de transferência que fornecem, fundamentalmente a partir da velocidade da tira e força de laminação, respectivamente, a velocidade e o *gap* dos cilindros, conforme mostrado na Tabela 4.2, da seção 4.2.

Define-se a força específica de laminação como sendo a força total, ou soma das forças aplicadas nos mancais lado motor e lado operação da cadeira do laminador, necessária para a redução da espessura da tira no passe de laminação, dividida pela largura da tira laminada. Para o processo de laminação de tiras a quente, no LTQ, é razoável assumir que essa largura da tira é aproximadamente constante, ao longo de sua passagem pelas cadeiras do laminador (PLAUT, 1986) (TSELIKOV, et al 1967, 1980). Assim sendo F a força de laminação, $Larg$ a largura da tira, temos para a força específica FW a seguinte expressão de definição:

$$FW = \frac{F}{Larg} \quad (7.1)$$

Ou seja, a força específica FW é dada em unidade de força por unidade de comprimento de largura da tira laminada. Sendo a largura assumida como constante, o cálculo da FW é proporcional ao cálculo da força de laminação F .

O objetivo desse capítulo é mostrar uma aplicação de Rede Neural Artificial (RNA), do tipo *MFB (Multilayer, Feedforward, Backpropagation)*, para cálculo da força específica de laminação de tiras a quente a quente, de aços planos comuns do tipo C-Mn, treinada e validada a partir de dados industriais relativos à laminação desse tipo de material no Laminador de Tiras a Quente (LTQ) da Companhia Siderúrgica Paulista - COSIPA.

Assim, neste trabalho, a FW real, alvo da RNA, é obtida de forma direta, a partir do dado de força total real, obtida pela soma das forças medidas pela célula de carga em cada lado, operação e motor da cadeira, na região da ponta inicial da tira (região de *set-up*), conforme definida na seção 5.3, dividida pela largura da tira.

7.2 Seleção das variáveis de entrada e alvo da RNA de FW

Como no caso da TEQ, descrito na seção (6.2), a seleção de variáveis de entrada da RNA de FW contempla as que têm relação teórica com a força de laminação, porém, intencionalmente mantendo-se o conceito de primariedade e facilidade da informação de cada variável de entrada.

A partir da expressão básica de cálculo da força específica de laminação no passe, temos:

$$FW = \frac{F}{Larg} = TEQ \cdot \sqrt{Rach \cdot (h_i - h_f)} \cdot Q + \frac{\alpha \cdot F_B}{Larg} \rightarrow FW = função(CQ, \varepsilon, \varepsilon, \theta, F_B) \quad (7.2)$$

O significado de cada variável relacionada com a TEQ já está descrito na seção (6.2). Já a variável adicional Q é um fator de correção genérico, que depende da teoria de cálculo de laminação adotada, muito comumente função das variáveis h_i , h_f e R_{ach} (GINZBURG, 1989) (PLAUT, 1986) (ROBERTS, 1983) (TSELIKOV, 1967, 1980).

Outra variável adicional é a F_B , força de bender, em unidades de força aplicada a cada mancal de cilindro de trabalho, que influi na força total de laminação, o que é evidenciado de forma simplificada através da constante de influência (α) (MURAO, et al, 1996).

As considerações que suportam a seleção das variáveis primárias de processo para alimentação da rede de FW estão esquematizadas na Figura 7.1., através da qual é mostrada que a relação funcional inicial de FW é transformada em outra mais conveniente para a definição de entradas da RNA, conforme a expressão dada a seguir:

$$FW = função(CQ, \varepsilon, \varepsilon, \theta, F_B) \rightarrow FW_{RNA} = função(C, Mn, Si, Cr, Mn, R_{ach}, v_p, h_i, h_f, \theta, F_B) \quad (7.2)$$




Figura 7.1 – Esquema da seleção das variáveis de entrada (*inputs*) da RNA de FW.

Com base nas argumentações e modelos descritos nas seções (6.5) e (6.6), são novamente utilizadas estimativas para a *temperatura da tira no passe de laminação*, θ , aproximada para T_{EP} , e para o *raio achatado de cilindros* (R_{ach}).

A Tabela 7.1 mostra a lista de variáveis selecionadas para entrada e saída da RNA de TEQ, com respectivos resumos estatísticos.

Tabela 7.1 – Resumo estatístico das variáveis da base de dados original que foram selecionadas para alimentação da RNA de FW (*inputs* e *targets*). Variável tipo 1 significa característica do aço; tipo 2 significa característica dependente de uma das 6 cadeiras do LTQ.

Tipo	Descrição	Unidade	Símbolo	Média	Desvio padrão	Mínimo	Máximo	Contagem	TEQ
1	Teor de carbono	(%)	C	0.0718	0.0488	0.0230	0.4810	7472	Input 01
1	Teor de manganês	(%)	Mn	0.3776	0.2175	0.1100	1.6500	7472	Input 02
1	Teor de silício	(%)	Si	0.0415	0.0877	0.0000	0.4300	7472	Input 03
1	Teor de cobre	(%)	Cu	0.0081	0.0202	0.0000	0.2700	7472	Input 04
1	Teor de cromo	(%)	Cr	0.0217	0.0409	0.0100	0.5400	7472	Input 05
2	Raio achatado estimado	(mm)	R_{ach}	372.4	40.24	314.0	507.1	6 x 7472	Input 06
2	Velocidade periférica dos cilindros de trabalho	(mpm)	v_P	217.9	126.0	46.6	548.8	6 x 7472	Input 07
2	Força de bender	(Tf/mancal)	F_B	38.55	19.63	0.00	103.60	6 x 7472	Input 08
2	Espessura de entrada na cadeira	(mm)	h_i	12.16	9.15	2.30	34.00	6 x 7472	Input 09
2	Espessura de saída da cadeira	(mm)	h_f	7.71	4.87	1.93	21.97	6 x 7472	Input 10
2	Temperatura estimada no passe	(°C)	θ_{EP}	929	26.6	841	1002	6 x 7472	Input 11
2	FORÇA ESPECÍFICA REAL	(Tf/mm)	FW_R	1.0480	0.2653	0.3284	2.0352	6 x 7472	Target

7.3 Arquitetura da RNA de FW

Analogamente à RNA de TEQ, a opção é por seis RNA's *MFB* individuais de FW, todas porém de arquitetura e parametrização similares, cada uma delas correspondendo a uma das cadeiras do LTQ, e com uma saída que é a FW do passe.

A Figura 7.2 mostra o diagrama de blocos da arquitetura da RNA adotada para cálculo da FW. Nos blocos são indicadas as matrizes de entradas (*inputs*) X , *bias* B , pesos W , funções de soma v , funções de ativação ϕ , e saída (*output*) Y , para cada uma das 4 camadas da rede. A matriz de dados X é formada pelo conjunto de dados de cada caso e alimenta a primeira camada da rede. A matriz Y da última camada corresponde à saída ou resposta da rede ao caso ou exemplo apresentado.




Figura 7.2 – Diagrama de blocos da arquitetura da RNA *MFB* (*Multilayer, Feedforward, Backpropagation*) utilizada para previsão da FW.

A Tabela 7.2 mostra com mais detalhes a arquitetura e parâmetros indexados que compõe a RNA de FW, indicando também os *targets* e erro da rede, enquanto a Tabela 7.3 complementa as informações sobre o tamanho da rede.

Tabela 7.2 – Detalhes da arquitetura e parâmetros da RNA *MFB* utilizada na previsão da FW.

RNA de FW			Entrada	Camada k				Saída
Parâmetro				1	2	3	4	
ENTRADA →	Variável	X_{ijk}	$[x_{i00}] = inputs$	$[x_{i01}] = [x_{i00}]$	$[x_{i02}] = [y_{1j1}]$	$[x_{i03}] = [y_{1j2}]$	$[x_{i04}] = [y_{1j3}]$	
	Entrada	i	1:11	1:11	1:11	1:25	1:13	
	Neurônio	j	0	1:11	1:25	1:13	1	
BIAS →	Variável	B_{ijk}		$[b_{1j1}]$	$[b_{1j2}]$	$[b_{1j3}]$	$[b_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:11	1:25	1:13	1	
PESOS →	Variável	W_{ijk}		$[w_{ij1}]$	$[w_{ij2}]$	$[w_{ij3}]$	$[w_{ij4}]$	
	Entrada	i		1:11	1:11	1:25	1:13	
	Neurônio	j		1:11	1:25	1:13	1	
FUNÇÃO SOMA →	Variável	$v_{ijk} = \Sigma(b_{ijk}+w_{ijk})$		$[v_{1j1}]$	$[v_{1j2}]$	$[v_{1j3}]$	$[v_{1j4}]$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:10	1:25	1:13	1	
FUNÇÃO DE ATIVAÇÃO →	Variável	$\phi_{ijk} = f(v_{ijk})$		$[\phi_{1j1}] = f(v_{1j1})$	$[\phi_{1j2}] = f(v_{1j2})$	$[\phi_{1j3}] = f(v_{1j3})$	$[\phi_{1j4}] = f(v_{1j4})$	
	Entrada	i		1	1	1	1	
	Neurônio	j		1:11	1:25	1:13	1	
	Função	f		Tangente sigmóide	Tangente sigmóide	Tangente sigmóide	Linear	
SAÍDA →	Variável	$Y_{ijk} = \phi_{ijk}(v_{ijk})$		$[y_{1j1}] = [\phi_{1j1}(v_{1j1})]$	$[y_{1j2}] = [\phi_{1j2}(v_{1j2})]$	$[y_{1j3}] = [\phi_{1j3}(v_{1j3})]$	$[y_{1j4}] = [\phi_{1j4}(v_{1j4})]$	$[y_{0j0}] = [y_{1j4}]$
	Entrada	i		1	1	1	1	1
	Neurônio	j		1:11	1:25	1:13	1	1
ALVO →	Variável	D_{ijk}						$[d_{0j0}] = targets$
	Entrada	i						0
	Neurônio	j						1
ERRO →	Variável	E_{ijk}						$[e_{0j0}] = [d_{0j0}- y_{0j0}]$
	Entrada	i						0
	Neurônio	j						1

Tabela 7.3 – Resumo da quantidade de parâmetros da RNA *MFB* utilizada na previsão da FW.

Ítem da rede	Entrada	Camadas				Saída	Total
		1	2	3	4		
Input (x)	11	-----	-----	-----	-----	-----	11
Neurônios	-----	11	25	13	1	-----	50
Bias (b)	-----	11	$1 \times 25 = 25$	$1 \times 13 = 13$	1	-----	50
Pesos (w)	-----	$11 \times 11 = 121$	$11 \times 25 = 275$	$25 \times 13 = 325$	$13 \times 1 = 13$	-----	734
Parâmetros livres = Pesos (w) + bias (b)	-----	132	300	338	14	-----	784
Output (y)	-----	-----	-----	-----	-----	1	1

Essa arquitetura de RNA de FW é a aplicada para cada uma das cadeiras do LTQ, e tendo sido selecionada após várias simulações nas quais se variou o número de camadas e de neurônios por camada. De forma consistente, é a que levou a um menor *MSE*, sem comprometimento do tempo de processamento da rede.

7.4 Treinamento da RNA de FW

Também para a RNA de FW, opta-se neste trabalho pelo algoritmo de treinamento *Levenberg-Marquardt*, com lote de validação e treinamento. Parâmetros específicos do algoritmo correspondem a valores padrão do software utilizado, comuns para as RNA's de FW de todas as cadeiras.

A partição da quantidade total de casos entre lotes de treino, validação e teste, atende novamente ao critério descrito na seção 3.10.

Nesse caso, a quantidade $(30 \times N_w) = (30 \times 784 \text{ parâmetros livres}) = 23.520$ casos, excede a quantidade de 7098 casos disponíveis para lotes de treino e validação (95% do total de 7.472 casos, com 5% já destinados a lote de teste), o que determina a escolha do método não assintótico e a necessidade do lote de validação.

A partir da expressão 3.29, obtêm-se a porcentagem máxima do lote de treinamento da ordem de 97.5% da quantidade de casos destinada a treino e validação, ficando a partição final igual a 90% dos casos destinados a lote de treino, 5% destinados a lote de validação e 5% a lote de teste.

Para que o perfil do mix de informações de alimentação e resposta da rede fosse o mesmo para cada lote, a seqüência de seleção dos casos para compor os lotes de treino, validação e teste, foi tornada propositalmente aleatória.

7.5 Resultados obtidos

No Apêndice G estão disponibilizados valores dos parâmetros do algoritmo de treinamento *Levenberg-Marquardt* utilizados no processamento da RNA de FW. No Apêndice I estão os valores de *bias* e pesos obtidos.

Os resultados do processamento e simulação da RNA de FW, de aços C-Mn, são mostrados nas Figuras 7.3 a 7.26, para cada uma das seis cadeiras, F1 a F6, do LTQ.

Para cada cadeira, é exibida uma seqüência de quatro figuras, compostas por gráficos relacionados às características de performance e precisão das RNA's de FW. No Apêndice H estão os respectivos valores de *bias* e pesos das RNA's de FW.

A descrição de cada figura da seqüência por cadeira é similar à realizada na seção (5.7) relativa aos resultados das RNA's de TEQ, e aplica-se integralmente a esta seção sobre resultados das RNA's de FW, com a ressalva que o conceito de desvio ou erro relativo das FW's (DFW_{SU} e DFW_{RNA}), para cada caso do lote, é conforme as expressões dadas a seguir:

$$DFW_{SU} = 100 \cdot \left(\frac{FW_{SU}}{FW_{REAL}} - 1 \right) \quad (7.3)$$

$$DFW_{RNA} = 100 \cdot \left(\frac{FW_{RNA}}{FW_{REAL}} - 1 \right) \quad (7.4)$$

Nas expressões, FW_{SU} , FW_{RNA} e FW_{REAL} são resultados do cálculo da força específica de laminação a quente, respectivamente do modelo de *set-up*, da rede neural e da medição real da força no passe.




Figura 7.3 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F1 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.4 – Desempenho da RNA de FW na cadeira F1 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.5 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F1 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.6 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F1 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.7 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F2 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.8 – Desempenho da RNA de FW na cadeira F2 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.9 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F2 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.10 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F2 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.11 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F3 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (d) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.12 – Desempenho da RNA de FW na cadeira F3 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.13 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F3 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.14 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F3 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.15 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F4 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.16 – Desempenho da RNA de FW na cadeira F4 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.17 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F4 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.18 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F4 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.19 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F5 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (c) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.20 – Desempenho da RNA de FW na cadeira F5 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.21 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F5 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.22 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F5 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.




Figura 7.23 – Desvio relativo FW_{SU} , pré-calculada pelo modelo de *set-up*, e da FW_{RNA} , fornecida pela rede neural, ambos em relação à FW_{REAL} , medida no topo da tira (*same-point*), para casos da cadeira F6 do LTQ: (a) desvio relativo da FW_{SU} para cada caso e (b) correspondente histograma dos desvios; (d) desvio relativo da FW_{RNA} para cada caso e (d) correspondente histograma dos desvios.




Figura 7.24 – Desempenho da RNA de FW na cadeira F6 do LTQ: (a) performance do treinamento da rede, (b) desvio relativo acumulado da FW_{SU} e da FW_{RNA} , ambas em relação à FW_{REAL} .




Figura 7.25 – Relação de ajuste da FW_{REAL} , medida no topo da tira (*same-point*), em função da FW_{RNA} fornecida pela rede neural, para casos da cadeira F6 do LTQ, pertencentes respectivamente a lotes de: (a) treinamento, (b) validação, (c) teste, (d) total (treinamento + validação + teste).




Figura 7.26 – Análise da sensibilidade da FW_{RNA} à cada variável de entrada da rede, para a cadeira F6 do LTQ: (a) sensibilidade de resposta para uma excitação de +1% do valor do sinal de entrada, medida pela média dos desvios absolutos do sinal de saída para cada caso; (b) variação relativa entre o máximo e o mínimo valor da variável.

7.6 Discussão dos resultados

As RNA's de FW forneceram um resultado de ajuste que variou de satisfatório a regular conforme a cadeira do LTQ, com precisão similar ou ligeiramente inferior à do cálculo de FW realizado pelo modelo de *set-up* (FSU) do LTQ.

Isto é mostrado na Tabela 7.4, que traz o resumo dos dados de precisão tanto da FW_{SU} , como da FW_{RNA} , além do resultado do ajuste da FW_{REAL} em relação à FW_{RNA} , para cada cadeira do LTQ.

Tabela 7.4 – Resumo da precisão da FW_{SU} e FW_{RNA} e do ajuste com a FW_{REAL}

FW	Parâmetro	F1	F2	F3	F4	F5	F6	Unidade
Modelo de set-up (FSU)	Desvio Médio (FSU)	-0.39	-0.57	-0.64	-0.53	-0.22	-0.07	(%)
	DP (FSU)	3.59	3.60	3.18	2.84	2.92	3.28	(%)
RNA	Desvio Médio (RNA)	0.35	0.23	0.09	-0.23	0.16	0.36	(%)
	DP (RNA)	3.45	4.29	3.84	3.68	3.97	6.12	(%)
Ajuste TEQ Real x RNA	Número de épocas	25	53	30	44	44	58	-----
	MSE (lote de treinamento)	0.002	0.002	0.002	0.001	0.001	0.002	(Tf/mm) ²
	Correlação linear (lote total)	0.944	0.962	0.966	0.956	0.940	0.956	-----
	Erro padrão (lote total)	0.045	0.044	0.043	0.035	0.030	0.037	(Tf/mm)
Nota : DP = desvio padrão dos desvios relativos								

O grau de ajuste entre a FW_{REAL} e a FW_{RNA} é satisfatório, com coeficiente de correlação linear entre 0.940 (F5) e 0.966 (F3). O desvio ou erro relativo médio da FW_{RNA} é menor em todas as cadeiras, comparado ao desvio relativo médio da FW_{SU} , sendo em média 140% inferior. Porém a dispersão dos desvios ou erros relativos, expressa pelo desvio padrão (DP) da FW_{RNA} em torno do desvio médio é ligeiramente maior nas cadeiras F2 a F5, igual na F1 e maior na F6, se comparado com a dispersão de erro da FW_{SU} . Em média essa dispersão é 19% superior nas cadeiras F1 a F5, e 31% maior se com essas cadeiras é levada em conta também a F6.




Figura 7.27 – Análise da precisão e ajuste de dados da FW_{RNA} , comparada com a FW_{SU} e FW_{REAL} , por cadeira do LTQ: (a) desvio relativo médio e desvio padrão (DP) do desvio relativo da FW_{RNA} e FW_{SU} ; (b) coeficiente de correlação linear entre a FW_{REAL} e a FW_{RNA} , e erro padrão da relação, ambos para a totalidade dos casos (lote total).

A Figura 7.27 mostra graficamente o resultado de precisão e ajuste da RNA de FW. Nota-se uma certa constância da dispersão dos desvios relativos no sentido da primeira cadeira F1 até a última cadeira F6, tanto para o resultado de TEQ do modelo de *set-up*, como para o da RNA, com exceção da dispersão de desvio relativo da FW_{RNA} da cadeira F6. Entretanto o erro padrão de estimativa da FW_{REAL} em relação à FW_{RNA} da F6 não foge muito aos valores das demais cadeiras.

Contribuem para esse comportamento de menor precisão da FW_{RNA} da F6, certamente as mesmas causas que levam a uma maior variação da TEQ, como evidenciado e comentado na seção (6.8) pela maior dispersão do erro tanto da TEQ_{SU} como da TEQ_{RNA} .

Assim, ainda com maior intensidade no caso da FW_{RNA} da cadeira F6, a menor precisão da estimativa do raio achatado de cilindros dado pelo modelo descrito na seção (6.6), influi bastante na dispersão do erro da FW_{RNA} da F6, já que a FW é proporcional à raiz do R_{ach} , e também diretamente proporcional ao fator Q , ambos fatores integrantes da equação (7.2) de cálculo da FW . Essa dependência é mostrada também na Figura 7.1, sobre a definição das variáveis de entrada da RNA de FW .

As considerações sobre a sensibilidade da TEQ_{RNA} , mostradas na seção (6.8), também se aplicam à sensibilidade da FW_{RNA} . Ou seja, embora no grau de sensibilidade da RNA de FW por variável haja um maior peso das variáveis tipo 2, que são R_{ach} , v_P , F_B , h_f , h_i , T_{EP} , relacionadas à cadeira do laminador, em relação às variáveis tipo 1, que são C , Mn , Si , Cu e Cr , relacionadas ao material laminado, nota-se que a amplitude da variação relativa dos valores dessas variáveis tipo 1 no lote são bem maiores do que a mesma amplitude de variação das variáveis de tipo 2, equilibrando a importância da influência de todas as variáveis. Isso, novamente, com exceção das variáveis Si e Cu , ambas com baixa amplitude de variação no lote de casos e baixo grau de sensibilidade.

8 Conclusões

Na indústria siderúrgica de produção de aços planos, a Laminação de Tiras a Quente tem uma função crucial, produzindo material na forma de bobinas de aço para entrega direta a clientes externos, ou bobinas que são matéria-prima destinada a processos posteriores internos, que agregam ainda mais valor ao produto final.

Na determinação do *set-up* de ajuste das cadeiras do LTQ, é realizado pelo modelo de FSU o cálculo para previsão de várias variáveis de processo, incluindo a de Tensão de Escoamento a Quente (TEQ) do aço, e a de Força Específica de Laminação (FW).

Atendendo à proposta desse trabalho, de cálculo da TEQ e da FW de aços C-Mn, com a aplicação de RNA's MFB, a partir de variáveis primárias, foram utilizadas relações teóricas básicas do processo de conformação do passe de laminação para definir as variáveis de entrada da rede (*inputs*). Foram assim selecionadas as variáveis tipo 1, características do material laminado, que são os teores de carbono (C) do aço, de manganês (Mn), de silício (Si), de cobre (Cu) e de cromo (Cr); e variáveis de tipo 2, relacionadas ao passe de laminação, que são o raio achatado estimado de cilindros de trabalho (R_{ach}), velocidade periférica dos cilindros (v_p), força de bender (F_B , apenas para a TEQ de FW), espessuras de entrada (h_i) e de saída (h_f) e a temperatura estimada da tira (T_{EP}).

A variável alvo (*target*) da RNA de TEQ é a TEQ_{REAL} , obtida a partir de recálculo feito pelo FSU, a partir de dados reais de força, temperatura e espessura de saída da tira, entre outros. No caso da RNA de FW, a variável alvo é a FW_{REAL} , obtida a partir da medição direta da força de laminação pelas células de carga das cadeiras do LTQ.

Para evitar cálculos complexos e recursivos, como os utilizados pelo modelo de *set-up*, foram desenvolvidos, por regressão estatística linear múltipla, modelos para a estimação da temperatura da tira no passe de laminação (T_{EP}), com coeficiente de correlação linear $R_{MÚLTIPLO}$ de 0.981, e do raio achatado de cilindros (R_{ach}), com $R_{MÚLTIPLO}$ de 0.965. Ambos os modelos são funções diretas de variáveis primárias, de fácil obtenção, mostrando-se adequados à aplicação.

O resultado da TEQ obtida pela RNA *MFB*, de 4 camadas de neurônios e 737 parâmetros livres (pesos e *bias*), apresenta para todas as cadeiras uma precisão de acerto superior à do atual modelo de *set-up* do LTQ. A generalização desse resultado é bastante adequada considerando o grau de ajuste obtido para os lotes de treinamento, validação, teste e total, com o grau de ajuste do lote total de casos, medido pelo coeficiente de correlação linear, variando de 0.977 a 0.990, dependendo da cadeira, com baixo valor de erro padrão da estimativa.

Já o resultado da FW obtida pela RNA *MFB*, de 4 camadas de neurônios e 784 parâmetros livres, é satisfatório, apresentando para as cadeiras F1 F5 uma precisão de acerto aproximada à do atual modelo de *set-up* do LTQ, e uma precisão menor na F6, considerando a dispersão dos desvios ou erros relativos dos resultados. Os graus de ajuste obtidos para o lote total variam de 0.940 a 0.966, dependendo da cadeira. A generalização do resultado é adequada, com perfil similar considerando os lotes de treinamento, validação, teste e total.

Na análise da sensibilidade das redes de TEQ e FW, as variáveis tipo 2, relacionadas ao passe de laminação, foram bem mais influentes do que as de tipo 1, relacionadas à composição química do aço. Porém, observando a faixa de variação de valores mínimo a máximo de cada variável do lote constata-se a tendência inversa, com variáveis tipo 1 mostrando maior variação relativa, no sentido de equilibrar a influência das variáveis. A exceção são as variáveis teores de Si e Cr, ambas com baixo fator de sensibilidade e baixa variação relativa no lote de dados. Com relação à sensibilidade da rede, o raio achatado e temperatura de laminação foram as variáveis com maior fator de influência.

9 Sugestões para novos trabalhos

A implementação de simuladores *off-line*, para previsão da tensão de escoamento, TEQ, e da força específica, FW, de laminação em tiras a quente de aços C-Mn, pode ser realizada de forma imediata e simples, reproduzindo-se a arquitetura, pesos, *bias* e funções das redes desenvolvidas, utilizando qualquer tipo de software comercial, seja ele o de uma linguagem de programação visual ou não, ou mesmo de uma planilha eletrônica.

É possível a utilização das RNA's de TEQ e de FW no *software* de controle de *set-up* do LTQ, o que porém exige extensa adaptação dos programas de controle de nível-2, principalmente, para a substituição parcial de modelos existentes. Obviamente, custos e riscos dessa implementação têm ser criteriosamente ponderados com os possíveis ganhos.

Seja para a construção de simuladores *off-line*, ou de sistemas de controle *on-line* do processo do LTQ, é altamente recomendável que sejam exploradas linhas adicionais de desenvolvimentos das RNA's *MFB* mostradas, como por exemplo, generalização para outros tipos de aços, como os de alta resistência microligados ao Nb-Ti-V, aços ULC, como os IF, aços estruturais e aços para fins elétricos de alto Si, e mesmo outros tipos de processos de laminação, como a ferrítica e a de chapas de piso, por exemplo. Isto possivelmente estabelecendo várias RNA's e/ou valores dos parâmetros livres, válidos por hierarquia de produto e processo, ou seja, *steel-grade*, faixas de espessura, largura e temperatura.

Outra possível linha de trabalho diz respeito ao grande número de variações de parâmetros e técnicas de elaboração de RNA's, algumas parcialmente comentadas neste texto, e que também podem ser alvo de experimentações quase ilimitadas, visando a melhoria adicional de desempenho e acerto da rede.

Finalmente, pode ser desenvolvida a aplicação das RNA's como uma adição ao mecanismo de aprendizado (*learning*), que adapta as equações do *FSU* aos resultados reais, configurando-se assim a implementação de um modelo misto, com uma abordagem inicial de modelamento clássico, complementada por outro modelo adicional de rede neural, para o cálculo de *set-up* do LTQ.

REFERÊNCIAS BIBLIOGRÁFICAS

- 1) BAPARI, AFSHIN; et al. **Prediction of Hot Flow Stress of CrMoV Steel Using Artificial Neural Network (ANN)**. ISIJ International, v. 47, 2007, no. 8, p. 1126-1130.
- 2) BARRETO, JORGE M. **Introdução às Redes Neurais Artificiais**. UFSCar: Departamento de Informática e Estatística, 2002, 57 p.
- 3) BRANCO, VANESSA PALA VIEIRA **Análise Crítica do Setor de Resfriamento de Chapas Laminadas a Quente do Aço LN28**. São Paulo: Dissertação de Mestrado em Engenharia Metalúrgica, USP – SP, 2004, 128 p.
- 4) CHO, SANG-HYUN; KANG, KI-BONG; JONAS, J. J. **The Dynamic, Static and Metadynamic Recrystallization of a Nb-Microalloyed Steel**. ISIJ International, 2001, v. 41, no. 1, p. 62-69.
- 5) CLAUMANN, CARLOS ALBERTO. **Desenvolvimento e Aplicações de Redes Neurais Wavelets e da Teoria de Regularização na Modelagem de Processos**. Florianópolis: Dissertação de Mestrado em Engenharia Química, UFSCar, 2003.
- 6) CONSIDERAÇÕES teóricas em redes neurais artificiais. [2000-2005], p. 69-82.
- 7) DEMUTH, HOWARD; BEALE, MARK; HAGAN, MARTIN. **Neural Toolbox 5 User's Guide – MatLab**. Editora Mathworks, inc, www.mathworks.com, Setembro de 2007, 852 p.
- 8) DENTI Fº, JOSÉ; MACHADO, MARCELO LUCAS P. **Modelo Microestrutural de Tamanho de Grão, Cálculo de Tensão de Escoamento Média e Força de Laminação de Aços Carbono e Ligas**. Campos do Jordão: 44º Seminário de Laminação – Processos e Produtos Laminados e Revestidos da ABM, Outubro de 2007.
- 9) GARSON, G. **Intepreting Neural-Network Connection Weighths**. AI Expert, April 1991, p. 47-51.
- 10) GINZBURG, VLADIMIR B. **Steel Rolling Thechnology**. New York : Editora Marcel Dekker, volume 30 de Manufacturing Engineering and Materials Processing, 1989, 791 p.
- 11) GORNI, A. A. **Application of Neural Networks in the Modeling of Plate Rolling Process**. Publicado em JOM-e, Abril de 1997, disponível em www.tms.org/pubs/JOM/9704/Gorni/Gorni-9704.html
- 12) GORNI, A. A. **Modelo Matemático para Determinação da Evolução Microestrutural de Aços C-Mn num Laminador de Tiras a Quente**. Santos: 26º Seminário Interno de Laminação da COSIPA, Abril de 2003.
- 13) GORNI, A. A.; DOLABELA, J. H. **Caracterização da Ocorrência de Recristalização Dinâmica na Laminação de Tiras a Quente**. Belo Horizonte: 60º Congresso Anual da ABM, Julho de 2005.
- 14) GORNI, A. A.; DOLABELA, J. H.; et al. **Influência dos Elementos de Liga Sobre o Efeito da Temperatura na Resistência à Deformação de Aços**. Rio de Janeiro: 61º Congresso Anual da ABM, Julho de 2006.
- 15) GORNI, A. A.; DOLABELA, J. H.; VALLIM, PEDRO S. S.; et al. **Efeito dos Elementos de Liga na Resistência à Deformação a Quente de Aços Estruturais Resistentes à Corrosão Atmosférica**. Vitória: 62º Congresso

- Anual da ABM, Julho de 2007.
- 16) GORNI, A. A.; DOLABELA, J. H.; VALLIM, PEDRO S. S.; et al. **Modelamento Matemático do Efeito dos Elementos de Liga dos Aços na Resistência à Deformação a Quente**. Belo Horizonte: 56º Congresso Anual da ABM, Julho de 2001.
 - 17) GORNI, A. A.; VALLIM, PEDRO S. S. **Efeito da Composição Química na Resistência à Deformação a Quente de Aços de Baixo Carbono**. São Paulo: 59º Congresso Anual da ABM, Julho de 2004.
 - 18) GORNI, A. A.; VALLIM, PEDRO S. S. **Efeito da Recristalização Dinâmica na Resistência à Deformação de Aços Processados no Laminador de Tiras a Quente**. Vitória: 40º Seminário de Laminação – Processos e Produtos Laminados e Revestidos da ABM, Outubro de 2003.
 - 19) GORNI, A. A.; VALLIM, PEDRO S. S.; et al. **Efeito do Boro na Resistência à Deformação a Quente de Aços de Baixo Carbono**. São Paulo: 59º Congresso Anual da ABM, Julho de 2004.
 - 20) HAYKIN, SIMON. **Redes Neurais Princípios e Práticas**. Tradução de Paulo Martins Engel. 2ª edição. Porto Alegre: Editora Bookman, 2001, 900 p.
 - 21) HELMAN, HORÁCIO; CETLIN, PAULO R. **Fundamentos da Conformação Mecânica dos Metais**. Rio de Janeiro: Editora Guanabara Dois, 1983, 179 p.
 - 22) HONEYCOMBE, R. W. K. **Aços Microestrutura e Propriedades**. Lisboa: Editora Fundação Calouste Gulbenkian, 1985, 348 p.
 - 23) HWU, Y. J.; LENARD, J. G. **Application of Neural Networks in the Prediction of Roll Force in Hot Rolling**. Department of Mechanical Engineering of the University of Waterloo, Ontario: Transaction of North American Manufacturing Research Institute/Society of Mechanical Engineering, [1995-2002], p. 85-90.
 - 24) JONAS, J. J. **Effect of Quench and Interpass Time on Dynamic and Static Softening during Hot Rolling**. Materials Technology: Steel Research International, 76, no. 5, 2005, p. 392-398.
 - 25) KINGSTON, G. B.; MAIER, H. R.; LAMBERT, M. F. **A Statistical Input Pruning Method for Artificial Neural Networks Used in Environmental Modeling**. Applied Modeling in Water Engineering. [University of Adelaide], [entre 2002 e 2007]
 - 26) LIPSCHYTZ, SEYMOUR. **Álgebra Linear**. São Paulo: Editora MacGraw-Hill, 1978, 413 p.
 - 27) LU, CHENG; WANG, XIUMEY; et al. **Application of ANN in Combination with Mathematical Models in Prediction Load of the Finishing Stands in HSM**. ISIJ: Proceedings of the 7th International Conference on Steel Rolling, 1998, p. 206-209.
 - 28) LUDWIG JR., OSWALDO; MONTGOMERY, EDUARD. **Redes Neurais Fundamentos e Aplicações em C**. Rio de Janeiro: Editora Ciência Moderna, 2007, 125 p.
 - 29) MACCANO, T. M; et al. **Determination of Recrystallization Stop Temperature from Rolling Mill Logs and Comparison with Laboratory Simulation Results**. ISIJ International, 1994, v. 34, no. 11, p. 917-922.

- 30) MISAKA, YOSHISUKE; YOSHIMOTO, TOMOSKICHI. **Formularization of Mean Resistance to Deformation of Plain Carbon Steels at Elevated Temperature**. Journal of the Japan Society for Thechnology of Plasticity, 1967, v. 8, no. 79, p. 414.
- 31) MURAO, H.; SHIMODA, N.; WAKAMYIA, Y. **Finishing Mill Set-up Calculation (FSU)**. Manual reservado da Mitshubishi Eletric Company, 1996-7-26. 138 p.
- 32) PADILHA, A. F.; SICILIANO, F. **Encruamento, Recristalização, Crescimento de Grão e Textura**. 3ª edição, São Paulo: Editora ABM Livros, 2005, 232 p.
- 33) PLAUT, RONALD LESLEY. **Laminação dos Aços – Tópicos Avançados**. São Paulo: Editora da ABM Livros, 1986, 180 p.
- 34) ROBERTS, WILLIAM L. **Hot Rolling of Steel**. New York : Editora Marcel Dekker, 1983, 1033 p, volume 10 de Manufacturing Engineering and Materials Processing.
- 35) SHIDA, SHIGERU. **Empirical Formula of Flow-Stress of Carbon Steels – Resistance to Deformation of Carbon Steels at Elevated Temperature**. Journal of the Japan Society for Thechnology of Plasticity, 1969, v. 10, no. 103, p. 610-617.
- 36) SICILIANO, F.; et al. **Mathematical Modeling of the Mean Flow Stress, Fraccional Softening and Grain Size during Hot Rolling of C-Mn Steels**. ISIJ International, 1996, v. 36, no. 12, p. 1500-1506.
- 37) SICILIANO, F.; JONAS, J. **Mathematical Modeling of the Hot Strip Rolling of Microalloyed Nb, Multiply-Alloyed Cr-Mo, and Plain C-Mn Steels**. Metallurgical and Materials Transactions, v. 31 A, Fevereiro de 2000, p. 511-530.
- 38) SPIEGEL, MURRAY R.; **Probabilidade e Estatística**. Traduzido por Alfredo Alves Faria. São Paulo: Editora McGraw-Hill do Brasil, 1978, 518 p.
- 39) TAKAHASHI, HIROSHI JORGE. **Predição de Propriedades Mecânicas de Aços de Alta Resistência Microligados Utilizando Técnicas de Inteligência Computacional**. Coronel Fabriciano: Dissertação de Mestrado em Engenharia Industrial, Unileste MG, Dezembro de 2006, 107p.
- 40) TSELIKOV, A. **Stress and Strain in Metal Rolling**. Moscou: Editora MIR Publishers, 1967, 475 p.
- 41) TSELIKOV, A.; NIKITIN, G. S.; ROKOTYAN, S. E. **The Theory of Lengthwise Rolling**. Editora MIR Publishers, 1980, 342 p.
- 42) ZHOU, SHUNXIN; FUNKE, PAUL; ZHONG, JUE. **Influence of roll geometry and strip width on flattenig in flat rolling**. Steel Research, 67, no. 5, 1996, p. 200-204.
- 43) ZHOU, SHUNXIN; FUNKE, PAUL; ZHONG, JUE; PLOCIENNIK, CHRISTIAN. **Modification of a classical formula for determination of roll flattening in flat rolling**. Steel Research, 67, no. 11, 1996, p. 491-494.
- 44) ZHOU, SHUNXIN; ZHONG, JUE; LIU, GUANGLIAN. **Investigation of model error on calculating strip profile in 4-high mills** . Steel Research, 71, no. 10, 2000, p. 403-409..

APÊNDICE A - Resumo do Algoritmo de Retro Propagação (*Backpropagation*)

Para uma RNA *MFB* (*Multilayer, Feedforward, Backpropagation*) o algoritmo de retro propagação do erro pode ser descrito como constituído de cinco etapas:

ETAPA 1: São inicializados os parâmetros livres (*bias* e pesos) da RNA, em uma distribuição uniforme e aleatória, com média nula.

ETAPA 2: São apresentados os casos para treinamento da rede, sendo cada caso, ou exemplo, um vetor de valores correspondente ao conjunto de variáveis de entrada (*inputs*).

ETAPA 3: o sinal é propagado num fluxo de informação desde os neurônios da camada de entrada até os neurônios da camada de saída. Em cada camada, os sinais de entrada são ponderados pelos pesos sinápticos (w_{ji}) da conexão para cada neurônio (j), e somados juntamente com o valor de *bias* (b_j) do neurônio através da função soma (v_j), sendo esse valor transformado pela função de ativação ($\phi_j(v_j)$) de forma a resultar no sinal de saída y_j . As funções de soma e ativação são representadas pelas expressões abaixo:

$$v_j = \sum_{i=0}^{n_j} (w_{ji} \cdot x_{ji}) = b_j + \sum_{i=1}^{n_j} (w_{ji} \cdot x_{ji}) \quad (3.1)$$

$$\phi_j = \phi_j(v_j) \quad (3.2)$$

O sinal de saída da última camada serve para calcular o erro de propagação (e_j) do neurônio (j), comparando-se o seu valor com o valor desejado, ou *target*, (d_j), obtendo-se assim, para o conjunto de neurônios da camada de saída o erro global instantâneo (E_t) da iteração (t).

$$(e_j)_t = (d_j - y_j)_t \rightarrow E_t = \left(\frac{1}{2} \cdot \sum_{j=1}^{n_m} (e_j^2) \right)_t \quad (3.9)$$

ETAPA 4: o sinal é retro propagado num fluxo contínuo de atualização dos pesos e *bias*, a partir do sinal de erro obtido na camada de saída, até a camada de entrada. Nesta etapa são encontradas duas situações de ajuste de parâmetros: ajuste na camada de saída e em camadas anteriores às de saída da rede. Para ambos os casos, o ajuste começa com a determinação do gradiente local (δ_j) de cada o neurônio da camada considerada, gradiente este que serve de base para a correção dos valores de pesos e *bias*.

Assim, para a camada de saída, tem-se a seguinte expressão de cálculo do gradiente local:

$$(\delta_j)_t = (-e_j \cdot \varphi'_j(v_j))_t \quad (3.14)$$

As quantidades de correções de pesos (w_{ji}) das conexões, e *bias* (b_j) dos neurônios para a camada de saída são dadas respectivamente por:

$$(\Delta w_{ji})_t = (-\eta \cdot \delta_j \cdot y_i)_t = (\eta \cdot e_j \cdot y_i \cdot \varphi'_j(v_j))_t \quad (3.16a)$$

$$(\Delta b_j)_t = (-\eta \cdot \delta_j \cdot y_i)_t = (\eta \cdot e_j \cdot y_i \cdot \varphi'_j(v_j))_t \quad (3.16b)$$

Para a camada intermediária, imediatamente anterior à de saída, o gradiente local de cada neurônio é dado por:

$$(\delta_i)_t = \left(\varphi'_i(v_i) \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.22)$$

Com as quantidades de correções de pesos (w_{ji}) das conexões, e *bias* (b_j) dos neurônios para essa camada intermediária, anterior à de saída sendo dadas por:

$$(\Delta w_{zi})_t = (-\eta \cdot \delta_i \cdot y_z)_t = \left(-\eta \cdot \varphi'_i(v_i) \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.23a)$$

$$(\Delta b_i)_t = (-\eta \cdot \delta_i \cdot y_z)_t = \left(-\eta \cdot \varphi'_i(v_i) \cdot \sum_{j=1}^{n_m} (\delta_j \cdot w_{ji}) \right)_t \quad (3.23b)$$

Nas expressões anteriores, o parâmetro de aprendizagem (η) pode ser constante ou variado de acordo com alguma estratégia, como a abaixo exemplificadas, na qual essa taxa decresce com a quantidade de iterações (n_t), na iteração (t):

$$(\eta)_t = \left(\frac{\eta_0}{1 + \left(\frac{n_t}{\tau} \right)} \right)_t$$

Nessa expressão, (η_0), (η_0) e (τ) são constantes de controle do ajuste da variação da taxa de aprendizado. Para as demais camadas intermediárias, o processo continua de forma análoga.

Para a camada de entrada, os valores de sinais de entrada devem ser tomados como x_z , que são os valores de *input* da rede, substituindo assim os y_z nas expressões de ajuste de pesos e *bias* das camadas intermediárias.


Para maior estabilização do ajuste, pode-se adotar uma suavização da correção de pesos, adicionando-se uma constante de momento (α), que faz a ponderação entre o ajuste atual e o da iteração anterior, conforme abaixo:


$$(\Delta w_{ji})_t = (\Delta w_{ji})_{t-1} + \alpha \cdot (\Delta w_{ji})_{t-1}, \text{ com } : 0 \leq \alpha \leq 1 \quad (3.25a)$$


ETAPA 5: são executadas iterações, cada uma delas conforme descrito nas etapas 3 e 4, apresentando à rede novas épocas de treinamento, sendo a ordem de apresentação dos casos aleatória, de época para época, até que seja satisfeito o critério de parada de processamento. Tal critério pode ser um número máximo de iterações ou um valor limite para o erro médio global. Para cada época de treinamento (T), o erro global médio da rede (E_T), utilizado para teste e finalização do processamento, é dado por:


$$\bar{E}_T = \left(\frac{1}{N} \cdot \sum_{i=1}^N E_i \right)_T \quad (3.10)$$


APÊNDICE B - Exemplo Simples de Aplicação do Algoritmo de Retro Propagação











APÊNDICE C - Conceitos Sobre o Algoritmo de Treinamento *Levenberg-Marquardt*

O algoritmo de *Levenberg-Marquardt* é uma das técnicas de otimização irrestritas, que visam minimizar uma função de custo diferenciável $E(W)$, sendo W um vetor de pesos qualquer (Demuth, et al, 2007) (Haikin, 2001).

Inicialmente, uma solução ótima, com pesos W^* , é dada por:

$$E(W^*) \leq E(W) \rightarrow \nabla E(W^*) = 0$$

Seja $g = \nabla E(W)$ o vetor gradiente da função de custo, dada pela matriz transposta mostrada abaixo:

$$g = \nabla E(W) = \left[\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_m} \right]$$

Assim, a cada iteração (t) a função custo é reduzida, e o vetor de pesos W é atualizado:

$$(E(W))_{t+1} < (E(W))_t \rightarrow E(W_{t+1}) < E(W_t)$$

Pelo método da descida mais íngreme, ou do gradiente descendente, a função custo é aproximada por uma série de Taylor de 1ª ordem, sendo a correção dos pesos proporcional ao gradiente (através da taxa de aprendizado η), porém no sentido contrário ao mesmo. Ou seja:

$$(E(W))_{t+1} \cong (E(W) + g^T \cdot \Delta W)_t$$

$$(\Delta W)_t = W_{t+1} - W_t = (-\eta \cdot g)_t$$

Pelo método de *Newton*, a aproximação da função de custo é dada por uma série de Taylor de 2ª ordem, e a correção de pesos é proporcional ao inverso da matriz Hessiana (H , de derivadas 2ª), que multiplica o gradiente, conforme abaixo:

$$(E(W))_{t+1} \cong \left(E(W) + g^T \cdot \Delta W + \frac{1}{2} \cdot \Delta W^T \cdot H \cdot \Delta W \right)_t \xrightarrow{\text{Minimização}} (g + H \cdot \Delta W)_t = 0$$

$$(\Delta W)_t = W_{t+1} - W_t = (-H^{-1} \cdot g)_t$$

Sendo a matriz Hessiana dada por:

$$H = \nabla^2 E(W) = \begin{pmatrix} \frac{\partial^2 E}{\partial w_1^2} & \frac{\partial^2 E}{\partial w_1 \cdot \partial w_2} & \cdots & \frac{\partial^2 E}{\partial w_1 \cdot \partial w_m} \\ \frac{\partial^2 E}{\partial w_2 \cdot \partial w_1} & \frac{\partial^2 E}{\partial w_2^2} & \cdots & \frac{\partial^2 E}{\partial w_2 \cdot \partial w_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_m \cdot \partial w_1} & \frac{\partial^2 E}{\partial w_m \cdot \partial w_2} & \cdots & \frac{\partial^2 E}{\partial w_m^2} \end{pmatrix}$$

Embora mais eficiente do que o método do gradiente descendente, o método de Newton exige que o inverso da matriz Hessiana seja definida positivamente para toda iteração (t) o algoritmo, o que não é garantido.

O método de *Gauss-Newton* considera a função custo expressa como a soma de erros quadrados, sendo $\mathbf{W}$ fixo no intervalo $0 \leq i \leq n_t$, por sua vez função linear do vetor de pesos ajustável $(\mathbf{W})_t$:

$$E(W) = \frac{1}{2} \cdot \sum_{i=1}^{n_t} e_i^2, \text{ com } W \text{ fixo}$$

$$e_i^{NEW}(W) = e_i + \left[\frac{\partial e_i}{\partial W} \right]_{W=(W)_t}^T \cdot (W - (W)_t), i = 1, 2, \dots, n$$

Matricialmente, pode-se considerar:

$$e^{NEW}(W) = (e + J \cdot (W - (W)_t))_t$$

Onde $(e)_t$ é o vetor de erros, expresso pela matriz transposta:

$$(e)_t = \left([e_1, e_2, \dots, e_t, \dots, e_{n_t}]^T \right)_t$$

E J é a matriz Jacobiana $n_t \times m$ dos erros $(e)_t$, que é igual à transposta da matriz de gradientes dos erros, conforme abaixo indicado, para cada iteração (t).

$$(J)_t = \begin{pmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \cdots & \frac{\partial e_1}{\partial w_m} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \cdots & \frac{\partial e_2}{\partial w_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{n_t}}{\partial w_1} & \frac{\partial e_{n_t}}{\partial w_2} & \cdots & \frac{\partial e_{n_t}}{\partial w_m} \end{pmatrix}_{W=W_t} = \left([\nabla e_1, \nabla e_2, \dots, \nabla e_{n_t}]^T \right)_t = (\nabla e^T)_t$$

Como o vetor de pesos atualizado $(W)_{t+1}$ é definido como sendo o argumento que minimiza o erro (e^{NEW}), pode-se calcular a norma euclidiana quadrática desse erro, visando sua diferenciação para obtenção da condição de minimização.

Assim (fazendo $(a+b \cdot c)^2 / 2$):

$$\frac{1}{2} \cdot \|e^{NEW}(W)\|^2 = \frac{1}{2} \cdot \|e\|^2 + e^T \cdot J \cdot (W - (W)_t) + \frac{1}{2} \cdot (W - (W)_t)^T \cdot J^T \cdot J \cdot (W - (W)_t)$$

$$\xrightarrow{\text{Minimização}} (J^T \cdot e + J^T \cdot J \cdot (W - (W)_t))_t = 0$$

Equação que resolvida para $(W)_t$ fornece:

$$(\Delta W)_t = W_{t+1} - W_t = - (J^T \cdot J)^{-1} \cdot J^T \cdot e_t$$

Novamente, encontra-se uma condição necessária que é a de não singularidade da matriz $(J^T \cdot J)$. Para contornar essa dificuldade é adicionada à referida matriz uma parcela correspondente ao produto do escalar μ , constante de pequeno valor positivo, à matriz diagonal unitária I , para que se garanta ser essa parcela sempre definida positivamente, para toda iteração (t) . Desta forma a correção do vetor de pesos modificada é dada pela expressão:


$$(\Delta W)_t = W_{t+1} - W_t = - (J^T \cdot J + \mu \cdot I)^{-1} \cdot J^T \cdot e_t$$

Esta última equação expressa a essência do algoritmo de *Levenberg-Marquardt*. Quando o escalar μ é nulo o algoritmo passa a ser o de *Newton*, com matriz Hessiana aproximada pela Jacobiana (método *Quasi-Newton*). Para valores elevados de μ , o algoritmo se aproxima do método do gradiente descendente, com passo de pequeno valor.

A aplicação do método de *Levenberg-Marquardt*, pode ser dividida em duas etapas utilizadas seqüencialmente até a convergência. Na primeira calculam-se as saídas de todos os neurônios para o lote de casos de treinamento correspondente a uma época, com os pesos permanecendo fixos. Com estas informações calculam-se as derivadas parciais dos erros em relação aos pesos para todos os casos. Na etapa seguinte, os pesos devem ser ajustados de acordo com a equação de correção dada. Deve-se notar que um sistema linear tem que ser resolvido a cada época para o cálculo das correções.

No algoritmo *Levenberg-Marquardt*, é adotada ainda a estratégia de ajuste do escalar μ a cada iteração, para aumentar a eficácia da busca do erro mínimo. Partindo-se de um valor μ_0 inicial, como o método de Newton é mais rápido próximo ao ponto de erro mínimo, o valor de μ é reduzido a cada iteração na qual ocorre redução da função de performance (erro médio quadrático). Caso contrário, ele é aumentado. Pode-se ainda ser estabelecido um valor limite para μ , sendo este mais um critério de parada do algoritmo.

APÊNDICE D - Lay-Out e Características da Linha de Tiras a Quente Número 1 da COSIPA



Companhia Siderúrgica Paulista			66" Hot Strip Mill Line		Cubatão / SP - Brazil	
Rolling Schedule						
Slab	Strip	Coil	Steel Grade	Suppliers		
Thickness 210 mm 690 ~ 1500	Thickness 200 ~ 1200 mm av = 3.65 mm	Weight : av = 12.1 t (S ~ 1.6)	(S = smooth; F = Floor Plate) Low Carbon Steel (S&F)	Furnace 1 & 2 : Sten-Roubaux		
Length 5200 ~ 6400 mm	Width 690 ~ 1600 mm av = 1208 mm	Specific Weight (kg/m²) av = 9.85 kg/m²	Medium Carbon Steel (S&F)	Furnace 3 : Itaipubim		
Transfer Bar Thickness 28 ~ 32 mm	Production 2.1 Mt/year	Smooth : av = 9.88 kg/m²	High Carbon Steel (S)	Roughing R1 : Pratimanga Motor G&E		
Usual = 32 mm		Floor plate : av = 9.52 kg/m²	IF Steel (S)	Roughing R2 : Seim United Motor		
		Inside : 610 ~ 630 mm	HSLA (S)	Westinghouse		
		Outside : 1224 ~ 1550 mm	API (S)	HSM : Mesta Motor Westinghouse		
			GNO (S-feritic)	Automation NELCO		
			Structural High-St (S)	Downcoilers : (1) & (2) Itaipubim (3) Demag		
Technical Data (Mill Start up : R1 - Dec/1985; R2 - Dec/1983 ; HSM - May/1964)						
Installed Power = 31.332 kW		Roughing Train = 10.444 kW		Finishing Train = 20.888 kW		
Furnace	Stand	Roll Dimensions (mm)	MC-Power (kW)	MC-Revolutions (rpm)	Roll-Speed (m/s)	Gear Ratio (r : 1)
Polar type	E1	ER - 2 914 814 x 576	DC - 2 x 33	10 20 30 40	av = 0.5 0.9 1.4	1.45
	R1	WR - 2 1075 975 x 1980	DC - 2 x 2611	55 70	1.8 2.5 3.2	1
	BUR - 2 1470 1320 x 1980		(usual = 40 55)	(usual = 1.5 2.5)		
	E2	ER - 2 910 880 x 500	DC - 2 x 746	av = 17 15 14	0.8 1.6 2.5 3.3	5.35
Bentons x Zonas (row)	R2	WR - 2 940 866 x 2750	DC - 2 x 2611	70 88 104	4.2 4.9	1
	BUR - 2 1350 1100 x 2476		(usual = 40 70)	(usual = 2.5 3.3)		
	F1	2 668 605 x 1726	DC - 1 x 1730	130 413	0.95 1.55	5.57
	F2	2 668 605 x 1726	DC - 1 x 1730	150 325	1.73 4.15	2.68
Bentons x Zonas (row)	F3	2 668 605 x 1726	DC - 1 x 1730	170 359	2.95 6.71	1.78
	F4	2 668 605 x 1726	DC - 1 x 1730	120 255	2.70 5.71	1
	F5	2 668 605 x 1726	DC - 1 x 1730	135 310	4.17 10.6	1
	F6	2 668 605 x 1726	DC - 1 x 2984	150 340	4.63 11.61	1
BUR F1 ~ F6						
Crop Shear						
With Optimization System (KELCO)		Others : WR & BUR Lubrication F1 ~ F5				
Strip Cooling		Downcoilers				
Type : Laminar Flow by nozzles	Collar 1 ~ No Hyd	2 - 660	DC - 1 x 224	125 335	4.5 11.9	1
5 banks x 6 headers - 1 venturi bank x 11 header	PR	2 - 914 877 wip	DC - 1 x 56	195	9.3 9.0	1
		2 - 436 430 bot	DC - 1 x 76	485	10.3 10.2	1
	Collar 3 No Hyd	2 - 660	DC - 1 x 173	140 1120	4.7 15.5	2.5
		2 - 914 877 wip	DC - 1 x 136	480	9.1 8.7	2.5
		2 - 441 435 bot	DC - 1 x 186	460	11.1 10.9	1
Note (1) = weight, width						

APÊNDICE E - Tabelas de Variáveis de Processo da Base de Dados Utilizada

Base de dados original da qual foram selecionados os <i>inputs</i> e <i>targets</i> das RNA's de Tensão de Escoamento a Quente (TEQ) e de Força de Específica de Laminação (FW = força / largura).										
No	Tipo	Descrição	Set-Up / Real	Fonte	Unidade	Código	Dados inicial e final do lote de 7472 bobinas (cadeira F1)		Variáveis das RNA's	
							Tira Inicial	Tira final	TEQ	FW
1	1	Código da bobina	-----	Sistema	-----	COIL	834387-0	856824-0		
2	1	Data de laminação	Real	Sistema	-----	DATE	01/11/2007 00:13:00	22/11/2007 10:30:03		
3	1	Cadeira do LTQ	-----	Sistema	-----	STAND	1	1		
4	1	Rolling Steel Grade	Set-Up	Modelo FSU	-----	RSG	65	65		
5	1	Hierarquia de espessura	Set-Up	Modelo FSU	-----	H_T	13	14		
6	1	Hierarquia de largura	Set-Up	Modelo FSU	-----	H_W	4	5		
7	1	Espessura	Set-Up	Sistema	(mm)	STRIP_TH	6.34	6.55		
8	1	Largura	Set-Up	Sistema	(mm)	STRIP_W	1316	1519		
9	1	Código do aço	-----	Sistema	-----	STEEL_N	424	532		
10	1	Teor de carbono	Real	Sistema	(%)	C	0.14200	0.16500	Input 01	Input 01
11	1	Teor de manganês	Real	Sistema	(%)	Mn	0.76000	0.83000	Input 02	Input 02
12	1	Teor de fósforo	Real	Sistema	(%)	P	0.01600	0.01300		
13	1	Teor de enxofre	Real	Sistema	(%)	S	0.00300	0.01300		
14	1	Teor de silício	Real	Sistema	(%)	Si	0.14000	0.26000	Input 03	Input 03
15	1	Teor de cobre	Real	Sistema	(%)	Cu	0.00000	0.00000	Input 04	Input 04
16	1	Teor de alumínio	Real	Sistema	(%)	Al	0.01900	0.03700		
17	1	Teor de boro	Real	Sistema	(%)	B	0.00010	0.00010		
18	1	Teor de nióbio	Real	Sistema	(%)	Nb	0.00200	0.00300		
19	1	Teor de vanádio	Real	Sistema	(%)	V	0.00100	0.00100		
20	1	Teor de titânio	Real	Sistema	(%)	Ti	0.00100	0.00100		
21	1	Teor de níquel	Real	Sistema	(%)	Ni	0.01000	0.01000		
22	1	Teor de cromo	Real	Sistema	(%)	Cr	0.02000	0.02000	Input 04	Input 04
23	1	Teor de molibdênio	Real	Sistema	(%)	Mo	0.00000	0.00000		
24	2	Diâmetro médio dos cilindros de trabalho	Real	Medido	(mm)	D_WR	636.49	634.00	Input 05	Input 05

Base de dados original da qual foram selecionados os *inputs* e *targets* das RNA's de Tensão de Escoamento a Quente (TEQ) e de Força de Específica de Laminação (FW = força / largura).

No	Tipo	Descrição	Set-Up / Real	Fonte	Unidade	Código	Dados inicial e final do lote de 7472 bobinas (cadeira F1)		Variáveis das RNA's	
							Tira Inicial	Tira final	TEQ	FW
25	2	Raio achatado médio dos cilindros de trabalho	Real SP	Modelo FSU	(mm)	WRA_SP	328.99	327.39		
26	2	Raio achatado estimado	Real Estimado	Cálculo (*)	(mm)	WRA_EST	339.5	337.1	Input 06	Input 06
27	2	Velocidade dos cilindros de trabalho	Real SP	Real Medido	(mpm)	V_WR_SP	62.0	52.4	Input 07	Input 07
28	2	Força de bender	Real SP	Real Medido	(Tf/mancal)	FB_SP	74.2	57.4		Input 08
29	2	Espessura de entrada na cadeia	Real SP	Modelo FSU	(mm)	FDH_E	30.000	30.000	Input 08	Input 09
30	2	Espessura de saída da cadeia	Real SP	Modelo FSU	(mm)	FDH_GM	20.283	19.560	Input 09	Input 10
31	2	Temperatura de laminação na cadeia	Real SP	Modelo FSU	(oC)	TR_EX_S	961.0	982.0		
32	2	Temperatura estimada no passe	Real	Cálculo (*)	(oC)	TLAME	961.0	973.8	Input 10	Input 11
33	2	Temperatura de entrada no LTQ	Real	Medida por pirômetro	(oC)	FET_ADS	1014.0	1040.0		
34	2	Temperatura de saída do LTQ	Real	Medida por pirômetro	(oC)	FDT_SP	869.1	859.0		
35	2	TENSÃO DE ESCOAMENTO A QUENTE CALCULADA	Set-Up	Modelo FSU	(Kg/mm ²)	KM_S	20.52	20.15		
36	2	TENSÃO DE ESCOAMENTO A QUENTE REAL	Real	Modelo FSU	(Kg/mm ²)	KM_L	20.34	20.20	Target	
37	2	FORÇA CALCULADA	Set-Up	Modelo FSU	(Tf)	FT_S	1495.5	1696.9		
38	2	FORÇA REAL	Real	Medida por célula de carga	(Tf)	FT_SP	1466.0	1705.8		
39	2	FORÇA ESPECÍFICA CALCULADA	Set-Up	Modelo FSU	(Tf/mm)	FT_S/W	1.1364	1.1171		
39	2	FORÇA ESPECÍFICA REAL	Real	Medida por célula de carga	(Tf/mm)	FT_SP/W	1.1140	1.1230		Target

Notas:

- (1) A coluna *Tipo* refere-se ao tipo de dado: tipo 1 dado relacionado ao material laminado; tipo 2 dado relacionado com a cadeia do LTQ.
- (2) A coluna *Set-Up / Real* refere-se a como deve ser considerado o dado: *Set-Up* significa calculado pelo modelo de *set-up*; *Real* significa dado que foi medido diretamente, ou, de forma indireta, calculado a partir de dados reais de outras variáveis.
- (3) A coluna *Fonte* indica de onde se originou o dado. Especificamente quando nela indicado Cálculo (*), significa que a variável foi *estimada de forma alternativa, como uma aproximação do dado original calculado pelo modelo de set-up*. Essa estimativa, obtida por regressão múltipla de variáveis de processo primárias e facilmente disponíveis em sistema, tem razoável grau de aproximação, e simplifica bastante seu uso, já que o dado original exige cálculo complexo e recursivo. É exemplo desse tipo dado o raio achatado de cilindros e a temperatura de laminação da tira, em cada cadeia do LTQ. Nesse caso são variáveis necessárias ao cálculo da TEQ e FW, mas ao mesmo tempo dependentes da TEQ e FW, o que demanda originalmente para a sua obtenção um cálculo recursivo dentro da rotina do modelo de *set-up* do LTQ.
- (4) As colunas *Tira inicial* e *Tira final* mostram exemplos de valores e de formatação dos dados das variáveis. São mostrados os vetores de dados do primeiro e último caso, respectivamente da primeira e da última tira do lote de 7472 bobinas utilizadas para a elaboração das RNA's. Dentre essas variáveis está data de laminação, cujos dados mostram a data de início e fim dessa produção de bobinas, correspondendo ao período de 01 e 22/11/2007.
- (5) Nas duas colunas finais estão indicadas as variáveis selecionadas a serem *inputs* e *targets* das RNA's de TEQ e de FW. As razões dessa seleção estão mencionadas adiante nos capítulos que descrevem as aplicações de RNA à determinação da TEQ e FW.
- (6) Na tabela está contida a rastreabilidade dos dados utilizados através do conteúdo das variáveis *Código de bobinas* e *Data de laminação*.

APÊNDICE F - Resumo Estatístico dos Valores das Variáveis da Base de Dados

Resumo estatístico das variáveis da base de dados original da qual foram selecionados os <i>inputs</i> e <i>targets</i> das RNA's													
No	Tipo	Descrição	Unidade	Código	Média	Mediana	Moda	Desvio padrão	Mínimo	Máximo	Contagem	Variáveis das RNA's	
												TEQ	FW
1	1	Código da bobina	-----	COIL	-----	-----	-----	-----	834387-0	856824-0	7472		
2	1	Data de laminação	-----	DATE	-----	-----	-----	-----	01/11/2007 00:13:00	22/11/2007 10:30:03	7472		
3	1	Cadeira do LTQ	-----	STAND	-----	-----	-----	-----	1	6	7472		
4	1	Rolling Steel Grade	-----	RSG	62.7	62.0	62.0	1.1	60	66	7472		
5	1	Hierarquia de espessura	-----	H_T	7.4	7.0	6.0	3.0	3	14	7472		
6	1	Hierarquia de largura	-----	H_W	2.9	3.0	3.0	1.0	1	5	7472		
7	1	Espessura	(mm)	STRIP_TH	3.303	3.040	3.500	1.107	2.000	7.070	7472		
8	1	Largura	(mm)	STRIP_W	1185.7	1214.0	1223.0	147.9	768.0	1589.0	7472		
9	1	Código do aço	-----	STEEL_N	-----	-----	-----	-----	-----	-----	7472		
10	1	Teor de carbono	(%)	C	0.071844	0.054000	0.037000	0.048836	0.023000	0.481000	7472	Input 01	Input 01
11	1	Teor de manganês	(%)	Mn	0.377634	0.330000	0.240000	0.217544	0.110000	1.650000	7472	Input 02	Input 02
12	1	Teor de fósforo	(%)	P	0.014852	0.014000	0.014000	0.003496	0.007000	0.030000	7472		
13	1	Teor de enxofre	(%)	S	0.008395	0.008000	0.007000	0.002561	0.001000	0.020000	7472		
14	1	Teor de silício	(%)	Si	0.041526	0.010000	0.010000	0.087707	0.000000	0.430000	7472	Input 03	Input 03
15	1	Teor de cobre	(%)	Cu	0.008130	0.010000	0.010000	0.020187	0.000000	0.270000	7472	Input 04	Input 04
16	1	Teor de alumínio	(%)	Al	0.050749	0.053000	0.055000	0.015019	0.000000	0.171000	7472		
17	1	Teor de boro	(%)	B	0.000273	0.000100	0.000100	0.000591	0.000000	0.007700	7472		
18	1	Teor de nióbio	(%)	Nb	0.001004	0.001000	0.000000	0.001023	0.000000	0.008000	7472		
19	1	Teor de vanádio	(%)	V	0.000877	0.001000	0.001000	0.000807	0.000000	0.004000	7472		
20	1	Teor de titânio	(%)	Ti	0.000804	0.001000	0.001000	0.000519	0.000000	0.005000	7472		
21	1	Teor de níquel	(%)	Ni	0.010258	0.010000	0.010000	0.002550	0.000000	0.050000	7472		
22	1	Teor de cromo	(%)	Cr	0.021732	0.020000	0.020000	0.040903	0.010000	0.540000	7472	Input 04	Input 04
23	1	Teor de molibdênio	(%)	Mo	0.000044	0.000000	0.000000	0.000663	0.000000	0.010000	7472		

Resumo estatístico das variáveis da base de dados original da qual foram selecionados os <i>inputs</i> e <i>targets</i> das RNA's													
No	Tipo	Descrição	Unidade	Código	Média	Mediana	Moda	Desvio padrão	Mínimo	Máximo	Contagem	Variáveis das RNA's	
												TEQ	FW
24	2	Diâmetro médio dos cilindros de trabalho	(mm)	D_WR	642.82	642.76	661.18	10.96	618.93	669.33	6 x 7472	Input 05	Input 05
25	2	Raio achatado médio dos cilindros de trabalho	(mm)	WRA_SP	372.38	363.93	326.05	41.72	323.81	699.22	6 x 7472		
26	2	Raio achatado estimado	(mm)	WRA_EST	372.38	364.05	324.51	40.24	313.99	507.11	6 x 7472	Input 06	Input 06
27	2	Velocidade dos cilindros de trabalho	(mpm)	V_WR_SP	217.86	198.00	64.40	125.95	46.60	548.80	6 x 7472	Input 07	Input 07
28	2	Força de bender	(Tf/mancal)	FB_SP	38.55	39.20	46.00	19.63	0.00	103.60	6 x 7472		Input 08
29	2	Espessura de entrada na cadeia	(mm)	FDH_E	12.16	8.58	30.00	9.15	2.30	34.00	6 x 7472	Input 08	Input 09
30	2	Espessura de saída da cadeia	(mm)	FDH_GM	7.71	5.93	3.27	4.87	1.93	21.97	6 x 7472	Input 09	Input 10
31	2	Temperatura de laminação na cadeia	(oC)	TR_EX_S	933.0	935.0	888.0	29.5	845.0	1028.0	6 x 7472		
32	2	Temperatura estimada no passe	(oC)	TLAME	929.0	929.2	949.3	26.6	841.3	1001.5	6 x 7472	Input 10	Input 11
33	2	Temperatura de entrada no LTQ	(oC)	FET_ADS	1041.2	1040.0	1040.0	14.5	952.0	1100.0	6 x 7472		
34	2	Temperatura de saída do LTQ	(oC)	FDT_SP	869.5	869.1	869.4	7.4	830.2	920.0	6 x 7472		
35	2	TENSÃO DE ESCOAMENTO A QUENTE CALCULADA	(Kgf/mm ²)	KM_S	22.70	22.76	20.67	2.95	15.48	32.12	6 x 7472		
36	2	TENSÃO DE ESCOAMENTO À QUENTE REAL	(Kgf/mm ²)	KM_L	22.63	22.72	22.98	3.00	15.36	33.70	6 x 7472	Target	
37	2	FORÇA CALCULADA	(Tf)	FT_S	1235.4	1213.7	993.5	341.9	399.3	2489.3	6 x 7472		
38	2	FORÇA REAL	(Tf)	FT_SP	1241.4	1221.8	902.8	344.2	371.2	2489.0	6 x 7472		
39	2	FORÇA ESPECÍFICA CALCULADA	(Tf/mm)	FT_SW	1.04293	1.03935	0.78258	0.26358	0.32890	2.15576	6 x 7472		
39	2	FORÇA ESPECÍFICA REAL	(Tf/mm)	FT_SP/W	1.04797	1.04711	0.80000	0.26529	0.32840	2.03516	6 x 7472		Target

APÊNDICE G – Tabelas de Valores dos Parâmetros do Algoritmo de Treinamento das RNA's de TEQ e FW

Parâmetros do algoritmo de treinamento Levenberg-Marquardt da RNA de TEQ		F1	F2	F3	F4	F5	F6	Condição	Objetivo
1	Intervalo de passes de adaptação	1	1	1	1	1	1	Padrão	Learning
2	Número máximo de épocas	150	150	150	150	150	150	Imposto	Early stoppage
3	Mínimo erro global médio	0.01	0.01	0.01	0.01	0.01	0.01	Imposto	Early stoppage
4	Máximo número de iterações com erro de validação	5	5	5	5	5	5	Imposto	Early stoppage
5	Processamento simultâneo de toda a matriz Jacobiana (1) ou particionada em submatrizes (acima de 1)	1	1	1	1	1	1	Padrão	Memory reduction resource
6	Mínimo valor do gradiente de performance	0.000	0.000	0.000	0.000	0.000	0.000	Padrão	Early stoppage
7	Valor inicial do escalar mi multiplicador da matriz identidade	0.001	0.001	0.001	0.001	0.001	0.001	Padrão	To avoid division by singular matrix
8	Decrescimento de mi no caso de redução da função de performance em uma iteração	0.100	0.100	0.100	0.100	0.100	0.100	Padrão	Faster training
9	Acréscimo de mi no caso do aumento da função de performance em uma iteração	10.000	10.000	10.000	10.000	10.000	10.000	Padrão	Faster training
10	Máximo valor de mi	1.0E+10	1.0E+10	1.0E+10	1.0E+10	1.0E+10	1.0E+10	Padrão	Early stoppage
11	Intervalo de épocas para exibição de performance em tela	5	5	5	5	5	5	Imposto	Screen update
12	Máximo tempo de treinamento em segundos	Inf	Inf	Inf	Inf	Inf	Inf	Padrão	Early stoppage

Notas:

(1) o algoritmo automaticamente executa o pré-processamento dos sinais de entrada (inputs) e o pós-processamento dos sinais de saída (outputs) utilizando matriz de valores mínimos e máximos dos casos do lote de treinamento.

(2) não se utilizou modificação da função de performance (erro global médio), para regularização

Parâmetros do algoritmo de treinamento Levenberg-Marquardt da RNA de FW										Objetivo
	F1	F2	F3	F4	F5	F6	Condição			
1	Intervalo de passes de adaptação	1	1	1	1	1	Padrão	1	Padrão	Learning
2	Número máximo de épocas	150	150	150	150	150	Imposta	150	Imposta	Early stoppage
3	Mínimo erro global médio	0.0001	0.0001	0.0001	0.0001	0.0001	Imposta	0.0001	Imposta	Early stoppage
4	Máximo número de iterações com erro de validação	5	5	5	5	5	Imposta	5	Imposta	Early stoppage
5	Processamento simultâneo de toda a matriz Jacobiana (1) ou particionada em submatrizes (acima de 1)	1	1	1	1	1	Padrão	1	Padrão	Memory reduction resource
6	Mínimo valor do gradiente de performance	0.000	0.000	0.000	0.000	0.000	Padrão	0.000	Padrão	Early stoppage
7	Valor inicial do escalar mi multiplicador da matriz identidade	0.001	0.001	0.001	0.001	0.001	Padrão	0.001	Padrão	To avoid division by singular matrix
8	Decrescimento de mi no caso de redução da função de performance em uma iteração	0.100	0.100	0.100	0.100	0.100	Padrão	0.100	Padrão	Faster training
9	Acréscimo de mi no caso do aumento da função de performance em uma iteração	10.000	10.000	10.000	10.000	10.000	Padrão	10.000	Padrão	Faster training
10	Máximo valor de mi	1.0E+10	1.0E+10	1.0E+10	1.0E+10	1.0E+10	Padrão	1.0E+10	Padrão	Early stoppage
11	Intervalo de épocas para exibição de performance em tela	5	5	5	5	5	Imposta	5	Imposta	Screen update
12	Máximo tempo de treinamento em segundos	Inf	Inf	Inf	Inf	Inf	Padrão	Inf	Padrão	Early stoppage

Notas:

(1) o algoritmo automaticamente executa o pré-processamento dos sinais de entrada (inputs) e o pós-processamento dos sinais de saída (outputs) utilizando matriz de valores mínimos e máximos dos casos do lote de treinamento.

(2) não se utilizou modificação da função de performance (erro global médio), para regularização

APÊNDICE H - Tabelas de Parâmetros Livres das RNA's de TEQ

PARÂMETROS LIVRES		RNA	TEQ	Cadeira	F1
-------------------	--	-----	-----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	10	neurônios	x	10	inputs	RNA	de	TEQ	Cadeira	F1
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10
1	-1.78E+01	1	-7.99E-01	4.05E+00	-3.63E+00	-6.24E-01	6.47E-01	1.74E-01	2.86E-01	1.28E+00	-4.75E+00	-3.79E-02
2	1.67E+01	2	-2.92E+00	-8.34E-01	7.19E-01	2.06E+00	1.64E+00	-8.54E-03	4.12E-03	3.75E-02	-2.58E-02	-1.43E-02
3	-1.09E+01	3	4.08E-02	3.51E-01	2.79E+00	6.99E-01	1.97E+00	-6.73E-02	-8.87E-02	4.42E-01	4.83E-01	1.74E-02
4	1.24E+01	4	5.11E+00	2.22E+00	-2.14E+00	3.04E+00	1.21E+00	2.34E-01	-1.47E-01	-1.18E+00	3.33E+00	-1.25E-01
5	1.59E+01	5	-3.84E+00	1.10E+00	-1.99E+00	3.68E+00	-2.25E-01	-7.56E-02	-8.81E-02	2.53E-01	-1.39E-01	7.97E-03
6	1.84E+01	6	2.85E+00	-1.97E-01	8.32E-01	-3.76E+00	9.10E-02	1.93E-02	5.57E-02	-1.94E-01	1.55E-01	-2.70E-02
7	1.58E+01	7	2.79E+00	-2.73E-01	1.53E+00	-1.36E+00	3.47E-01	2.98E-04	8.27E-03	3.69E-03	6.97E-02	-1.90E-02
8	3.06E+00	8	-1.75E+00	-1.02E+00	-7.23E-01	7.95E-01	-4.51E+00	1.68E-01	-2.82E-02	-2.00E-01	1.15E-01	-5.00E-02
9	3.04E+01	9	-3.78E+00	-1.30E+00	-1.17E+00	-1.33E-01	9.42E-01	-3.06E-02	-6.34E-02	2.79E-01	3.06E-01	-3.10E-02
10	5.25E+00	10	-9.99E-01	8.28E-01	2.12E-01	-3.11E+00	9.17E-01	1.63E-02	3.09E-02	-1.71E-01	1.91E-02	-9.02E-03

Camada	2	Arquitetura	25	neurônios	x	10	inputs	RNA	de	TEQ	Cadeira	F1
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10
1	-2.81E+00	1	-1.41E+00	4.56E-01	-5.07E-01	-3.55E-01	-1.59E+00	-6.09E-02	-3.77E+00	-4.75E-01	1.34E-01	-1.89E+00
2	-2.60E+00	2	1.47E-01	2.14E-02	2.58E-01	8.82E-01	-5.57E-01	4.32E-01	-6.45E-01	-8.61E-02	1.69E+00	1.14E+00
3	8.75E-01	3	-1.63E+00	-1.44E-01	1.01E+00	6.97E-01	2.49E+00	-1.05E-01	-1.52E+00	-2.61E-01	8.28E-01	5.83E-01
4	6.82E-01	4	-9.94E-01	1.17E+00	1.17E+00	2.02E+00	9.84E-01	-1.39E+00	-6.53E-01	-4.28E+00	-1.73E+00	-8.80E-01
5	-9.33E-01	5	5.89E-01	1.79E+00	-9.58E-02	-1.08E+00	8.15E-01	2.13E+00	2.56E-01	3.18E-01	5.59E-01	3.02E-01
6	-1.36E+00	6	1.41E+00	-1.59E+00	2.13E-01	-6.16E-01	-7.55E-01	1.32E-01	-1.80E+00	3.78E-01	1.51E+00	8.71E-01
7	1.35E-01	7	-1.36E+00	-2.12E+00	2.31E-01	-6.82E-01	-1.57E+00	-1.29E+00	3.35E-01	-2.34E+00	1.05E+00	-6.89E-01
8	-3.49E-01	8	3.34E+00	1.57E+00	1.46E-01	2.72E-01	1.03E+00	-8.48E-01	-9.93E-01	1.10E-01	8.98E-01	-2.83E-01
9	-5.47E-01	9	-9.25E-02	5.44E-01	2.80E-01	1.18E+00	1.86E+00	-9.64E-01	-2.37E+00	-1.15E+00	-1.09E+00	-1.22E+00
10	-9.49E-01	10	7.95E-01	4.05E-02	-6.96E-01	-3.21E-01	1.27E+00	1.14E-01	-6.59E-01	1.59E-01	-6.99E-01	3.63E-01
11	-1.00E+00	11	2.49E-01	5.07E-01	-3.92E-01	1.34E+00	-8.54E-01	-1.43E+00	1.33E+00	4.77E-01	-5.10E-01	1.64E+00
12	-4.59E-01	12	-3.11E-01	1.22E+00	2.20E-01	-2.35E-01	1.71E+00	2.36E-01	3.58E-01	1.77E+00	-1.34E-01	6.99E-01
13	-1.18E+00	13	-3.43E-01	2.49E-01	3.85E+00	2.71E-01	1.69E+00	-2.33E+00	-3.00E-01	-6.33E-01	9.97E-01	-7.53E-01
14	7.44E-01	14	-1.21E+00	1.73E+00	-7.51E-01	3.61E+00	-1.74E+00	-1.90E-01	-4.86E+00	-2.47E+00	1.75E+00	1.53E+00

PARÂMETROS		RNA	TEQ	Cadeira	F1	LIVRES					
15	-4.77E-01	15	-4.43E+00	-1.76E+00	-4.26E+00	-9.80E-01	2.67E-02	-5.81E-01	-1.92E-01	1.64E+00	6.15E-01
16	-7.52E-01	16	1.74E+00	6.27E-01	3.06E-01	1.89E+00	-2.16E+00	2.26E-01	-2.46E+00	-1.62E+00	-6.46E-01
17	-1.21E+00	17	-9.94E-01	-7.85E-01	2.37E+00	-1.23E-01	-4.44E-01	-1.55E+00	1.38E+00	1.31E+00	1.71E+00
18	-3.79E-01	18	-3.64E-01	3.47E-01	9.87E-02	6.10E-01	-2.32E+00	2.51E+00	8.84E-01	-4.66E-01	1.33E+00
19	1.55E+00	19	2.10E+00	2.10E+00	7.02E-01	1.02E+00	-6.64E-01	-2.65E+00	-4.54E-01	5.40E-01	-2.09E-01
20	-1.72E+00	20	-1.35E+00	2.74E+00	-5.00E-01	-3.87E-01	3.55E-01	1.00E+00	-1.69E+00	1.39E+00	1.92E+00
21	1.76E+00	21	-3.27E+00	-8.77E-01	1.57E+00	4.38E-01	-1.80E+00	-2.09E+00	-1.32E+00	4.39E-01	4.13E+00
22	2.68E+00	22	1.29E+00	-6.50E-02	-1.93E+00	-2.44E+00	2.21E+00	2.83E-01	2.28E-01	-1.63E+00	-3.87E-01
23	-2.80E+00	23	-8.03E-01	-1.45E+00	-5.31E-01	-1.22E-01	2.18E+00	-1.92E+00	1.22E+00	-2.35E+00	2.33E+00
24	-2.34E+00	24	-4.41E-01	-1.48E+00	6.55E-02	1.39E+00	-4.99E-01	-4.46E-01	-1.13E+00	1.21E+00	9.92E-01
25	2.11E+00	25	1.75E+00	1.88E+00	-4.01E-01	6.99E-01	-3.60E-02	2.84E+00	1.08E+00	-4.70E-02	2.39E+00

Camada	3	Arquitetura	13	neurônios	x	25	Inputs	RNA	de	TEQ	Cadeira	F1
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10
1	-2.44E+00	1	1.13E+00	1.33E+00	-1.25E+00	1.30E+00	1.22E+00	-7.39E-02	1.63E+00	4.26E-01	-9.86E-01	1.49E+00
2	1.01E+00	2	-1.64E+00	3.85E-01	1.45E+00	4.01E-01	8.46E-01	-1.65E+00	1.06E-01	-1.78E+00	3.86E-01	-1.42E-01
3	4.06E-01	3	-9.14E-01	-1.41E+00	3.76E-01	2.03E+00	2.01E+00	-6.27E-01	1.93E+00	6.96E-01	7.66E-01	-6.43E-01
4	8.86E-02	4	-1.86E+00	-1.76E+00	2.88E-01	-1.82E+00	4.00E-01	-1.23E+00	-9.01E-01	1.18E+00	-2.96E-01	-3.08E-01
5	1.20E+00	5	2.02E-01	-3.99E-01	3.59E-01	-1.33E-01	1.86E+00	-9.12E-01	-4.79E-01	-3.29E-01	-9.70E-01	-1.67E+00
6	-2.20E-01	6	-2.39E+00	2.63E-01	2.22E+00	-6.52E-01	2.76E+00	-6.33E-01	2.97E+00	1.46E+00	-1.06E+00	4.09E-01
7	-4.03E-01	7	-7.74E-01	9.41E-01	1.10E+00	-1.41E+00	1.44E-01	1.81E+00	-6.79E-01	1.34E+00	1.02E+00	1.52E+00
8	-6.61E-01	8	9.82E-01	2.46E-01	4.74E-01	-2.29E-01	-2.76E+00	-2.59E-01	-8.45E-01	-5.41E-01	6.58E-02	2.95E-01
9	-2.50E-01	9	-3.02E+00	3.77E-01	1.50E-01	-1.97E+00	-1.65E-01	-7.05E-01	-1.05E+00	1.20E+00	1.75E-01	1.17E+00
10	-1.99E+00	10	7.56E-01	1.35E+00	-9.01E-02	-1.63E+00	-3.58E+00	1.13E+00	9.72E-01	-3.09E-01	-5.30E-01	1.64E+00
11	-4.65E-02	11	-4.64E-01	-1.28E+00	5.78E-02	1.31E+00	-9.35E-01	-9.89E-01	-1.13E-01	-6.08E-01	1.58E+00	-5.59E-01
12	-5.37E-01	12	-9.70E-01	-7.22E-01	1.04E-03	-4.50E-01	6.62E-01	-1.04E+00	7.37E-01	1.13E+00	-2.37E+00	-9.85E-01
13	1.89E+00	13	8.43E-01	-3.94E-01	-3.23E-01	-6.25E-01	-4.19E-01	8.27E-01	9.07E-01	8.77E-02	-4.51E-01	7.19E-01
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20
		1	-2.12E+00	5.53E-01	5.17E-01	4.02E-01	1.30E+00	-1.31E+00	7.13E-01	7.29E-01	-6.37E-01	6.66E-01
		2	3.34E+00	-1.45E+00	-6.85E-01	-8.80E-01	1.24E-01	-5.49E-01	6.24E-01	-7.95E-01	1.83E-02	2.57E-01
		3	1.42E+00	2.95E-01	-1.75E+00	2.50E+00	-1.77E+00	1.37E+00	1.36E+00	4.35E-01	1.59E+00	-4.81E+00
		4	-2.30E-01	-2.67E-01	4.49E-01	-1.84E+00	1.73E+00	1.10E+00	-1.82E+00	5.80E-02	-3.86E-01	2.19E+00
		5	7.18E-01	-1.41E+00	1.55E-01	9.52E-01	6.71E-01	2.77E+00	-1.96E+00	1.22E+00	-6.92E-01	5.75E-01

PARÂMETROS LIVRES											
		RNA	TEQ	Cadeira	F1						
	6	-1.15E+00	-4.06E-01	1.45E+00	-1.52E+00	-1.89E+00	3.06E-02	7.79E-01	-1.51E+00	-5.29E-01	1.14E+00
	7	6.61E-01	1.80E+00	1.33E+00	9.28E-01	1.37E+00	-1.37E+00	-2.16E+00	-3.95E-01	4.58E+00	-5.43E-01
	8	-2.99E+00	1.47E+00	-8.31E-01	3.52E-01	1.57E+00	-2.02E-01	-2.00E+00	-1.69E+00	-6.73E-02	3.52E+00
	9	-2.08E+00	1.55E+00	-6.48E-01	-3.67E-01	1.93E+00	1.54E+00	-5.20E-01	1.15E+00	-2.37E+00	-2.13E+00
	10	-6.81E-01	4.67E-01	-3.41E-02	8.06E-01	1.93E+00	1.78E+00	1.54E+00	1.05E+00	-2.97E-01	-7.35E-01
	11	1.77E+00	-1.24E+00	2.08E-01	2.22E-02	-3.27E-01	-1.22E+00	8.52E-01	5.12E-01	9.39E-02	1.46E+00
	12	-1.92E+00	-1.77E-01	8.84E-01	-1.14E+00	3.49E-01	3.16E-01	2.80E-02	7.78E-01	-2.32E+00	1.99E+00
	13	1.43E+00	7.64E-01	-7.17E-03	-1.42E-01	1.70E-01	4.35E-01	-7.56E-01	1.05E+00	4.41E-01	-2.55E-02
	Pesos w_{ij}	21	22	23	24	25					
	1	-3.88E-01	-1.75E+00	-6.35E-01	7.17E-01	-1.35E+00					
	2	3.10E-01	-3.93E-01	-1.15E+00	3.29E-02	4.13E-02					
	3	-2.30E+00	-9.10E-03	4.75E-01	-1.61E+00	-3.65E-01					
	4	-4.26E-01	-2.16E+00	9.04E-01	1.14E-01	1.04E+00					
	5	1.92E-01	1.72E-01	7.66E-01	1.10E+00	6.67E-01					
	6	-9.08E-01	8.19E-02	2.68E+00	9.49E-01	-3.76E-01					
	7	-2.00E+00	1.91E-01	-6.86E-01	7.83E-01	-3.63E-01					
	8	3.88E-01	-7.46E-01	-1.13E-01	1.16E-01	1.94E-02					
	9	2.83E-01	1.08E+00	-1.79E+00	8.97E-01	-1.19E+00					
	10	-2.74E+00	-8.79E-01	8.41E-01	1.52E+00	3.04E-01					
	11	-3.05E-01	4.13E-02	-2.13E-01	-7.46E-01	-6.58E-01					
	12	-3.53E-01	-3.81E-01	1.24E+00	-6.64E-01	9.81E-01					
	13	-1.65E+00	-1.25E-01	4.69E-01	-7.26E-01	6.92E-01					

Camada	4	Arquitetura	1	neurônios	x	13	inputs	RNA	de	TEQ	Cadeira	F1
Bias b_{ij}	Saída	Pesos w_{ij}	1	2	3	4	5		7	8	9	10
1	9.16E+00	1	-8.37E+00	1.18E+00	3.06E-01	-4.27E-01	1.05E+00	-7.73E-01	2.32E-01	-9.18E-01	2.51E-01	-1.13E+00
		Pesos w_{ij}	11	12	13							
		1	-1.10E+00	2.33E-01	1.97E+00							

PARÂMETROS LIVRES		RNA		TEQ	Cadeira	F2
-------------------	--	-----	--	-----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	10	neurônios	x	10	inputs	RNA	de	TEQ	Cadeira	F2
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10
1	-1.97E+01	1	4.32E+00	3.98E+00	-7.37E+00	1.23E+01	-1.73E+01	1.64E-01	1.75E-02	8.40E-02	1.66E-01	-4.00E-02
2	-2.32E+01	2	-2.97E+00	6.93E-01	-5.04E-01	4.44E+00	-9.47E-01	-5.07E-02	-1.17E-02	5.59E-02	1.01E-01	4.32E-02
3	-7.42E+00	3	-2.85E+00	1.28E+00	2.42E+00	6.74E+00	2.05E+00	-8.09E-02	6.13E-02	-1.18E-01	7.62E-01	2.35E-02
4	-1.08E+00	4	5.83E+00	-6.74E+00	3.42E+00	-8.21E-01	-1.20E+00	1.16E-01	5.28E-03	5.41E-01	-1.15E+00	-3.97E-02
5	-6.99E+00	5	6.65E+00	-5.03E+00	7.91E+00	4.99E+00	-8.07E+00	2.16E-02	8.52E-02	3.19E-01	-4.45E-01	-7.88E-03
6	-3.15E+00	6	-4.83E+00	9.04E-01	4.45E+00	1.75E+00	3.42E+00	-1.51E-02	1.26E-02	-9.81E-02	5.42E-01	2.45E-03
7	-1.27E+01	7	-2.91E-01	-2.61E-01	-3.04E+00	-8.02E-01	-1.26E+00	1.07E-02	-1.21E-02	-2.38E-02	-7.28E-02	1.30E-02
8	1.20E+01	8	5.24E+00	1.97E+00	3.08E+00	-8.15E+00	-6.84E+00	-7.32E-02	-2.50E-02	-2.89E-01	1.04E+00	2.43E-03
9	1.57E+01	9	-1.78E+00	-5.25E-01	-5.83E+00	1.82E+00	7.31E+00	-5.04E-03	5.68E-02	-2.25E-01	-1.26E-02	-1.49E-02
10	1.38E+01	10	-1.17E+01	9.38E-01	1.33E+00	7.75E-02	1.65E+00	-4.58E-02	-4.41E-01	8.96E-01	-1.74E-01	2.60E-02

Camada	2	Arquitetura	25	neurônios	x	10	inputs	RNA	de	TEQ	Cadeira	F2
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10
1	1.35E+00	1	-4.62E+00	4.30E+00	-5.29E+00	8.06E-01	9.90E-01	1.04E-01	4.87E-01	-7.20E+00	5.56E-02	1.47E-01
2	-3.07E+00	2	-5.40E+00	5.42E-01	-6.16E+00	-1.11E+00	4.90E+00	4.02E+00	5.06E-01	4.03E-01	-3.73E+00	2.70E+00
3	1.15E+00	3	-1.07E+01	-3.64E+00	6.53E+00	-8.40E+00	-3.56E+00	1.80E+00	-1.76E+00	-2.60E+00	-8.30E+00	-5.88E-01
4	-2.18E+00	4	2.66E+00	2.90E-01	-3.93E-01	-1.22E-01	-1.60E-01	7.90E-01	-1.34E+00	-4.88E-01	6.14E-01	2.36E-01
5	8.83E+00	5	2.65E+00	2.17E+00	-5.45E+00	8.67E-01	-2.65E+00	-1.48E+01	-2.31E+00	-9.66E-01	-6.09E+00	-3.29E+00
6	4.68E+00	6	-5.09E-01	-2.27E-01	-2.39E+00	6.34E+00	8.17E-01	1.36E+00	5.51E-01	-5.49E+00	-4.10E-01	-1.24E+01
7	-2.33E-01	7	4.41E+00	1.68E+00	7.28E+00	9.11E+00	-2.58E+00	2.00E+00	-4.65E+00	-4.79E+00	-3.54E+00	-2.80E+00
8	6.95E+00	8	-5.25E+00	-1.33E+01	6.89E+00	-1.51E+01	-5.19E+00	5.73E+00	6.19E-01	-2.35E+00	-2.18E+00	4.74E+00
9	-8.15E-01	9	-2.93E+00	4.21E+00	1.65E+00	4.05E+00	1.99E+00	-1.32E+00	-8.83E+00	-2.19E+00	-5.42E-01	-6.40E+00
10	-2.60E+00	10	-3.57E+00	-1.44E+00	-3.01E+00	2.26E+00	-2.62E+00	5.21E+00	2.20E-01	-2.86E+00	1.71E+00	-8.33E+00
11	2.54E+00	11	-1.89E+00	5.58E+00	-6.79E-01	-1.15E+00	-6.13E-01	-6.92E-02	-1.65E-01	-2.78E+00	9.16E-02	6.97E+00
12	-2.27E+00	12	4.04E+00	-2.99E+00	5.02E+00	-3.56E+00	-1.38E+00	1.11E-01	1.80E+00	6.59E-01	2.49E+00	9.59E+00
13	1.17E+00	13	-3.26E+00	-5.36E-01	-3.25E+00	5.21E+00	2.56E+00	9.36E+00	-5.01E+00	1.44E+00	-2.18E+00	3.36E+00

PARÂMETROS LIVRES				RNA	TEQ	Cadeira	F2							
14	-1.93E+00	14		-1.09E+00	-5.38E+00	2.67E+00	8.76E-01	2.60E+00	3.14E+00	-4.46E-01	-1.29E+01	4.67E+00	4.73E+00	
15	-3.66E+00	15		8.32E-01	1.28E+00	-6.96E+00	-5.71E+00	1.10E+00	-3.49E-01	4.07E+00	-2.42E+00	-3.33E+00	6.31E+00	
16	3.28E-02	16		-1.01E+00	4.22E+00	2.50E+00	5.35E+00	-8.07E-01	4.93E-01	-1.97E-01	-4.45E+00	1.38E+00	6.18E+00	
17	5.44E-01	17		-1.49E+00	-5.11E+00	-6.66E+00	8.23E+00	1.33E+00	2.92E+00	-1.44E+00	8.51E+00	4.00E-01	-3.23E+00	
18	-6.80E+00	18		1.31E+01	5.06E+00	1.92E-01	7.25E+00	2.50E+00	5.25E-01	-5.93E+00	3.34E+00	-1.89E-01	-9.64E-03	
19	-7.44E-01	19		-2.54E+00	-7.19E+00	-6.11E+00	-4.26E+00	3.15E+00	6.50E+00	-5.86E+00	5.74E+00	5.51E+00	4.01E+00	
20	1.58E+00	20		-1.88E-01	-6.70E+00	-3.45E-01	-2.38E+00	1.77E-01	-1.05E+00	-4.42E-01	-3.40E+00	-6.93E-01	-1.30E+00	
21	2.93E+00	21		3.78E+00	3.55E-01	1.56E+00	7.76E-01	-7.02E-01	7.03E-01	-5.84E-01	1.85E+00	8.65E-01	3.96E+00	
22	-2.89E+00	22		-4.00E+00	9.49E+00	3.19E-01	2.61E+00	2.48E+00	-3.65E+00	-7.21E-01	-6.01E+00	3.71E+00	-6.29E+00	
23	2.34E+00	23		8.42E-01	-2.82E-01	2.88E+00	-3.65E+00	3.97E-02	8.57E-01	1.21E+00	-6.83E+00	-2.05E+00	1.21E+00	
24	2.29E+00	24		-2.59E-03	6.76E+00	-3.15E+00	-2.68E+00	8.24E+00	1.91E+00	1.57E+01	1.33E+00	-1.25E-01	3.17E+00	
25	-1.24E+00	25		1.04E+00	-3.61E+00	-3.73E+00	-3.88E+00	-2.06E-01	1.17E+00	-3.61E+00	-5.42E-01	-1.22E+00	7.19E-01	

Camada	3	Arquitetura	13	neurônios		x	25	inputs		RNA	de	TEQ	Cadeira	F2
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10		
1	2.01E+00	1	-4.55E+00	-7.25E-01	1.75E+00	2.41E+00	-4.74E+00	7.54E+00	3.03E+00	-7.61E+00	2.42E+00	-6.24E+00		
2	-2.46E+00	2	7.03E-02	8.60E-01	-4.50E+00	3.21E+00	-6.03E-01	4.53E+00	-8.21E-01	8.12E-01	-2.42E+00	2.12E+00		
3	-3.04E+00	3	1.37E+00	1.77E+00	3.27E-01	-5.52E+00	7.58E-01	5.99E+00	-2.07E+00	3.81E+00	5.26E+00	-9.02E-02		
4	-1.23E+00	4	2.95E+00	1.39E+00	6.28E+00	-5.63E+00	-1.66E+00	-4.80E-01	1.77E+00	3.12E+00	4.06E+00	-4.44E+00		
5	3.09E+00	5	6.00E+00	-1.87E+00	-3.79E-01	-7.05E-01	9.94E-01	-1.14E+01	-4.29E-01	3.76E-01	-4.29E-01	-1.60E-01		
6	-1.43E+00	6	3.42E+00	2.58E+00	7.80E+00	4.27E-01	-2.95E+00	2.37E+00	-4.41E+00	-6.16E+00	1.90E+00	-9.29E+00		
7	-3.69E+00	7	-2.69E+00	1.69E+00	-3.66E+00	-3.91E+00	4.86E-01	-3.93E-01	1.81E+00	-1.69E+00	3.34E+00	-1.72E+00		
8	-6.81E+00	8	-2.84E+00	2.70E+00	-4.73E-01	3.12E+00	-3.84E+00	-1.68E+00	-2.58E+00	8.71E+00	1.13E+00	-2.95E+00		
9	1.18E+00	9	-1.66E+00	1.30E+00	-4.54E-01	8.73E-01	-2.93E+00	-2.17E+00	4.02E-01	-5.16E-01	-2.75E-01	-8.75E-01		
10	-6.52E-01	10	-3.15E+00	1.81E+00	-6.13E-01	8.99E+00	6.57E-03	6.25E-01	3.99E+00	4.46E+00	-5.07E+00	-2.63E+00		
11	5.38E+00	11	1.29E-02	4.19E-01	-1.40E-01	1.22E+00	2.36E-01	-2.05E-01	2.45E-02	6.66E-03	-1.85E-02	3.94E-02		
12	-1.57E+00	12	2.33E-01	1.33E+00	4.56E-01	-3.37E+00	-1.27E+00	5.45E+00	3.61E+00	-1.61E+00	1.92E+00	2.66E+00		
13	-3.32E+00	13	-6.83E+00	1.29E+00	3.51E+00	-7.29E-01	-1.50E+00	-1.15E+00	3.20E+00	3.59E+00	-8.45E+00	3.78E+00		
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20		
		1	2.26E+00	5.53E+00	-4.73E+00	-2.76E+00	-5.48E+00	-3.50E+00	8.35E+00	1.23E+00	2.41E+00	1.45E+00		
		2	-8.34E+00	1.21E+00	-2.25E+00	8.54E+00	3.38E-01	5.85E+00	-8.25E-01	-5.47E+00	-1.57E+00	5.78E+00		
		3	-7.29E-01	-5.37E+00	8.07E+00	6.07E-01	-8.37E-01	-9.53E+00	2.39E+00	3.53E+00	3.65E+00	-6.42E-02		
		4	7.70E+00	9.31E-01	1.94E+00	4.23E+00	-4.03E+00	-1.31E+00	1.02E+01	4.46E+00	1.35E+00	1.47E+00		

PARÂMETROS LIVRES																							
		RNA		TEQ		Cadeira		F2															
		5	5.94E+00	1.38E+00	-9.20E+00	1.86E-01	-2.93E-01	-1.88E+00	-3.29E+00	-4.74E-01	3.11E+00	-5.56E+00											
		6	-2.91E+00	-3.27E+00	-3.19E+00	-9.03E-01	-1.81E+00	1.94E+00	-6.16E+00	2.13E-01	6.55E+00	1.29E+00											
		7	4.71E+00	5.82E+00	-4.12E+00	-2.46E+00	-2.16E-01	-6.01E+00	1.14E+00	-5.45E+00	-2.70E+00	-3.80E-01											
		8	-2.19E+00	1.95E+00	3.79E+00	-1.20E+00	-3.88E+00	-9.03E-01	-6.48E+00	-9.64E-01	-3.07E+00	1.34E+00											
		9	-8.17E+00	-6.09E+00	1.10E+00	-2.10E+00	4.18E-01	-1.27E+01	1.03E+00	-4.64E-02	-1.11E+00	2.27E+00											
		10	-5.34E+00	3.30E-01	7.87E+00	-3.99E-01	3.11E+00	3.69E-01	-1.87E+00	-3.32E-01	3.61E+00	-1.89E+00											
		11	-1.47E-01	-3.53E-01	5.67E-02	-4.02E-02	-2.00E-01	8.59E-01	3.76E-01	-1.07E-01	9.30E-01	9.05E-01											
		12	-3.08E+00	5.18E+00	1.80E+00	2.91E-01	1.42E+00	-2.20E+00	2.20E+00	-3.53E-02	-4.56E+00	4.11E+00											
		13	1.63E+00	3.61E+00	-1.41E+00	-7.41E+00	-1.60E+00	3.28E+00	4.99E+00	1.92E+00	1.95E+00	-1.86E+00											
		Pesos w_{ij}																					
		1	2.59E+00	-3.32E+00	-3.05E-02	-2.98E+00	-4.96E+00																
		2	-1.13E+00	-3.54E+00	-4.09E-01	-2.60E+00	1.73E+00																
		3	-5.27E+00	4.79E+00	-3.90E+00	1.24E+00	1.29E+00																
		4	2.07E+00	-1.57E+00	-5.86E-01	1.99E+00	2.91E+00																
		5	-6.58E-01	-7.61E+00	-1.26E-01	-1.07E+01	-6.39E+00																
		6	1.22E+00	-2.53E+00	-7.14E+00	-1.99E+00	3.28E+00																
		7	-1.95E+00	-1.95E+00	-2.89E-01	2.62E+00	1.27E+00																
		8	2.15E+00	1.66E+00	-1.89E+00	1.76E+00	-1.56E+00																
		9	-3.71E+00	-1.26E+00	1.44E+00	2.99E+00	3.64E+00																
		10	-1.88E+00	5.49E+00	-2.01E+00	-3.78E+00	-2.40E+00																
		11	-3.29E-01	-3.83E-01	3.81E+00	-7.69E+00	1.51E-01																
		12	-3.28E-01	-7.39E-01	-2.69E+00	-1.05E+00	-1.35E+00																
		13	3.23E-01	1.92E+00	-2.06E+00	2.36E-01	5.30E-01																
		Pesos w_{ij}																					
		1	2.34E+00	3.70E-01	6.66E-02																		
Camada	4	Arquitetura		neurônios		x		13		inputs		RNA		de		TEQ		Cadeira		F2			
Bias b_{ij}		Pesos w_{ij}		1		2		3		4		5		6		7		8		9			
1	2.16E+01	1		-1.32E-01		1.96E-01		1.93E-01		1.53E-01		-6.62E-01		-1.19E-01		-1.48E-01		-2.04E-01		3.55E-01			
		Pesos w_{ij}		11		12		13															
		1		2.34E+00		3.70E-01		6.66E-02															

PARÂMETROS LIVRES			
Convenção	k =	j =	i =
	camada	neurônio	conexão

Convenção	k =	j =	i =
	camada	neurônio	conexão

Camada	1	Arquitetura	10	neurônios	x	3	4	10	inputs	RNA	de	7	8	TEQ	Cadeira	F3
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	-1.07E+01	1	-9.61E+00	-3.32E+00	5.79E+01	-4.35E+00	-8.16E+00	-3.02E+01	-5.25E+02	7.08E+00	-1.52E+01	1.86E-01				
2	-1.65E+01	2	2.17E+00	1.12E+00	1.75E+00	1.89E+00	6.83E-01	-1.25E+01	-9.98E+03	1.19E+00	-2.69E+00	7.21E-02				
3	-6.67E+00	3	-4.66E+00	-2.24E+00	-6.63E+00	3.70E+00	-1.80E+00	4.13E+02	-1.40E+02	-1.33E+01	5.52E-01	-6.28E-03				
4	3.38E+00	4	-1.49E+00	6.67E-01	8.19E+01	-1.09E+00	1.19E-01	1.81E-03	-2.47E+03	-1.37E+01	4.84E-02	-2.66E-03				
5	-1.59E+01	5	-2.80E-01	1.71E+00	7.55E-01	-8.97E-01	1.04E+00	-7.06E-03	-1.24E+02	-6.30E+01	3.72E-01	2.58E-02				
6	3.14E+01	6	6.66E+00	2.27E+00	3.34E+00	-6.84E+00	2.99E+00	-2.34E-01	7.80E+02	-2.57E+01	1.11E+00	3.89E-02				
7	1.14E+02	7	3.39E+01	4.46E+00	1.89E+01	-9.03E+00	1.29E+01	-5.00E-01	1.48E-01	7.63E-01	-7.02E-01	3.99E-02				
8	-5.26E+01	8	2.90E+01	5.12E+00	-5.65E+01	2.58E+01	-5.41E+00	-3.99E-01	-3.48E+03	3.53E+00	-5.48E+00	2.00E-01				
9	-1.76E+01	9	-5.24E+00	1.30E+00	-1.57E+00	8.10E-01	-3.17E-01	-4.12E+03	-4.56E+03	-4.74E+01	4.34E-01	2.29E-02				
10	2.07E+01	10	6.15E+00	-3.41E+00	3.66E+00	1.98E+00	5.59E+00	1.03E-01	-2.73E+02	8.47E-01	-1.17E+00	-5.74E-02				

Camada	2	Arquitetura	25	neurônios	x	3	4	10	inputs	RNA	de	7	8	TEQ	Cadeira	F3
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	8.31E+00	1	-2.09E+01	-1.37E+00	-1.28E+00	-4.08E+00	-5.37E-01	4.19E+00	-5.85E+00	-1.82E+01	7.41E+00	3.01E+00				
2	-2.68E+01	2	2.72E+01	5.70E-01	-9.27E-01	-4.83E-01	3.68E+00	2.21E+00	-2.61E+01	-2.25E+01	-5.24E-01	2.42E+00				
3	-3.67E-01	3	-1.59E+00	1.26E+00	1.29E+00	3.54E+00	9.05E-01	-1.08E+00	-1.52E+00	-1.75E+00	-1.52E+00	2.78E-02				
4	5.75E+01	4	-2.93E-01	2.11E-01	-3.38E-01	-1.15E+00	-3.24E-01	3.52E-01	-4.10E+00	5.24E+01	1.80E-01	4.12E-01				
5	3.95E+01	5	1.63E+00	-1.64E+00	1.21E+00	1.31E+00	-2.52E+00	-5.03E+00	-8.15E+00	2.52E+01	8.99E-01	6.35E+00				
6	3.56E+01	6	-6.86E+00	-2.15E+00	-1.62E+00	-3.21E+00	4.66E+00	-4.17E-02	-5.12E+01	-1.77E+01	-7.31E+00	3.02E+00				
7	2.40E+01	7	-5.33E-01	2.20E+00	3.14E+00	1.94E+00	-2.48E+00	-3.09E+00	-7.49E+00	1.48E+01	1.46E-01	-1.19E+00				
8	-3.16E+01	8	-2.00E+01	1.01E-01	-1.01E+00	4.86E+00	6.09E+00	8.09E+00	-1.25E+01	-5.12E+01	7.36E+00	6.20E+00				
9	-4.68E+01	9	5.23E-01	-2.87E-01	8.55E-01	-5.38E+00	-1.32E+00	-1.12E+00	1.93E-01	-5.21E+01	9.95E+00	4.94E+00				
10	-2.12E+01	10	-7.38E+00	1.78E+00	3.32E+00	-1.74E+00	2.08E+00	5.26E+00	8.41E-01	-2.18E+01	2.06E+00	1.41E+00				
11	6.87E+01	11	2.24E+00	-1.26E+00	6.59E+00	7.15E+00	4.15E+00	-3.46E+00	6.12E+00	7.86E+01	-3.01E+00	-4.23E+00				
12	1.07E+02	12	3.33E+00	-5.70E-01	-6.80E+00	-1.58E+00	3.21E+00	-3.81E+00	-1.90E+01	8.06E+01	-1.67E+00	2.61E+00				
13	3.39E+01	13	-7.52E-02	4.64E-01	3.00E-01	2.31E-01	7.64E-01	2.42E-02	1.74E+00	3.60E+01	-1.17E+00	-6.76E-01				

PARÂMETROS LIVRES				RNA	TEQ	Cadeira	F3
14	1.81E+01	14		-6.15E+01	4.02E+00	-1.08E+00	-7.58E+00
15	2.82E+01	15		2.69E+02	3.26E-01	2.01E-01	7.98E-01
16	3.37E+01	16		-3.21E+00	-3.30E+00	-2.44E+00	-2.21E+00
17	-1.07E+01	17		-9.12E+00	9.28E+00	-4.89E+00	1.18E+00
18	8.04E+00	18		9.00E+00	-4.05E-01	-1.04E+00	-2.09E+00
19	5.13E+01	19		4.42E-01	-8.87E-01	3.00E+00	4.69E+00
20	-7.17E+01	20		-2.46E+01	-4.56E-01	-6.84E+00	-2.18E+00
21	-7.21E+01	21		1.20E+00	-1.31E+00	1.21E+00	-7.75E+00
22	1.49E+01	22		-1.21E+00	9.39E-01	2.38E+00	-1.09E+00
23	2.68E+00	23		3.34E+00	-5.39E+00	-4.07E+00	-8.07E-01
24	-2.84E+00	24		5.19E-01	-2.51E+00	3.27E+00	2.95E+00
25	-5.02E+01	25		-1.09E+01	2.60E+00	7.20E-01	5.74E-01

Camada	3	Arquitetura	13	neurônios	x	25	inputs	RNA	de	TEQ	Cadeira	F3
Bias b_{ij}												
1	-2.94E-01	1	-6.08E+00	2.23E+00	2.35E+00	2.50E+00	-1.00E+01	1.87E+00	-9.44E+00	-8.54E+00	8.78E-01	3.59E-01
2	-3.15E+01	2	-2.49E+00	-9.04E+00	2.63E+01	1.63E+01	6.35E+00	9.97E+00	-7.59E+00	5.83E-01	-8.78E+00	1.31E+00
3	2.47E+01	3	-1.35E+01	1.05E+01	2.48E+00	-1.11E+01	-9.01E+00	9.02E-01	-1.42E+01	-3.64E+00	-5.69E+00	-4.62E+00
4	4.95E+01	4	-9.58E+00	-1.49E+01	-6.66E-01	1.04E+01	-4.82E+00	-1.34E+01	1.06E+00	2.00E+01	1.01E+01	1.23E+01
5	2.14E+01	5	-3.15E+00	7.87E+00	-7.22E+00	-5.44E-01	2.30E+00	1.39E+00	8.14E-01	-1.05E+00	-7.93E-01	-9.62E+00
6	-2.09E+01	6	1.36E+00	1.85E+01	-2.03E+00	-7.82E+01	8.02E+00	-3.25E+00	4.15E+00	2.83E+01	4.62E+00	2.62E+00
7	8.60E+00	7	4.66E+00	-5.41E+00	6.19E+00	-6.21E+00	1.82E+01	5.23E+00	-6.76E+00	-2.77E+01	5.24E-01	2.34E+00
8	1.03E+02	8	-6.08E+00	2.23E+00	1.83E+00	-1.48E+00	2.19E+01	8.86E+00	1.84E+00	-3.55E+00	1.98E+00	7.73E+00
9	3.99E+01	9	6.69E+00	5.18E+01	-1.01E+00	2.22E+01	-2.29E+01	2.02E+01	3.38E+01	5.58E+01	2.41E+01	1.52E+01
10	-4.24E+01	10	-4.19E+00	5.25E+00	-9.23E+00	-1.79E+01	2.77E-01	-9.40E+00	4.37E+00	3.68E+01	-1.36E+00	-7.33E-01
11	-1.15E+01	11	-4.69E+01	-2.40E+01	2.81E+00	-1.04E+01	-7.13E-01	3.95E+00	-4.45E+00	1.57E+01	2.29E+01	6.45E+00
12	-9.50E+01	12	6.42E+00	-2.03E+01	-1.31E+01	-7.20E+00	-1.46E+01	2.79E-01	-1.79E+01	-3.45E+01	-8.32E+00	-1.48E+01
13	-3.92E-01	13	1.51E+02	3.21E-02	7.58E-02	-2.91E-01	8.95E-04	-3.17E-04	-3.36E-02	3.18E-02	-4.61E-02	4.07E-02
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20
1			-3.95E+00	-1.03E+01	9.57E-01	-2.97E+00	-6.10E+00	4.46E+00	1.92E+01	1.07E+01	2.41E+01	-1.48E-01
2			7.80E+01	4.77E+00	-3.03E+01	4.18E+01	-2.60E+00	-2.05E+01	2.91E+01	-2.02E+01	-2.60E+01	4.61E+00
3			5.42E-01	-6.74E+00	2.06E+01	6.65E+00	-5.20E+00	3.02E+00	8.21E+00	-1.28E+01	-3.36E+00	-3.40E+00
4			2.08E+01	-1.81E+01	1.60E+00	-3.98E+01	-4.37E+00	-2.40E+01	9.78E-01	3.06E+00	-1.07E+00	-4.94E+00

PARÂMETROS LIVRES																	
Camada				RNA		TEQ		Cadeira		F3							
				5	4.18E+00	8.86E+00	5.98E+00	-2.49E+00	2.82E+00	5.32E+00	-2.56E+01	-1.61E+01	-1.78E+01	7.83E+00			
				6	9.29E+00	-2.10E+00	-3.66E+00	3.29E+01	8.78E+00	-6.48E+00	-5.37E+01	-2.80E+01	-3.40E+01	-1.13E+00			
				7	-2.13E+01	-2.10E+00	3.86E+00	-1.43E+01	-1.93E+00	4.67E+00	1.09E+01	7.17E-02	8.23E-01	-6.10E-01			
				8	1.86E+01	9.55E+00	-7.23E-01	-7.68E+01	6.93E+00	3.41E+00	1.09E+01	-4.43E+00	8.34E-01	-5.98E+00			
				9	5.81E+01	-2.55E+01	8.78E+00	4.72E+01	1.93E+00	-2.81E+01	-1.25E+01	1.64E+01	4.46E+01	8.16E+00			
				10	1.37E-01	-1.15E+01	-5.59E+00	-8.73E+00	-2.84E+01	1.71E+00	-4.11E+00	4.69E+00	1.76E+01	5.26E+00			
				11	-2.28E-01	5.87E-01	-3.00E+01	-2.06E+01	-1.99E+00	-1.41E+01	-1.43E+01	-1.34E-01	-3.30E-01	-1.21E+01			
				12	4.98E+01	-4.42E+01	1.15E+01	-2.07E+01	-4.66E+00	-1.30E+01	3.98E+01	3.90E+01	-4.30E+01	-1.48E+01			
				13	-6.00E-03	2.39E-02	-4.50E-01	1.50E-02	7.27E-01	-6.12E-04	-1.17E-02	2.01E-02	-3.12E-02	-3.71E-03			
Pesos w_{ij}					21	22	23	24	25								
				1	1.07E+00	-4.44E+00	-5.25E+00	-9.97E+00	2.98E+00								
				2	3.71E+00	-1.82E+01	-6.49E+00	6.95E-01	4.75E+00								
				3	-9.51E+00	-9.66E+00	-2.11E+00	2.21E+01	7.13E-01								
				4	1.19E+01	-8.28E+00	-1.42E+01	-3.26E+01	-3.91E+00								
				5	1.61E+01	4.23E+00	-1.73E+00	-7.52E-01	-1.86E+00								
				6	2.15E+01	-1.69E+00	1.64E+00	8.34E+00	4.07E+00								
				7	1.57E+01	3.66E-01	-1.65E-01	8.97E+00	5.41E+00								
				8	1.28E+01	-1.23E+01	7.25E+00	4.48E+00	2.49E+00								
				9	8.09E+01	-3.15E+00	2.27E+00	-7.92E+00	4.59E+01								
				10	-2.91E-01	8.77E+00	1.59E+01	7.78E+00	1.18E+01								
				11	-4.67E+01	8.14E-01	1.78E+01	-5.42E-02	-1.72E+01								
				12	-1.01E+01	2.13E+01	1.42E+01	3.52E+01	1.50E+01								
				13	-2.78E-02	-2.57E-02	2.78E-02	1.07E-02	3.23E-02								
Arquitetura				1	neurônios				x	13	inputs		RNA	de	TEQ	Cadeira	F3
Pesos w_{ij}				1	1	2	3	4	5	6	7	8	9	10			
1				2.69E+01	3.87E-02	6.59E-02	-8.93E-02	5.18E-02	5.09E-04	-5.38E-02	4.99E-02	1.42E-01	-7.05E-02	2.30E-02			
Pesos w_{ij}					11	12	13										
1					3.25E-02	-1.87E-02	1.06E+01										

PARÂMETROS LIVRES		RNA	TEQ	Cadeira	F4
-------------------	--	-----	-----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	10	neurônios	x	3	4	5	RNA	de	7	8	TEQ	Cadeira	F4
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10			
1	-6.84E+00	1	2.84E+00	-6.53E-01	-1.94E+00	4.23E-01	-2.81E+00	-2.90E-01	2.10E-01	-2.06E-01	3.66E-01	7.88E-02			
2	-9.62E+00	2	-3.08E+00	2.13E+00	5.55E+00	2.67E+00	-5.36E-01	-5.25E-03	1.43E-02	3.49E-01	-9.78E-01	1.05E-02			
3	2.55E+00	3	2.07E+00	1.84E+00	-3.98E+00	3.33E-01	-3.20E+00	2.17E-03	-7.30E-02	3.49E-01	-1.17E+00	1.44E-02			
4	-9.75E+00	4	1.87E+00	-2.45E-01	1.53E+00	1.19E+00	1.04E+00	-6.97E-03	-3.31E-03	-4.34E-01	7.26E-01	1.33E-02			
5	-6.24E+00	5	-2.18E+00	-1.03E+00	-3.54E+00	2.18E+00	-5.79E-02	2.32E-02	-2.24E-02	-1.87E-01	-2.86E-01	7.52E-03			
6	-1.50E+00	6	5.65E+00	-1.89E+00	-4.83E+00	-5.11E-01	1.24E+00	5.66E-02	3.16E-03	-4.57E-01	1.98E+00	-3.13E-02			
7	1.55E+01	7	-1.85E+00	-2.50E-01	-4.41E+00	1.65E-01	6.92E-01	-1.05E-02	3.00E-03	-5.44E-01	1.19E+00	-1.60E-02			
8	1.61E+01	8	2.59E+00	-1.46E+00	-4.15E+00	2.22E+00	8.07E-02	-6.28E-02	-9.41E-03	-1.68E-01	4.64E-02	1.19E-02			
9	2.91E+00	9	-4.40E+00	-5.36E-01	-3.35E+00	-2.49E-01	2.07E-02	1.44E-03	-3.92E-03	-2.10E-01	4.57E-01	-2.59E-03			
10	1.08E+01	10	2.48E+00	-2.98E-01	2.50E+00	-1.06E+00	1.47E+00	-5.19E-03	-4.20E-03	2.42E-01	-5.46E-01	-8.22E-03			

Camada	2	Arquitetura	25	neurônios	x	3	4	5	RNA	de	7	8	TEQ	Cadeira	F4
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10			
1	2.44E+00	1	-3.60E-01	-2.34E-01	3.14E-01	-1.19E+00	4.13E-01	-1.26E+00	-6.32E-01	-1.31E-01	1.51E+00	-2.37E-01			
2	-1.70E+00	2	1.90E-01	6.94E-01	-1.47E+00	5.47E-01	-1.62E+00	-5.59E-01	-3.32E-01	-6.39E-01	1.75E+00	6.89E-01			
3	-1.63E+00	3	8.12E-01	4.91E-03	6.00E-02	-3.31E-01	1.12E+00	1.28E+00	5.17E-01	-1.49E-01	1.03E+00	-5.62E-01			
4	-1.50E+00	4	3.51E-01	-7.62E-01	1.15E-01	5.47E-01	-5.35E-01	-1.10E+00	-7.53E-01	-1.48E-01	-9.29E-01	-1.30E-01			
5	-1.63E-02	5	-2.24E-01	7.89E-01	-1.07E+00	-2.89E-01	-1.14E+00	4.71E-01	-4.87E-02	-1.83E-01	1.70E+00	2.17E+00			
6	6.69E-01	6	-1.08E+00	4.42E-01	-1.29E-01	1.47E+00	-2.81E-01	-6.22E-01	-6.84E-02	5.84E-01	6.89E-03	4.55E-01			
7	1.20E+00	7	-5.88E-01	9.08E-01	-8.46E-01	1.02E+00	-6.32E-01	-2.25E+00	-2.25E+00	-4.24E-01	6.30E-01	-5.03E-01			
8	-4.65E-01	8	2.46E-01	7.44E-01	-6.82E-01	-6.12E-01	-5.99E-01	1.63E+00	2.74E+00	-2.29E-01	9.29E-01	1.17E+00			
9	-1.87E-01	9	-6.29E-01	8.25E-01	2.33E+00	5.07E-01	-1.68E-01	4.37E-01	-1.35E+00	-1.59E+00	-4.49E-01	1.02E+00			
10	-2.13E-01	10	9.80E-01	2.06E-01	5.91E-01	4.57E-01	-2.07E-01	1.07E+00	-1.87E+00	-1.67E+00	7.26E-01	-6.53E-01			
11	4.40E-01	11	-1.33E-01	-8.21E-01	2.98E-02	6.07E-02	-9.95E-01	7.02E-01	6.08E-01	6.43E-01	-1.13E+00	2.38E+00			
12	5.83E-01	12	-2.05E+00	-6.66E-01	3.39E-01	-5.27E-01	-3.34E-01	-3.29E-02	1.12E+00	4.16E-01	9.13E-01	-2.92E-01			
13	2.52E-01	13	-9.73E-01	-7.43E-01	-1.61E-02	4.86E-01	-6.02E-01	1.70E+00	-6.72E-01	1.59E+00	-1.06E+00	8.61E-01			

PARÂMETROS LIVRES			RNA	TEQ	Cadeira	F4							
14	7.70E-01	14	-2.49E-01	1.68E+00	-1.08E+00	-9.97E-01	1.96E-01	2.45E+00	-1.56E+00	-3.88E-01	1.24E-01	-1.66E+00	
15	-8.50E-01	15	-5.58E-01	-5.45E-01	2.81E-01	-2.67E-01	9.29E-01	-5.26E-01	-1.27E+00	-8.20E-01	7.51E-01	-2.68E-01	
16	1.84E-01	16	9.10E-01	-3.41E-01	-2.95E-01	-3.78E-01	-1.15E-01	-1.91E+00	9.93E-01	-9.94E-01	-2.42E+00	1.88E-01	
17	-1.95E-02	17	4.90E-01	1.90E+00	-4.93E-01	7.18E-01	-1.41E-01	1.15E+00	8.53E-01	6.19E-01	8.30E-01	-9.50E-01	
18	1.22E+00	18	2.76E-01	-3.44E-01	-3.28E-01	5.89E-01	8.79E-01	-6.87E-01	-8.67E-01	-1.27E+00	3.84E-01	1.67E+00	
19	-1.12E+00	19	2.40E-01	1.64E+00	2.12E-01	-6.39E-01	1.42E-01	-1.71E+00	4.50E-01	-5.65E-01	1.83E+00	3.02E-02	
20	-1.79E-01	20	-1.14E+00	-5.32E-03	-4.22E-01	3.78E-01	1.61E+00	2.46E-01	6.47E-01	-2.15E-01	2.02E+00	3.93E-01	
21	-1.37E+00	21	-6.08E-01	-5.99E-01	-5.12E-01	-1.28E+00	1.98E+00	8.78E-01	4.69E-01	-2.39E-01	5.84E-01	4.36E-01	
22	1.89E+00	22	3.66E-01	-1.77E-01	6.60E-01	-4.04E-01	1.25E-02	9.00E-01	1.03E+00	-9.49E-01	2.60E-01	3.03E-01	
23	2.25E+00	23	2.43E-01	9.18E-01	-6.38E-01	-3.39E-01	-1.20E+00	-1.30E+00	3.46E-01	1.25E-01	-1.50E-01	5.86E-01	
24	2.13E+00	24	2.95E-01	6.75E-01	-5.20E-01	1.82E+00	-2.00E-01	3.79E-01	1.35E+00	7.29E-02	6.19E-01	-1.32E+00	
25	1.03E+00	25	4.54E-01	2.75E-01	4.81E-02	-5.43E-01	3.87E-01	1.36E+00	-8.99E-01	-7.57E-01	1.72E-01	2.63E-01	

Camada	3	Arquitetura	13	neurônios		x	25	inputs		RNA	de	TEQ	Cadeira	F4
Bias b_{ij}		Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10		
1	1.45E+00	1	3.31E-01	4.05E-01	5.05E-01	-1.06E-01	-1.37E+00	-5.86E-01	-6.08E-01	-2.01E-01	-6.01E-01	2.42E-01		
2	-1.66E+00	2	5.86E-02	-6.36E-02	4.54E-01	1.15E-01	-2.42E-01	-1.98E-01	6.66E-01	2.79E-01	2.10E-01	2.81E-01		
3	-1.68E+00	3	2.94E-01	-4.24E-01	6.25E-01	6.24E-01	-2.17E+00	-5.68E-01	-5.94E-01	-6.45E-01	1.67E-01	7.27E-01		
4	6.07E-02	4	-7.26E-02	1.79E-01	5.59E-01	9.12E-01	-7.14E-01	6.82E-01	-5.24E-01	4.11E-01	6.50E-01	4.62E-01		
5	1.10E+00	5	4.67E-02	-7.29E-01	-3.00E-01	-3.82E-01	-3.85E-01	-3.00E-01	3.90E-01	2.97E-01	-4.77E-01	-1.74E-01		
6	1.19E-02	6	-1.75E-01	6.63E-01	1.87E-01	8.23E-01	-1.11E-01	-8.62E-02	1.15E-02	3.52E-01	-3.04E-01	3.76E-01		
7	3.29E-02	7	-1.64E+00	6.68E-01	-1.22E+00	5.45E-01	1.09E-01	-5.42E-01	-7.14E-01	-1.45E-01	2.27E-01	1.09E+00		
8	-9.46E-01	8	-7.21E-02	3.01E-01	1.41E-01	1.28E+00	-1.19E+00	-2.09E-01	1.06E-01	-8.03E-01	-6.81E-01	-1.75E-01		
9	1.43E+00	9	1.33E+00	-7.56E-01	-1.10E+00	-9.38E-01	-1.01E+00	-4.52E-01	3.24E-01	-6.94E-01	2.22E+00	-5.27E-01		
10	-2.18E-01	10	-9.45E-02	-5.75E-01	-1.18E+00	-1.68E-01	3.81E-02	4.50E-01	2.47E-01	-8.04E-01	-9.48E-02	1.40E+00		
11	-1.17E+00	11	-5.95E-01	3.67E-01	7.51E-01	9.90E-03	3.79E-01	-2.98E-01	-6.57E-01	4.28E-02	-1.92E-01	-5.04E-03		
12	1.30E+00	12	2.40E-01	-5.24E-01	-6.39E-01	1.09E-01	1.03E-01	4.54E-01	-6.26E-01	1.61E-01	3.36E-01	2.74E-01		
13	-2.20E+00	13	-1.21E+00	-9.88E-01	-4.74E-01	-5.28E-01	-6.83E-01	-2.55E-01	-8.73E-01	1.26E+00	-5.76E-01	-5.80E-02		
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20		
1		1	4.71E-01	1.17E-01	-1.67E-01	8.81E-01	-8.00E-01	1.09E+00	-4.15E-01	1.24E-01	2.96E-01	-5.51E-02		
2		2	-3.89E-01	-4.64E-01	2.38E-01	2.45E-01	1.82E-01	-2.77E-01	3.58E-01	-6.09E-01	-3.89E-02	-4.13E-01		
3		3	-3.22E-01	2.91E-01	-1.89E-01	1.18E+00	-5.87E-01	-3.16E-01	-9.43E-01	5.68E-01	2.61E-01	-7.87E-02		
4		4	-1.39E+00	1.53E+00	-2.59E-01	1.79E+00	-1.07E+00	4.42E-01	3.75E-01	4.28E-01	-5.18E-02	4.42E-01		

PARÂMETROS LIVRES		RNA		TEQ	Cadeira	F5
-------------------	--	-----	--	-----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	10	neurônios		x	10	inputs		RNA	de	TEQ		Cadeira	F5
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	10	5	6	7	8	9	10		
1	-1.81E+01	1	-3.87E-01	2.52E-01	-2.61E+00	1.78E+00	-1.16E+00	-1.40E-03	2.33E-03	-1.41E+00	2.18E+00	1.85E-02			
2	-7.18E+00	2	-1.78E+00	-1.18E+00	1.35E+00	3.17E+00	-2.92E+00	2.53E-01	6.60E-03	2.98E+00	3.82E+00	-1.48E-01			
3	-6.60E+00	3	-2.51E+00	-9.88E-01	2.99E+00	7.91E-01	-7.66E-01	3.48E-01	-5.58E-02	4.36E+00	-7.28E+00	-1.05E-01			
4	7.13E+00	4	-1.12E+01	-9.88E-02	-9.03E-01	-1.43E-01	2.84E-01	1.62E-03	-2.05E-03	-2.69E-01	2.76E-01	-7.56E-03			
5	-4.44E+00	5	-7.92E+00	-1.58E+00	-1.11E+00	7.59E-01	-1.11E+00	1.46E-01	-4.16E-02	1.95E+00	-2.70E+00	-3.79E-02			
6	1.89E+01	6	1.32E+00	2.82E+00	5.04E+00	-1.62E+00	3.10E+00	6.29E-01	-2.16E-01	-1.22E-01	2.90E-01	-2.37E-01			
7	6.06E+00	7	-7.20E+00	-1.16E+01	7.38E+00	-1.94E+00	5.52E+00	5.41E-01	2.52E-04	6.43E+00	-8.85E+00	-2.15E-01			
8	1.13E+01	8	2.26E-01	-1.65E+00	3.83E+00	-2.30E+00	2.77E-01	-1.56E+00	4.13E-01	-3.20E+00	-5.32E+00	5.95E-01			
9	-9.82E-01	9	9.80E+00	-6.44E-02	-1.53E+00	-8.95E-01	5.04E+00	-1.42E-01	5.12E-02	-1.22E+00	1.54E+00	4.51E-02			
10	-1.18E+01	10	2.03E+00	8.43E-01	-6.94E-01	-1.94E+00	-7.29E-01	-7.30E-01	2.65E-01	4.47E-02	-7.36E-01	2.54E-01			

Camada	2	Arquitetura	neurônios			x	10			inputs		RNA	de		TEQ	Cadeira	F5
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10					
1	2.22E+00	1	-7.29E-01	2.25E+00	1.22E+00	5.06E+00	2.28E+00	-6.27E+00	5.48E+00	-1.17E+00	8.16E-01	-1.55E+00					
2	2.28E+00	2	-6.46E+00	5.98E+00	1.73E+00	3.97E+00	1.55E+00	-5.18E+00	1.01E+00	-3.33E+00	3.13E-01	2.26E+00					
3	3.73E+00	3	-2.56E+00	-7.44E-01	1.09E+00	3.12E+00	1.22E+00	-2.13E+00	1.40E+00	3.29E+00	2.51E+00	-2.35E+00					
4	-5.89E+00	4	2.26E+00	-3.50E+00	-2.08E+00	-7.42E-01	-5.20E+00	4.29E+00	1.63E+00	1.85E+00	4.67E+00	-2.54E+00					
5	-6.70E-01	5	4.44E+00	9.00E-01	2.50E-01	-1.67E-01	-1.63E+00	2.16E+00	-2.96E+00	-1.84E+00	3.39E-02	4.13E-01					
6	-1.76E-01	6	2.28E-01	1.61E-01	-6.81E-01	5.59E+00	-1.49E+00	-2.10E+00	-3.72E-01	-3.75E-01	-5.46E-01	2.49E+00					
7	-1.42E+00	7	-2.54E+00	-1.48E+00	-3.97E+00	3.79E+00	1.15E+00	4.46E+00	-9.77E+00	-4.05E+00	3.68E-01	-1.79E+00					
8	8.56E-01	8	-1.98E-01	8.73E-01	1.24E-01	-1.66E+00	5.32E-02	3.11E+00	5.98E-01	1.38E-02	1.32E-01	-2.68E-01					
9	6.20E-01	9	2.13E-01	-6.91E-01	-3.95E-01	1.98E+00	3.34E+00	1.04E+00	-7.94E+00	-9.12E+00	-1.83E+00	2.48E+00					
10	2.53E+00	10	-5.02E-02	2.02E+00	-4.76E-01	1.16E+00	3.66E+00	-2.80E-01	-2.44E+00	-3.02E+00	1.13E+00	1.33E+00					
11	-6.68E+00	11	4.01E+00	-5.56E-01	-1.22E+00	-3.77E+00	4.95E-01	9.78E-01	8.18E-01	-4.61E-01	1.54E+00	-1.33E+00					
12	3.95E+00	12	2.06E-01	1.28E+00	3.54E+00	3.48E+00	2.46E+00	3.77E-01	6.20E-01	4.85E-01	-4.00E+00	3.21E+00					
13	-3.31E+00	13	-1.15E+00	-5.46E-01	-9.25E-01	-2.32E+00	1.01E+00	1.45E+00	-3.91E+00	-1.37E+00	1.83E-01	1.36E+00					

PARÂMETROS LIVRES					RNA	TEQ	Cadeira	F5					
14	2.92E+00	14	7.22E-01	2.58E+00	8.52E-01	-1.37E+00	-1.59E+00	-3.60E+00	1.08E+00	-8.00E-01	3.05E+00	2.21E+00	
15	1.18E+00	15	-1.69E+00	-1.03E+00	3.72E+00	2.09E-02	-1.00E+00	9.29E-01	-7.18E-01	-1.17E+01	-3.33E-01	6.58E+00	
16	-3.77E+00	16	-1.75E-01	-4.97E-01	3.64E+00	-1.59E+00	-3.03E+00	-3.80E+00	-3.10E+00	-1.44E+00	-3.43E+00	2.85E+00	
17	-1.59E-01	17	-2.28E+00	5.38E-01	2.45E-01	2.30E-01	2.59E+00	4.95E+00	1.14E-01	3.31E+00	4.27E+00	-2.99E-01	
18	-1.78E+00	18	-9.96E-01	-1.81E+00	-1.66E+00	7.39E-01	-4.01E+00	2.45E-01	-5.55E-01	2.79E-01	-1.47E+00	-3.68E-01	
19	1.25E+00	19	-7.96E+00	1.37E+00	-5.52E+00	-1.91E+00	-9.20E-01	4.46E+00	-2.37E+00	8.68E-01	2.60E+00	-1.35E+00	
20	9.90E-01	20	-1.28E+00	2.95E-01	-3.71E+00	5.59E+00	-6.70E+00	-7.46E+00	3.18E+00	1.42E+00	-2.52E+00	-2.03E+00	
21	-5.15E+00	21	-1.29E+00	-1.72E+00	-1.82E+00	-5.41E+00	6.56E-01	6.56E-01	9.94E-01	1.75E+00	7.73E-01	-1.03E-01	
22	-2.70E+00	22	-3.30E+00	-6.91E-01	-2.31E+00	-3.34E+00	-2.51E+00	-1.13E+00	-1.82E+00	5.43E-01	1.87E+00	-2.75E+00	
23	-2.74E+00	23	-1.72E+00	2.10E+00	-9.65E-02	-2.05E+00	9.50E-01	5.99E-01	1.89E+00	1.15E+00	2.60E+00	-6.04E-01	
24	-1.31E+00	24	1.66E+00	-3.85E+00	-2.18E+00	-5.00E+00	-1.25E+00	-1.04E+00	-1.13E+00	1.40E+00	-7.95E-01	-2.33E+00	
25	3.18E+00	25	-4.69E+00	3.71E-02	3.79E+00	1.08E+00	3.12E+00	-1.42E+00	-5.37E+00	6.50E-01	8.41E-01	-3.17E+00	

Camada	3	Arquitetura	13	neurônios		x	25	inputs		RNA	de	TEQ	Cadeira	F5
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10		
1	1.26E-01	1	3.13E+00	-1.89E-01	1.85E+00	-1.19E+00	-9.10E-01	-1.48E+00	-6.87E-01	7.22E-01	3.28E-01	-2.49E+00		
2	-3.57E+00	2	3.87E+00	1.96E-01	3.15E+00	-2.76E+00	-1.54E+00	4.40E+00	-2.25E-01	-1.82E+00	9.56E-01	7.16E-01		
3	-7.22E-01	3	8.28E-01	4.95E-01	2.14E+00	-5.72E-01	4.99E-01	1.18E+00	1.26E+00	7.58E-01	-9.79E-01	1.40E+00		
4	9.24E-01	4	1.80E+00	4.20E-01	-1.19E+00	6.02E-03	-6.67E-01	-8.54E-01	-2.01E+00	-2.17E+00	1.07E-01	-9.37E-01		
5	1.15E+00	5	-6.28E-01	-2.48E+00	-4.20E+00	4.01E-01	-1.88E+00	-2.18E-02	-1.99E+00	-5.55E+00	9.82E-02	-1.41E+00		
6	1.45E+00	6	-5.47E-01	2.80E+00	2.32E+00	1.44E-01	-2.67E+00	-1.59E+00	3.04E+00	4.98E+00	-1.96E+00	-2.34E-01		
7	1.91E+00	7	3.04E+00	3.14E+00	1.04E+00	-5.19E+00	-2.76E+00	7.55E-01	1.26E+00	9.54E-01	-2.98E+00	2.61E+00		
8	2.30E+00	8	2.37E+00	-1.44E+00	-4.72E-01	3.52E+00	-2.14E+00	-1.07E+00	-3.47E+00	2.50E+00	2.74E+00	-2.65E+00		
9	-1.93E-01	9	1.79E+00	1.12E+00	-1.95E+00	-1.42E+00	-1.24E+00	2.70E+00	1.86E+00	-7.84E-01	2.18E+00	1.91E+00		
10	-3.19E+00	10	-9.14E-01	-8.41E-02	-5.98E-01	1.15E-01	1.84E-02	9.90E-01	1.18E+00	-1.92E+00	1.44E+00	-1.21E+00		
11	-6.31E-01	11	-1.39E+00	-2.65E+00	1.57E-01	-9.64E-01	-5.96E-01	-7.48E-01	-7.43E+00	-2.61E+00	4.93E+00	-2.11E+00		
12	-1.54E+00	12	-1.35E+00	3.34E+00	-2.06E-01	-6.30E-01	1.22E+00	1.38E+00	1.05E+00	-4.82E+00	2.30E-01	-3.94E+00		
13	-9.08E-01	13	4.40E+00	1.99E-01	-1.89E+00	-2.37E+00	-1.26E+00	-4.19E+00	2.92E+00	-3.84E+00	-2.91E+00	1.12E+00		
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20		
		1	1.10E+00	-3.30E-01	1.50E+00	-1.24E+00	-2.45E+00	2.02E-01	-2.46E+00	8.67E-01	1.59E+00	1.56E+00		
		2	5.42E+00	7.56E-01	6.30E-01	1.89E+00	-3.20E+00	5.48E-01	4.09E+00	-7.45E-01	4.54E+00	5.39E+00		
		3	3.33E-01	-2.36E+00	1.21E+00	1.10E+00	-5.40E+00	5.33E-01	3.37E-01	-6.95E-01	-3.03E+00	7.18E+00		
		4	1.96E-01	5.47E-01	5.15E-01	-3.11E+00	-1.49E+00	-1.89E-01	2.55E+00	-2.66E+00	-2.27E+00	1.77E-01		

PARÂMETROS LIVRES		RNA	TEQ	Cadeira	F6
-------------------	--	-----	-----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	10	neurônios	x	3	10	4	inputs	RNA	de	7	8	TEQ	Cadeira	F6
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	-1.08E+01	1	-2.70E+00	-1.05E+01	-9.29E+00	-2.54E-01	-3.00E+00	9.04E+00	2.74E-01	-7.13E+00	3.87E+00	3.96E+00				
2	1.55E+01	2	-1.48E+00	8.09E-02	1.20E+01	8.84E+00	8.65E+00	-2.31E-01	-1.14E-02	2.06E+01	-4.23E+00	-5.05E-02				
3	1.45E+01	3	-7.45E+00	-4.75E-01	-1.10E+00	-2.27E+00	2.18E+00	-2.86E-02	7.14E-03	-1.13E+00	8.09E-01	-1.21E-03				
4	-1.52E+01	4	-2.73E+00	-1.92E+00	2.57E+00	6.19E+00	2.55E+00	-5.61E-01	2.29E-01	-1.08E-01	-2.71E+00	1.72E-01				
5	-1.92E+00	5	1.51E+00	2.42E+01	-1.19E+01	3.30E+00	6.58E+00	-1.03E-01	1.65E-01	-1.48E+01	2.30E+01	-4.91E-02				
6	-1.43E+01	6	-6.62E+00	-1.91E+01	-1.23E+00	-6.02E+00	-6.86E+00	-3.89E-01	2.06E-01	2.05E+01	-6.26E+00	8.10E-02				
7	-4.24E+00	7	-1.35E+01	-1.58E+00	-7.75E+00	3.50E+00	8.12E+00	1.58E-02	-4.75E-02	6.35E+00	-7.09E+00	1.20E-02				
8	-6.02E+00	8	9.85E+00	6.55E-02	6.97E-01	-1.42E-01	-1.35E-01	1.19E-03	4.89E-04	7.35E-01	-7.84E-01	4.80E-03				
9	9.77E+00	9	6.79E+00	3.65E-02	6.84E+00	-1.00E+00	6.81E-01	6.65E-02	-1.83E-02	4.19E+00	-5.13E+00	-3.53E-02				
10	1.99E+01	10	-2.07E+00	-7.76E+00	-5.64E+00	-5.38E-01	-1.53E+00	-6.91E+00	-3.97E+00	-3.59E-01	6.44E+00	6.29E+00				

Camada	2	Arquitetura	25	neurônios	x	3	10	4	inputs	RNA	de	7	8	TEQ	Cadeira	F6
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	3.79E+00	1	-4.45E+00	4.15E+00	4.63E-01	-3.94E+00	-3.44E+00	-8.53E+00	2.98E+00	-1.24E+01	1.76E+00	-1.16E+00				
2	1.62E+00	2	1.38E+00	-7.12E+00	3.32E+00	-7.34E-01	8.57E-01	-1.50E+00	2.21E+00	1.92E+00	-6.34E+00	-1.07E+00				
3	-3.42E+00	3	-2.41E-01	1.98E+00	3.28E+00	-2.65E-02	1.36E-01	3.81E+00	1.70E+00	1.02E+01	-1.87E+00	-1.97E+00				
4	-1.32E+00	4	2.53E+00	6.52E+00	1.14E+01	-1.86E+00	-2.88E-01	3.12E+00	-3.00E+00	7.69E+00	1.54E+00	-6.02E+00				
5	-3.35E+00	5	8.60E-03	-3.53E-01	-1.62E+00	4.96E+00	-8.86E-02	7.66E+00	9.98E-01	-2.53E+00	7.03E-01	2.45E+00				
6	-5.50E+00	6	-3.99E+00	-3.00E+00	1.37E+00	6.32E+00	-6.34E+00	-1.46E+00	-5.80E+00	-5.85E+00	-2.57E+01	-4.22E+00				
7	3.30E+00	7	4.20E-01	1.04E+00	2.02E+00	-1.26E-01	-6.37E-02	-2.83E+00	-1.80E-01	-3.16E+00	4.91E-01	-1.56E+00				
8	1.00E+00	8	1.01E+00	9.02E+00	-1.21E+01	4.36E+00	1.02E-01	-4.78E+00	-2.96E+01	-6.23E+00	-9.06E+00	-1.17E+00				
9	9.18E+00	9	7.52E+00	-7.57E+00	-6.37E-01	-8.41E+00	3.16E-01	2.05E-01	3.28E+00	-2.05E+00	-1.96E+01	7.02E+00				
10	2.25E+00	10	1.40E+00	-1.69E+00	-5.10E+00	-4.53E+00	2.57E+00	1.44E+00	3.48E+00	-1.49E+01	2.08E+00	3.83E+00				
11	2.18E+00	11	-1.76E+00	1.25E+00	1.49E+01	-1.52E+00	1.99E+00	-1.25E+01	-2.86E+00	1.05E+01	-9.46E+00	-3.02E+00				
12	-2.80E+00	12	-1.51E-01	1.03E+01	-2.28E+00	-2.94E-01	8.18E-01	1.90E+01	-5.60E+00	-1.34E+00	-7.77E+00	-4.07E+00				
13	-7.35E+00	13	-4.87E+00	5.81E+00	-7.62E+00	7.94E+00	9.08E+00	-8.16E+00	-6.21E+00	-7.89E+00	-2.03E+01	-8.63E+00				

PARÂMETROS LIVRES			RNA	TEQ	Cadeira	F6						
14	3.44E+00	14	8.56E-01	1.12E+01	6.65E+00	-5.65E+00	-1.80E+01	-4.19E+00	-9.00E+00	-2.71E+00	1.10E+01	6.90E+00
15	-6.45E-01	15	2.38E+00	-4.77E+00	-5.47E+00	-2.70E-01	-6.09E+00	-1.85E+00	-1.70E+00	9.45E+00	1.50E+00	-3.91E-01
16	-5.64E-02	16	-5.94E-01	2.94E+00	6.01E+00	5.07E-01	5.13E+00	-8.71E-02	4.67E+00	-2.37E+00	2.84E+00	-1.41E+00
17	-2.51E+00	17	-2.81E+00	2.32E+00	6.10E+00	6.03E-01	5.09E+00	-1.70E-01	1.25E+01	1.85E+01	-3.98E+00	-1.27E+00
18	-2.05E+00	18	-6.88E-01	-5.75E-01	7.36E+00	7.37E+00	1.90E+00	-3.95E+00	2.15E+00	-1.00E+01	-3.67E+00	3.68E-01
19	9.19E-01	19	-5.23E+00	7.78E-01	-6.75E+00	-5.16E-01	-3.99E+00	3.17E+00	2.81E+00	1.72E+00	-2.74E+00	3.21E+00
20	-1.94E+00	20	-3.61E-01	-1.26E+00	1.26E+00	-6.80E+00	1.49E-01	-1.94E+00	2.86E-01	-4.60E-01	8.56E-01	-2.65E+00
21	1.54E+00	21	1.44E-01	-1.32E-01	-2.12E-01	1.60E+00	-4.69E-02	2.53E-01	1.16E-01	-1.20E+00	1.05E-01	-4.60E-01
22	3.06E+00	22	1.05E+00	-2.03E-01	1.44E+00	-2.39E+00	4.68E+00	-1.03E+01	4.84E+00	-2.42E+00	6.48E+00	8.52E+00
23	-1.54E+00	23	5.58E+00	-2.41E-01	6.67E+00	1.79E+00	-3.03E-02	7.41E-02	-1.86E+00	9.45E-01	4.69E-01	6.61E-01
24	-6.67E+00	24	-1.23E+01	6.63E-01	3.96E+00	5.06E+00	-9.25E+00	1.06E+01	-6.03E+00	-3.97E+00	-2.57E+01	-4.30E+00
25	-9.66E+00	25	-3.99E+00	-9.01E-01	1.42E+01	6.11E+00	1.69E-01	9.49E-01	9.08E+00	1.45E+01	8.15E-01	7.59E+00

Camada	3	Arquitetura	13	neurônios		x	25		inputs	RNA	de	TEQ	Cadeira	F6
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10		
1	1.02E+00	1	-1.83E-01	-1.24E-01	-8.01E-03	1.51E-01	1.07E+00	-2.47E-02	6.57E-01	-5.11E-02	-1.73E+00	-1.80E-01		
2	-2.08E-01	2	6.19E+00	-3.63E+00	-1.30E+00	9.60E+00	1.41E+01	1.89E+00	-3.91E+00	-8.58E-01	-4.37E+00	-8.46E+00		
3	-9.46E+00	3	8.47E-01	2.20E+00	9.09E-01	1.57E+00	-6.44E-01	4.66E+00	-2.11E+00	-4.30E-01	4.05E+00	1.98E+00		
4	3.26E+00	4	-3.08E+00	-7.89E+00	3.27E+00	-4.24E+00	-6.42E+00	-8.77E+00	2.76E+00	1.78E+00	7.90E+00	-1.38E+01		
5	-8.14E+00	5	8.00E+00	-2.86E+00	6.46E+00	-3.92E+00	2.67E+00	6.13E+00	-9.34E+00	4.75E+00	-1.55E+01	5.96E+00		
6	7.68E+00	6	3.12E-01	3.08E-01	-1.26E-01	-1.62E+00	1.28E+00	-1.49E-01	-1.78E+00	-1.46E-01	-1.24E+01	-7.27E-01		
7	-2.25E+00	7	-3.98E-01	-3.43E+00	9.15E+00	6.23E-02	6.45E+00	-1.70E+01	8.83E+00	6.52E+00	7.24E-01	5.96E+00		
8	-1.36E+00	8	2.60E+00	-1.18E+00	3.86E+00	4.87E+00	1.42E+01	-1.84E+00	-5.30E+00	-8.96E+00	-2.38E+00	-9.62E-01		
9	-1.01E+00	9	2.34E-01	1.30E-01	-2.62E-01	1.50E-02	-8.03E-01	1.29E-02	-1.11E+00	-1.81E-02	-4.15E+00	8.28E-01		
10	-4.80E+00	10	-3.33E+00	2.41E+00	5.33E+00	-6.68E+00	6.44E+00	5.82E+00	-3.67E+00	-1.44E+01	-4.78E+00	-4.33E+00		
11	-5.66E-01	11	-4.56E+00	2.76E+00	-2.11E+00	-7.72E+00	3.73E+00	-2.62E+00	-5.15E+00	-5.86E+00	1.27E+00	-1.62E+00		
12	-6.78E+00	12	2.19E+00	-7.68E+00	1.95E+00	1.11E+01	1.33E+00	6.77E+00	-4.22E+00	4.16E+00	8.88E+00	-8.31E-02		
13	1.10E+00	13	-4.83E-02	4.50E-01	4.00E-01	-3.63E-01	1.31E+00	-1.01E-01	8.41E-01	-1.43E-01	-2.04E+00	2.53E+00		
		Pesos w_{ij}	11	12	13	14	15	16	17	18	19	20		
		1	1.32E-02	-1.48E-01	2.69E-01	-1.08E-01	2.82E-02	2.32E-02	1.74E-01	-1.72E-01	1.98E-01	2.51E-01		
		2	8.75E+00	1.12E+01	-3.82E+00	-4.94E+00	-1.03E+01	3.67E+00	-2.55E+00	6.84E+00	-6.07E+00	8.76E+00		
		3	1.35E-01	7.09E-01	1.09E+01	3.80E+00	-6.97E-01	1.30E+00	2.21E+00	5.73E-01	-1.33E+00	8.09E+00		
		4	3.79E+00	-4.53E+00	-1.88E+00	5.07E+00	-1.62E+00	3.66E+00	-5.36E-02	1.44E+01	-6.57E+00	7.25E+00		

PARÂMETROS LIVRES

Camada		4		Arquitetura		1	neurônios		x	13	inputs		RNA	de	TEQ	Cadeira	F6
Bias b_{ij}		Saída		Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10			
1	2.22E+01		3.90E+00	-9.44E-02	2.15E-01	1.80E-01	2.95E-01	8.18E-01	-8.59E-02	-1.65E-01	2.10E+00	-7.92E-02					
		Pesos w_{ij}	11	12	13												
1	2.14E-01	1.08E-01	-1.41E+00														

5	-9.37E-02	1.13E+00	7.13E+00	-2.50E+00	3.52E+00	3.11E+00	1.51E+00	-1.03E+01	-3.67E-01	1.31E+01	
6	3.48E-01	-3.62E-01	-2.56E+00	2.03E-01	-3.38E-01	-6.26E-02	-1.09E+00	-1.15E+00	-1.45E-01	-9.13E-01	
7	-1.45E+01	-6.47E-01	7.02E+00	-2.08E+01	1.15E+00	1.14E+01	-1.28E-01	-6.04E+00	2.14E+00	-7.25E+00	
8	1.21E+00	7.08E+00	-5.07E-01	4.03E+00	-1.37E+01	4.05E+00	-4.32E+00	3.35E+00	-2.39E+00	3.33E+00	
9	1.04E-02	-2.58E-01	-1.23E+00	-2.22E-01	7.55E-02	7.88E-01	-2.12E-01	4.35E-01	6.60E-01	4.09E+00	
10	8.10E+00	6.56E+00	6.26E-01	-2.65E+00	5.41E+00	7.02E+00	-1.54E+01	5.79E+00	-1.44E+00	5.46E+00	
11	-4.46E-01	6.03E+00	5.02E-01	-1.87E+00	2.46E+00	-6.05E+00	-1.44E+00	6.29E-01	-9.67E+00	-4.51E+00	
12	-1.71E+00	1.02E+01	3.82E+00	1.93E+00	-1.26E+01	-5.22E+00	1.58E+00	1.52E+00	2.79E+00	5.79E+00	
13	2.75E-01	-4.77E-01	1.46E+00	-4.13E-01	4.00E-01	8.52E-01	5.04E-01	1.34E-01	9.61E-01	3.82E-01	
Pesos w_{ij}		21	22	23	24	25					
1	-3.24E+00	-7.04E-02	3.52E-01	7.32E-02	8.98E-02						
2	1.46E+01	2.74E+00	-2.44E+00	-6.96E+00	5.66E+00						
3	-5.31E+00	3.27E+00	-3.05E+00	-4.26E-02	-2.13E+00						
4	-7.46E+00	-1.86E+00	-8.35E+00	-8.24E+00	1.98E+00						
5	-1.59E+01	7.15E+00	9.75E+00	-3.36E+00	-9.91E-01						
6	-2.37E+00	1.29E-01	-1.96E-02	-1.49E-01	-6.65E-01						
7	-2.27E+00	-2.19E+00	-4.87E+00	5.19E+00	-8.31E-01						
8	1.01E+01	3.76E+00	3.92E+00	1.30E+01	-2.70E+00						
9	-8.59E-02	-3.39E-01	5.67E-01	5.56E-02	-1.30E-02						
10	3.90E+00	-1.36E+01	5.98E+00	8.29E+00	-9.00E+00						
11	-3.79E+00	3.42E+00	-3.95E+00	-8.75E+00	-2.26E+00						
12	2.74E+00	2.02E+01	-1.04E+01	1.33E+00	1.04E+01						
13	-8.42E-01	-2.44E-01	-2.22E-01	-1.11E-01	-2.31E-01						

APÊNDICE I - Tabelas de Parâmetros Livres das RNA's de FW

PARÂMETROS LIVRES		RNA	FW	Cadeira	F1
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	11	neurônios	x	3	4	11	inputs	RNA	de	7	8	Cadeira	F1
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	2	3	4	11	5	6	7	8	9	10	11
1	1.14E+01	1	-1.76E+00	1.64E+00	1.79E+00	2.60E+01	2.60E+01	2.60E+01	2.69E+00	-1.77E-02	2.77E-02	1.78E-02	-1.86E-01	2.95E-01	-9.65E-03
2	-2.02E+01	2	-2.97E+00	4.09E-01	2.07E+00	-1.59E+00	-1.59E+00	-1.59E+00	-3.17E+00	1.47E-01	1.83E-01	1.80E-02	-4.73E-01	4.91E-01	-3.10E-02
3	1.18E+01	3	3.98E-01	2.30E+00	-3.26E+00	9.72E-01	9.72E-01	9.72E-01	2.70E+00	-2.87E-02	-1.16E-02	9.12E-03	1.46E-01	-3.49E-02	-6.96E-03
4	-1.91E+01	4	2.10E+00	-9.66E-01	3.27E+00	-2.30E+00	-2.30E+00	-2.30E+00	1.81E+00	2.80E-02	1.62E-03	-1.77E-02	7.21E-02	-2.09E-01	1.11E-02
5	2.14E+01	5	2.28E+00	-5.49E-01	-1.16E+00	3.21E+00	3.21E+00	3.21E+00	-8.40E-01	-9.14E-02	-1.29E-01	3.26E-02	2.71E-01	2.69E-01	2.88E-03
6	1.12E+01	6	3.20E+00	9.74E-02	-2.74E+00	3.08E+00	3.08E+00	3.08E+00	2.81E+00	1.61E-03	4.06E-02	5.16E-03	-4.12E-02	-2.49E-01	-9.73E-03
7	-1.63E+00	7	1.03E+00	-3.35E-01	-1.28E+00	4.22E+00	4.22E+00	4.22E+00	-9.69E-01	-3.06E-02	-4.83E-02	-2.58E-02	-6.10E-01	2.78E-01	3.06E-02
8	1.29E+01	8	2.99E+00	-1.01E+00	-2.11E+00	2.60E+00	2.60E+00	2.60E+00	3.81E+00	-1.44E-02	2.01E-02	-1.35E-02	-3.48E-01	-7.78E-02	3.16E-03
9	3.59E+00	9	2.19E+00	1.67E+00	-8.37E-01	2.59E+00	2.59E+00	2.59E+00	1.95E+00	-7.40E-02	-4.79E-03	-8.44E-03	6.85E-02	3.11E-01	1.38E-02
10	2.68E+01	10	3.51E-01	2.32E-01	2.97E+00	-3.31E+00	-3.31E+00	-3.31E+00	-2.12E+00	-1.03E-01	1.90E-02	3.08E-03	-2.83E-01	1.80E-01	1.09E-02
11	1.48E+01	10	-3.29E+00	1.01E-02	2.47E-01	2.01E+00	2.01E+00	2.01E+00	1.34E+00	1.83E-02	-3.02E-02	1.53E-03	2.27E-01	-3.22E-01	-2.15E-02

Camada	2	Arquitetura	25	neurônios	x	3	4	11	inputs	RNA	de	7	8	Cadeira	F1
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	2	3	4	11	5	6	7	8	9	10	11
1	1.88E+00	1	-4.11E-01	7.46E-01	-1.03E+00	-4.08E-01	7.69E-01	7.69E-01	-1.14E+00	4.97E-01	5.68E-01	2.15E-01	-3.61E-02	3.31E-01	-8.30E-01
2	-1.78E+00	2	3.34E-01	-1.03E+00	-8.37E-01	-6.48E-01	-4.02E-01	-4.02E-01	7.53E-01	5.00E-01	-6.16E-01	-6.56E-01	-2.53E-01	-4.65E-01	6.58E-02
3	1.47E+00	3	-1.57E+00	-8.37E-01	6.15E-01	2.61E-02	-3.39E-01	-3.39E-01	1.06E+00	3.76E-01	5.40E-01	7.04E-01	5.67E-01	5.85E-01	4.74E-01
4	1.40E+00	4	-9.20E-01	6.15E-01	-4.63E-01	-4.63E-01	-5.28E-02	-5.28E-02	-4.80E-01	-9.11E-01	1.04E+00	-4.09E-01	-1.27E+00	-4.21E-01	-1.57E-01
5	1.34E+00	5	-3.56E-01	-1.40E-01	1.09E+00	1.09E+00	4.55E-01	4.55E-01	3.90E-01	4.28E-01	4.39E-01	-1.15E+00	-3.83E-01	4.82E-01	-4.74E-01
6	7.68E-01	6	-4.40E-01	4.26E-01	-6.77E-01	-6.77E-01	1.47E+00	1.47E+00	2.80E-01	5.54E-01	3.13E-01	6.02E-01	4.73E-01	-1.29E-01	2.49E-01
7	-1.03E+00	7	2.98E-01	2.12E-01	-9.76E-01	-9.76E-01	1.07E-02	1.07E-02	6.61E-01	6.99E-01	-5.35E-01	-5.28E-01	2.46E-02	-1.40E+00	6.88E-01
8	-7.59E-01	8	-7.39E-02	5.71E-01	-6.16E-01	-6.16E-01	-9.53E-01	-9.53E-01	-1.25E+00	-6.01E-01	1.25E+00	7.47E-01	8.77E-02	5.35E-01	-8.13E-01
9	8.10E-01	9	1.19E-01	8.00E-01	4.96E-01	4.96E-01	-3.31E-01	-3.31E-01	2.66E-01	-1.85E-01	-1.91E-01	7.93E-01	-1.26E+00	-4.05E-01	-1.54E-01
10	-2.20E-01	10	-8.20E-01	1.15E-01	-8.32E-01	-8.32E-01	5.35E-01	5.35E-01	3.89E-02	1.18E+00	4.98E-01	-7.88E-01	3.22E-01	-1.47E+00	-9.47E-01
11	5.82E-01	11	-7.14E-01	-6.21E-01	-2.02E+00	-2.02E+00	2.07E-01	2.07E-01	6.56E-01	1.75E-01	-2.73E-01	-3.08E-01	1.13E-01	8.77E-01	-8.37E-01
12	-4.50E-01	12	1.56E-02	-3.59E-02	8.34E-01	8.34E-01	-1.92E-01	-1.92E-01	6.69E-01	-4.20E-01	-1.52E-01	1.46E+00	1.47E-01	-9.62E-01	-8.86E-01

PARÂMETROS LIVRES													
		RNA	FW	Cadeira	F1								
13	1.86E-01	13	3.01E-01	-5.86E-01	7.78E-01	1.21E+00	-1.14E-01	-3.90E-01	3.86E-01	-1.58E+00	-6.99E-02	9.87E-01	9.52E-03
14	-2.39E-02	14	3.26E-01	-6.14E-01	-1.82E-01	1.29E-02	6.57E-01	8.90E-01	-8.22E-01	4.05E-01	1.19E+00	-6.72E-01	3.92E-01
15	-4.29E-01	15	-1.25E-01	1.02E+00	-1.26E+00	-5.61E-01	-2.81E-01	-2.73E-01	3.12E-02	-7.35E-01	6.16E-01	7.07E-01	3.87E-01
16	3.61E-01	16	8.50E-03	-1.07E+00	3.81E-01	-3.95E-02	2.58E-01	1.09E+00	-2.39E-01	3.91E-01	7.18E-01	1.28E+00	-2.98E-01
17	8.08E-01	17	4.43E-01	8.38E-01	6.35E-01	2.70E-02	2.88E-01	-6.35E-01	-7.04E-01	-1.49E-01	1.09E+00	-4.94E-01	1.37E-01
18	-4.21E-01	18	3.34E-01	-4.96E-01	-3.27E-02	1.19E-01	-5.69E-01	2.22E-01	3.87E-01	-1.24E+00	2.33E-01	-2.67E-01	-1.08E+00
19	8.66E-01	19	2.25E-01	-6.80E-01	-1.33E+00	1.05E+00	-6.70E-01	-8.41E-02	3.27E-01	-1.43E-01	-1.18E+00	-1.08E+00	8.58E-01
20	-1.20E+00	20	-1.82E+00	2.89E-02	1.74E-02	9.24E-01	5.17E-02	1.40E-01	-3.48E-01	-2.33E-01	-8.31E-02	8.01E-01	4.44E-01
21	1.33E+00	21	1.23E+00	-8.38E-01	2.11E-01	3.26E-01	-4.77E-01	-8.86E-01	7.14E-01	1.04E+00	-1.31E+00	1.04E-01	2.04E-02
22	1.29E+00	22	3.57E-01	7.10E-01	-3.42E-01	-1.53E-01	-7.77E-01	-7.23E-01	-3.71E-01	6.25E-01	9.38E-01	2.55E-01	-3.97E-01
23	1.45E+00	23	5.79E-01	-2.49E-01	9.34E-01	-1.30E+00	-1.11E+00	5.23E-01	9.47E-01	6.89E-01	2.79E-01	2.00E-01	-8.24E-01
24	-1.33E+00	24	-5.48E-01	1.16E+00	-6.09E-01	4.94E-01	-2.08E-01	-1.04E+00	1.27E+00	-8.88E-01	-9.41E-01	-7.95E-01	2.53E-01
25	1.73E+00	25	-1.29E-01	-1.54E-01	9.33E-01	2.52E-01	-4.00E-01	-5.50E-01	-9.98E-01	-5.49E-02	8.24E-01	1.42E-01	5.62E-01

Camada	3	Arquitetura	13	neurônios	x	25	inputs	RNA	de	FW	Cadeira	F1	
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11
1	-1.66E+00	1	1.69E-01	4.53E-01	1.40E-01	1.58E-01	-5.37E-01	2.38E-01	3.88E-01	-4.96E-01	-4.55E-01	-4.79E-01	-6.31E-02
2	-1.24E+00	2	-1.15E-02	-4.59E-01	5.13E-02	-8.85E-01	6.64E-01	2.17E-02	1.44E-01	-2.00E-01	-5.70E-01	3.59E-01	4.27E-02
3	1.10E+00	3	-2.00E-01	-3.85E-02	-3.27E-01	-3.40E-01	-3.87E-01	6.99E-01	-5.07E-01	-1.44E-01	-4.57E-01	-2.24E-02	2.10E-01
4	-9.17E-01	4	-1.27E-01	-9.52E-02	-3.36E-01	-1.89E-01	-3.37E-01	3.30E-01	1.18E-01	-3.64E-01	2.01E-01	-5.20E-01	7.11E-01
5	4.70E-01	5	-2.58E-02	1.07E-01	1.44E-01	3.71E-01	-1.48E-01	4.16E-01	2.94E-01	-4.49E-01	3.65E-01	-5.02E-01	7.22E-01
6	1.98E-01	6	-4.43E-01	2.39E-01	7.83E-02	3.57E-01	-2.30E-01	-6.77E-02	-2.00E-01	2.01E-01	-3.52E-01	1.06E-01	-2.03E-01
7	2.39E-02	7	-3.59E-01	1.45E-01	3.98E-01	2.76E-01	-1.75E-01	-2.26E-01	1.49E-02	-3.38E-01	9.00E-02	-1.07E-02	-5.44E-01
8	1.19E-01	8	1.19E-01	3.85E-01	5.70E-01	5.81E-02	-4.01E-01	-4.46E-01	-1.70E-01	-2.43E-02	-2.89E-01	4.43E-02	6.17E-01
9	-7.71E-01	9	-4.71E-01	6.33E-01	2.40E-01	2.57E-02	1.96E-01	2.13E-01	5.27E-01	3.28E-01	-1.42E-01	-2.74E-01	4.49E-01
10	-9.02E-01	10	-4.79E-01	-2.04E-01	-2.16E-01	-4.52E-01	7.20E-01	4.01E-01	-6.79E-01	-4.31E-01	-6.47E-02	4.82E-01	-5.05E-02
11	9.25E-01	11	-1.32E-01	-9.56E-02	1.76E-02	-5.34E-01	4.84E-01	7.29E-01	3.56E-01	1.38E-01	4.46E-01	1.72E-01	3.10E-01
12	1.37E+00	12	1.04E-01	-3.42E-01	-5.34E-01	6.11E-02	-2.36E-01	1.15E-01	-1.54E-01	-7.95E-01	4.10E-01	9.78E-01	-2.74E-01
13	1.45E+00	13	4.20E-01	-4.72E-01	7.31E-01	-3.05E-01	-2.19E-01	-8.24E-01	2.35E-01	3.42E-01	-5.78E-01	-2.87E-01	2.85E-01
		Pesos w_{ij}	12	13	14	15	16	17	18	19	20	21	22
		1	-4.20E-02	2.67E-01	-4.74E-02	1.87E-01	-2.23E-01	-1.92E-01	-2.72E-01	5.27E-02	3.73E-01	4.98E-01	-4.36E-01
		2	2.22E-01	-2.80E-01	-3.16E-01	5.85E-01	-5.26E-01	-3.11E-01	4.85E-01	4.78E-01	6.17E-01	-1.26E-01	-1.34E-01
		3	5.21E-01	7.00E-01	-3.55E-01	2.81E-01	3.82E-01	2.75E-01	-3.62E-01	4.54E-01	-5.98E-01	-1.90E-01	8.97E-03

PARÂMETROS LIVRES		RNA	FW	Cadeira	F2
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	11	neurônios	x	11	inputs	RNA	de	FW	Cadeira	F2	
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11
1	2.86E+01	1	-3.32E+00	2.16E-01	-1.63E+00	6.11E-01	1.25E+00	-4.45E-03	6.97E-03	4.22E-02	4.90E-01	-6.95E-01	-3.08E-02
2	-8.40E+00	2	1.68E+00	7.36E-01	3.57E+00	7.67E-01	-2.40E+00	-1.67E-02	6.05E-02	-2.92E-03	-5.16E-01	6.14E-01	8.92E-03
3	-1.10E+01	3	9.78E-01	-3.46E-01	-1.50E+00	-1.96E+00	-5.68E+00	5.68E-02	-6.23E-03	1.27E-02	-5.78E-01	4.31E-01	-3.04E-03
4	5.64E+00	4	3.15E+00	6.74E-01	-1.64E+00	5.14E-01	-3.22E+00	-4.57E-02	4.27E-02	3.01E-03	9.30E-02	1.27E-01	2.27E-03
5	-2.27E+01	5	4.81E-01	3.57E-01	2.86E+00	-1.91E+00	-1.70E+00	-4.94E-02	1.92E-02	1.03E-02	-1.60E-02	6.01E-01	3.36E-02
6	-9.41E+00	6	-4.80E+00	-5.97E-01	-1.67E+00	-2.64E+00	2.41E+00	1.88E-02	-2.73E-02	-9.13E-03	-2.77E-01	3.04E-01	9.15E-03
7	1.56E+01	7	5.35E-01	1.08E-02	4.14E+00	2.77E+00	-3.83E-01	-2.89E-02	-2.44E-02	-7.42E-03	-4.70E-01	3.95E-01	2.95E-04
8	-2.77E+00	8	3.16E+00	2.09E+00	4.77E+00	-3.02E+00	-1.87E+00	1.80E-02	-3.76E-02	-1.08E-02	-1.28E-01	3.69E-01	-2.00E-03
9	-2.64E+00	9	-3.00E+00	-5.51E-01	-2.17E+00	3.17E-01	1.72E+00	3.29E-02	-2.06E-02	-5.51E-03	6.16E-01	-1.50E+00	-1.13E-03
10	-1.74E+01	10	5.08E-01	3.28E-01	-2.35E+00	1.73E-01	-3.39E+00	4.58E-03	4.15E-02	2.24E-01	2.53E-01	3.03E-01	3.60E-03
11	1.85E+01	10	-2.43E+00	3.51E-01	-2.52E+00	3.75E+00	-5.43E-01	-4.66E-02	1.97E-02	2.84E-03	2.11E-01	1.65E-01	-1.10E-02

Camada	2	Arquitetura	25	neurônios			x	11	inputs		RNA	de	FW	Cadeira			F2
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11				
1	-1.85E+00	1	6.30E-01	1.41E+00	-3.17E-01	5.30E-01	1.83E-01	6.14E-02	9.42E-01	4.29E-01	8.43E-01	-4.46E-01	2.80E-01				
2	-1.61E+00	2	8.37E-01	-3.53E-01	1.68E+00	-2.01E-02	1.19E+00	2.39E+00	1.50E-02	2.45E-01	5.20E-01	4.36E-01	1.14E+00				
3	1.21E+00	3	-1.69E-01	5.18E-01	9.02E-01	-1.81E+00	2.52E-01	1.03E+00	-4.31E-01	9.18E-01	1.53E+00	1.97E-01	7.12E-01				
4	9.33E-01	4	-1.12E+00	-6.07E-01	-2.67E-01	5.91E-01	-4.70E-02	-9.86E-01	1.35E+00	-4.70E-01	-3.83E-01	9.34E-01	-4.30E-01				
5	-1.83E+00	5	6.69E-01	5.60E-01	-5.37E-01	4.82E-01	1.69E+00	-2.06E-02	-8.50E-02	1.10E+00	6.80E-01	6.69E-01	-6.15E-01				
6	-1.56E+00	6	-6.69E-02	1.82E-01	2.34E-01	8.27E-01	5.21E-01	-6.60E-01	9.67E-01	5.88E-01	-1.42E+00	-5.17E-01	1.14E+00				
7	-6.08E-01	7	1.33E-01	-4.95E-01	-9.81E-01	-7.09E-01	-5.08E-01	1.42E-01	-9.79E-02	-1.03E+00	5.25E-01	-1.14E+00	-8.37E-01				
8	1.17E+00	8	-2.14E-01	1.16E+00	3.90E-01	1.49E+00	2.31E-01	9.04E-01	1.31E+00	-2.84E-01	5.60E-01	4.46E-01	-5.58E-01				
9	-9.51E-01	9	3.01E-02	-7.34E-01	2.59E-01	7.99E-01	-5.57E-01	2.44E-01	-1.18E-01	6.23E-01	-7.64E-01	5.20E-01	-1.38E+00				
10	-5.87E-01	10	-3.50E-01	5.64E-01	1.01E-01	1.24E+00	1.26E+00	-2.19E+00	3.16E-01	5.36E-01	1.45E+00	-1.12E-01	6.29E-01				
11	6.94E-01	11	2.96E-01	8.45E-01	-6.84E-01	-1.28E+00	1.00E+00	-9.94E-03	2.32E-01	-4.54E-01	1.26E-01	-2.94E-01	9.47E-01				
12	-4.11E-01	12	7.17E-01	-6.57E-01	-9.51E-01	2.65E-01	-6.67E-01	1.59E-01	8.03E-01	-1.52E+00	-2.07E-01	7.29E-01	-1.18E-01				

PARÂMETROS LIVRES			RNA		FW	Cadeira	F2
Camada	3	Arquitetura	13	neurônios	x	25	4
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5
1	-1.60E+00	1	3.67E-02	2.50E-01	-3.64E-01	-2.49E-01	5.23E-03
2	-1.26E+00	2	4.77E-01	5.17E-01	-5.70E-01	2.66E-01	2.39E-01
3	6.52E-01	3	5.65E-01	-7.89E-01	-2.50E-01	2.91E-01	-4.67E-01
4	-6.59E-01	4	1.84E-01	-1.10E-01	1.37E-01	-1.34E-01	9.93E-01
5	8.37E-01	5	-5.92E-01	-2.93E-01	-5.77E-01	-1.69E-01	-1.12E+00
6	-1.54E-01	6	1.38E-01	-1.44E-01	7.46E-01	-9.16E-01	-1.63E-01
7	-4.20E-01	7	-5.46E-01	3.69E-01	-4.33E-01	-7.69E-02	-4.28E-01
8	-2.19E-01	8	-7.33E-01	-5.68E-01	6.03E-01	-1.78E-01	-1.50E-02
9	-6.42E-01	9	-3.39E-01	-2.18E-02	-6.71E-01	3.57E-01	-3.41E-01
10	5.02E-01	10	3.22E-01	-1.20E-01	-1.19E-01	3.89E-01	-5.35E-01
11	9.04E-01	11	4.12E-01	-5.93E-01	-6.74E-01	2.34E-01	-5.18E-01
12	1.21E+00	12	3.08E-01	-1.15E+00	-3.05E-01	-5.69E-01	-2.92E-01
13	1.47E+00	13	7.51E-01	-8.35E-01	-6.24E-01	-8.35E-01	-7.55E-02
		Pesos w_{ij}	12	13	14	15	16
		1	-3.94E-01	1.27E-01	-1.08E-02	-4.95E-01	1.45E-01
		2	-3.13E-01	6.61E-02	4.59E-01	-5.24E-01	3.96E-01
		3	-5.44E-01	-5.08E-01	4.48E-01	-3.46E-01	2.45E-01

PARÂMETROS LIVRES			RNA		FW	Cadeira	F2
Camada	3	Arquitetura	13	neurônios	x	25	4
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5
1	-1.60E+00	1	3.67E-02	2.50E-01	-3.64E-01	-2.49E-01	5.23E-03
2	-1.26E+00	2	4.77E-01	5.17E-01	-5.70E-01	2.66E-01	2.39E-01
3	6.52E-01	3	5.65E-01	-7.89E-01	-2.50E-01	2.91E-01	-4.67E-01
4	-6.59E-01	4	1.84E-01	-1.10E-01	1.37E-01	-1.34E-01	9.93E-01
5	8.37E-01	5	-5.92E-01	-2.93E-01	-5.77E-01	-1.69E-01	-1.12E+00
6	-1.54E-01	6	1.38E-01	-1.44E-01	7.46E-01	-9.16E-01	-1.63E-01
7	-4.20E-01	7	-5.46E-01	3.69E-01	-4.33E-01	-7.69E-02	-4.28E-01
8	-2.19E-01	8	-7.33E-01	-5.68E-01	6.03E-01	-1.78E-01	-1.50E-02
9	-6.42E-01	9	-3.39E-01	-2.18E-02	-6.71E-01	3.57E-01	-3.41E-01
10	5.02E-01	10	3.22E-01	-1.20E-01	-1.19E-01	3.89E-01	-5.35E-01
11	9.04E-01	11	4.12E-01	-5.93E-01	-6.74E-01	2.34E-01	-5.18E-01
12	1.21E+00	12	3.08E-01	-1.15E+00	-3.05E-01	-5.69E-01	-2.92E-01
13	1.47E+00	13	7.51E-01	-8.35E-01	-6.24E-01	-8.35E-01	-7.55E-02
		Pesos w_{ij}	12	13	14	15	16
		1	-3.94E-01	1.27E-01	-1.08E-02	-4.95E-01	1.45E-01
		2	-3.13E-01	6.61E-02	4.59E-01	-5.24E-01	3.96E-01
		3	-5.44E-01	-5.08E-01	4.48E-01	-3.46E-01	2.45E-01

PARÂMETROS LIVRES			RNA		FW	Cadeira	F2
Camada	3	Arquitetura	13	neurônios	x	25	4
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5
1	-1.60E+00	1	3.67E-02	2.50E-01	-3.64E-01	-2.49E-01	5.23E-03
2	-1.26E+00	2	4.77E-01	5.17E-01	-5.70E-01	2.66E-01	2.39E-01
3	6.52E-01	3	5.65E-01	-7.89E-01	-2.50E-01	2.91E-01	-4.67E-01
4	-6.59E-01	4	1.84E-01	-1.10E-01	1.37E-01	-1.34E-01	9.93E-01
5	8.37E-01	5	-5.92E-01	-2.93E-01	-5.77E-01	-1.69E-01	-1.12E+00
6	-1.54E-01	6	1.38E-01	-1.44E-01	7.46E-01	-9.16E-01	-1.63E-01
7	-4.20E-01	7	-5.46E-01	3.69E-01	-4.33E-01	-7.69E-02	-4.28E-01
8	-2.19E-01	8	-7.33E-01	-5.68E-01	6.03E-01	-1.78E-01	-1.50E-02
9	-6.42E-01	9	-3.39E-01	-2.18E-02	-6.71E-01	3.57E-01	-3.41E-01
10	5.02E-01	10	3.22E-01	-1.20E-01	-1.19E-01	3.89E-01	-5.35E-01
11	9.04E-01	11	4.12E-01	-5.93E-01	-6.74E-01	2.34E-01	-5.18E-01
12	1.21E+00	12	3.08E-01	-1.15E+00	-3.05E-01	-5.69E-01	-2.92E-01
13	1.47E+00	13	7.51E-01	-8.35E-01	-6.24E-01	-8.35E-01	-7.55E-02
		Pesos w_{ij}	12	13	14	15	16
		1	-3.94E-01	1.27E-01	-1.08E-02	-4.95E-01	1.45E-01
		2	-3.13E-01	6.61E-02	4.59E-01	-5.24E-01	3.96E-01
		3	-5.44E-01	-5.08E-01	4.48E-01	-3.46E-01	2.45E-01

PARÂMETROS LIVRES		RNA	FW	Cadeira	F2
4		-2.06E-01	9.26E-01	5.71E-01	-6.25E-01
5		-4.05E-01	-4.86E-01	-5.25E-01	4.27E-01
6		-4.30E-01	2.43E-01	1.95E-01	-1.71E-01
7		6.30E-01	4.91E-01	-4.10E-01	-6.59E-01
8		-3.70E-01	4.59E-01	-5.91E-02	-2.00E-01
9		1.45E-01	-2.20E-01	-2.47E-01	-1.77E-01
10		-4.89E-01	-3.60E-01	5.55E-02	-8.10E-01
11		-5.38E-01	-4.24E-01	3.43E-02	1.90E-01
12		-9.76E-01	2.81E-01	4.60E-02	-6.72E-02
13		-1.18E+00	2.09E-02	4.31E-01	2.83E-01
Pesos w _{ij}		23	24	25	
1		-3.57E-02	3.41E-01	-2.38E-01	
2		-3.43E-01	4.65E-01	8.42E-02	
3		1.35E-01	7.67E-02	3.46E-01	
4		3.00E-01	-1.26E-02	1.33E-01	
5		-3.05E-01	-3.65E-02	3.63E-01	
6		4.24E-01	1.07E+00	-7.20E-01	
7		-7.79E-01	-6.38E-01	1.02E+00	
8		-9.31E-02	9.39E-02	-4.50E-01	
9		-2.46E-02	-8.23E-01	5.23E-01	
10		-3.54E-01	-2.53E-01	-5.24E-01	
11		-4.37E-01	-2.69E-01	-1.69E-01	
12		-1.20E+00	-5.10E-01	1.09E-01	
13		-3.21E-01	-4.62E-01	-4.46E-01	

[illegible]

PARÂMETROS LIVRES		RNA	FW	Cadeira	F3
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	11	neurônios		x	11	inputs		RNA	de	FW	Cadeira		F3
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	3	4	4	5	6	7	8	9	10	11
1	8.88E+00	1	-9.27E-01	-9.77E-01	3.06E+00	2.68E+00	-1.45E+00	-1.48E-02	7.80E-03	5.46E-03	3.00E-01	-1.62E-01	3.00E-01	-1.62E-01	-6.34E-03
2	1.67E+01	2	-2.88E+00	5.09E-01	2.10E+00	-3.00E+00	-1.10E+00	9.26E-03	1.24E-02	-3.98E-02	8.12E-01	-3.50E-01	8.12E-01	-3.50E-01	-2.66E-02
3	-1.95E+01	3	-2.49E+00	2.27E-01	1.89E+00	-1.21E+00	-3.03E+00	7.40E-02	3.14E-03	6.17E-03	-3.17E-01	1.65E-01	-3.17E-01	1.65E-01	-5.67E-03
4	-2.08E+00	4	-1.56E+00	-5.28E-01	-9.13E-02	-4.04E+00	-2.71E+00	3.03E-02	-2.22E-02	7.11E-03	8.56E-01	-1.40E+00	8.56E-01	-1.40E+00	-3.19E-03
5	-2.16E+01	5	2.90E+00	-7.40E-01	-1.49E+00	-4.46E-01	9.92E-01	4.12E-02	-2.71E-02	3.41E-03	-4.25E-01	4.82E-01	-4.25E-01	4.82E-01	1.33E-02
6	-6.08E+00	6	2.23E+00	-6.73E-01	3.57E+00	-2.75E+00	6.71E-01	-6.85E-03	2.28E-02	2.20E-02	-4.38E-01	1.34E+00	-4.38E-01	1.34E+00	-4.20E-04
7	-2.55E+01	7	3.01E-01	7.93E-01	-1.16E+00	1.50E+00	3.04E+00	5.72E-02	-2.53E-03	-6.67E-03	-7.45E-01	9.23E-01	-7.45E-01	9.23E-01	5.82E-03
8	-9.23E+00	8	1.33E+00	8.22E-01	2.23E+00	4.87E-02	-2.45E+00	-3.14E-02	2.62E-02	-3.55E-02	-5.28E-01	1.00E+00	-5.28E-01	1.00E+00	1.62E-02
9	1.23E+01	9	-2.39E-01	-3.19E-01	3.93E+00	3.65E+00	2.04E+00	2.82E-03	-2.64E-02	4.74E-02	-1.56E-01	-1.02E-01	-1.56E-01	-1.02E-01	-1.10E-02
10	6.37E+00	10	4.31E+00	3.14E-02	-2.25E+00	1.50E+00	1.61E+00	-3.74E-02	6.60E-03	3.53E-03	-1.17E+00	1.39E+00	-1.17E+00	1.39E+00	8.76E-03
11	1.07E+00	10	-4.64E+00	-2.17E+00	-2.22E+00	2.82E-01	-3.77E+00	6.04E-02	-2.20E-02	-1.12E-03	5.27E-02	-1.78E-01	5.27E-02	-1.78E-01	-1.79E-02

Camada	2	Arquitetura	25	neurônios		x	11	inputs		RNA	de	FW	Cadeira		F3
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11		
1	-1.78E+00	1	5.96E-01	2.62E-01	1.38E+00	-4.49E-01	4.44E-01	1.29E-01	8.64E-01	-4.18E-01	-1.57E-02	2.19E+00	1.43E+00		
2	-1.99E+00	2	5.63E-01	2.89E-01	8.28E-02	5.12E-01	1.06E+00	5.07E-01	9.86E-01	2.71E-01	1.93E-01	-1.71E+00	1.11E+00		
3	-1.58E+00	3	7.02E-01	-1.13E+00	2.02E-01	-5.01E-02	-9.86E-01	-8.47E-01	3.91E-01	-2.41E-01	7.97E-01	-2.43E-01	-5.38E-01		
4	-1.13E+00	4	-2.14E-01	-1.25E-01	3.87E-01	3.54E-02	-5.34E-01	-1.00E+00	4.72E-01	-5.98E-01	-2.86E-01	1.29E-01	1.39E+00		
5	-1.30E+00	5	1.35E-02	-1.16E+00	-2.46E-02	1.00E+00	-2.95E-01	-1.05E+00	1.27E+00	1.69E-01	-1.36E-01	-1.21E+00	-4.76E-01		
6	5.26E-01	6	-6.64E-01	4.97E-01	6.42E-01	-1.08E+00	2.20E-01	4.32E-02	-5.24E-02	-2.13E-01	4.28E-01	-7.39E-01	1.48E+00		
7	-7.52E-01	7	-4.12E-01	7.09E-01	2.55E-02	1.24E+00	9.94E-01	-4.88E-01	-3.06E-01	1.43E+00	6.64E-01	1.78E-01	1.25E+00		
8	-4.82E-01	8	2.50E-01	1.03E+00	6.41E-01	1.21E+00	3.74E-01	-2.57E-01	-9.49E-01	3.00E-01	-1.23E+00	8.84E-01	6.88E-01		
9	-7.63E-01	9	9.05E-01	-5.53E-01	-2.82E-01	-3.22E-01	-4.25E-01	3.13E-01	-1.02E-01	4.76E-01	4.10E-01	-3.26E-01	9.47E-01		
10	-1.35E-01	10	-1.42E-01	-8.62E-01	-1.02E+00	8.24E-01	3.26E-01	1.30E+00	-7.80E-01	3.94E-01	-4.67E-01	5.84E-01	-7.30E-01		
11	-1.96E-01	11	9.19E-01	1.26E+00	2.64E-01	-1.91E-01	1.49E-01	-4.36E-01	4.84E-01	1.01E-01	4.97E-01	1.36E+00	-1.35E+00		
12	6.64E-02	12	-1.08E+00	1.88E-01	2.20E-01	2.57E-01	3.13E-01	-6.10E-01	6.20E-02	-4.64E-01	-9.49E-02	2.28E-01	-1.33E+00		

PARÂMETROS LIVRES

LIVRES													
13	2.77E-02	13	-1.28E+00	8.55E-01	-4.03E-01	1.30E+00	-1.39E-01	-3.35E-01	-8.14E-01	-5.89E-01	-5.69E-01	-4.52E-01	1.18E-02
14	-5.75E-01	14	-1.03E+00	-6.21E-01	-6.47E-01	-1.61E-01	9.68E-01	-1.63E-01	9.06E-02	2.46E-01	-5.87E-01	1.35E+00	1.19E+00
15	-2.18E-01	15	1.34E-01	2.45E-01	5.16E-01	1.03E+00	-6.41E-01	5.94E-02	1.62E-01	-5.77E-01	-6.51E-01	-2.58E-01	-1.63E-01
16	4.43E-01	16	1.18E+00	-4.26E-01	2.65E-01	8.52E-01	6.00E-01	2.03E-01	-5.37E-01	5.40E-01	-2.00E-01	6.50E-01	6.38E-01
17	-6.54E-01	17	-7.57E-01	9.27E-01	2.10E-01	-8.58E-01	9.54E-01	-9.58E-02	8.90E-01	-9.84E-02	6.66E-02	3.54E-01	6.23E-01
18	-6.84E-01	18	-5.68E-01	1.60E+00	8.83E-02	-6.45E-01	-1.02E+00	7.38E-01	-1.25E+00	4.43E-01	-3.45E-02	9.06E-01	-1.73E+00
19	-9.26E-01	19	-7.15E-01	-7.67E-01	-2.16E-02	-3.89E-01	8.79E-01	7.08E-01	-6.16E-01	8.54E-01	4.47E-01	-6.49E-01	3.62E-01
20	1.45E+00	20	6.10E-01	7.78E-01	-6.65E-01	-4.00E-01	1.74E-01	-6.10E-01	-4.82E-02	1.81E-01	4.75E-01	1.04E+00	-6.34E-01
21	-1.76E+00	21	-1.72E-01	-1.09E+00	-8.75E-01	6.62E-01	5.03E-02	8.81E-01	2.28E-01	5.87E-01	3.26E-01	3.83E-01	1.20E+00
22	-1.67E+00	22	-1.43E+00	2.96E-01	1.33E-02	2.05E-01	-1.06E+00	1.08E+00	-8.02E-01	-2.84E-01	5.73E-01	6.38E-02	9.35E-01
23	-1.30E+00	23	-8.29E-01	-1.00E+00	9.95E-04	-3.71E-01	-6.94E-01	2.30E-01	-8.77E-01	-1.07E+00	4.52E-01	3.81E-01	5.22E-01
24	1.88E+00	24	2.72E-01	-7.93E-01	7.20E-01	-9.40E-01	1.52E-01	-1.24E+00	5.66E-01	6.59E-01	-9.04E-01	-1.21E+00	4.83E-01
25	1.76E+00	25	4.27E-01	3.09E-01	-1.06E+00	-9.28E-02	-6.49E-01	2.87E-01	7.64E-02	-1.37E-01	-5.91E-01	1.14E+00	-7.87E-01

Camada	3	Arquitetura	13	neurônios	x	25	inputs	RNA	de	FW	Cadeira	F3	
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11
1	1.49E+00	1	-9.56E-02	-6.58E-01	-1.65E-01	5.15E-01	2.16E-01	4.39E-01	1.50E-01	1.68E-01	-1.80E-01	1.63E-02	-6.14E-01
2	1.29E+00	2	5.82E-01	-5.82E-01	-4.43E-01	9.77E-02	1.67E-01	1.67E-01	4.95E-01	-3.37E-01	-6.54E-01	-5.54E-01	2.57E-01
3	9.94E-01	3	5.07E-02	3.36E-01	-3.46E-01	1.31E-01	-3.28E-03	-1.85E-01	9.33E-01	-2.31E-02	2.16E-01	7.11E-01	7.69E-01
4	5.11E-01	4	-2.60E-01	1.85E-01	2.17E-01	2.13E-01	3.11E-01	-4.26E-01	1.10E-01	-7.16E-01	-5.05E-01	2.31E-01	-5.98E-02
5	7.46E-01	5	-1.13E+00	-4.45E-01	-4.79E-02	-5.91E-01	-9.13E-01	1.55E-01	-1.23E-01	-8.34E-02	4.11E-01	7.85E-01	-5.45E-01
6	4.86E-01	6	1.49E-01	9.26E-02	-1.60E-01	-1.07E-01	1.48E-01	6.53E-01	5.20E-01	3.89E-02	-7.73E-01	-6.11E-02	1.78E-01
7	3.29E-01	7	-3.36E-02	8.25E-01	-3.47E-01	-4.90E-01	-5.70E-01	-3.73E-01	-5.31E-01	4.38E-01	1.25E-01	3.12E-01	-6.82E-01
8	3.32E-01	8	3.35E-01	1.64E-01	-4.05E-02	-6.40E-01	7.87E-01	1.68E-01	1.99E-01	3.44E-01	7.46E-01	1.68E-01	1.19E+00
9	-6.81E-01	9	-7.11E-01	-4.75E-01	5.67E-01	8.55E-01	2.64E-01	-8.36E-02	-6.04E-01	4.26E-01	-5.31E-01	6.52E-01	-1.29E-01
10	-9.44E-01	10	-6.66E-01	-2.54E-02	-3.66E-01	3.43E-01	-3.15E-02	8.80E-01	-4.45E-01	2.01E-01	2.50E-01	-1.61E-01	-6.21E-02
11	1.01E+00	11	-2.95E-01	-3.87E-01	2.42E-01	-3.61E-01	3.66E-01	5.01E-01	-1.28E+00	2.43E-01	9.54E-02	2.73E-01	3.35E-01
12	-1.15E+00	12	5.46E-02	1.50E-01	5.30E-01	7.17E-01	4.60E-01	1.25E-01	-1.12E-01	-1.62E-01	-4.85E-01	4.44E-02	1.05E-01
13	-1.35E+00	13	8.84E-02	2.37E-01	-5.59E-01	8.24E-01	1.01E+00	4.19E-01	-3.07E-01	-6.53E-01	-1.07E+00	-1.63E-01	-5.19E-04
		Pesos w_{ij}	12	13	14	15	16	17	18	19	20	21	22
		1	5.20E-01	-5.56E-02	-3.49E-01	-3.28E-01	5.20E-02	5.54E-01	-2.19E-01	1.45E-01	4.10E-01	-4.24E-01	-3.69E-01
		2	2.75E-01	5.39E-01	-6.89E-02	3.94E-01	-6.01E-01	-6.07E-02	1.15E-03	6.52E-01	-4.03E-01	3.78E-01	3.30E-01
		3	-8.93E-01	-4.35E-01	7.88E-01	-3.73E-01	6.47E-01	-2.10E-01	4.30E-01	-3.90E-02	2.21E-01	8.31E-02	-2.26E-01

PARÂMETROS LIVRES		RNA	FW	Cadeira	F3							
4		5.21E-01	-2.62E-01	6.34E-02	-6.37E-02	-5.07E-01	9.85E-01	6.84E-01	7.25E-01	-3.51E-01	-1.21E-01	-6.13E-01
5		3.89E-01	-3.97E-01	3.61E-01	4.41E-01	2.17E-01	5.80E-01	-2.99E-01	-1.16E-01	7.29E-01	-1.76E-01	-3.47E-01
6		6.49E-01	-1.49E-01	1.33E-01	-5.54E-01	-1.26E-01	-5.68E-01	-2.41E-01	-5.31E-01	-1.98E-01	-2.18E-01	1.26E-02
7		7.40E-01	-1.04E-01	-3.71E-01	1.01E-01	4.76E-01	2.16E-01	3.29E-01	-3.60E-01	-4.34E-01	-6.54E-02	-2.66E-01
8		-2.33E-01	-4.11E-01	1.42E-01	3.45E-01	-6.39E-01	-5.49E-01	8.98E-01	-8.55E-02	-2.66E-01	4.48E-01	7.02E-01
9		9.31E-03	-4.60E-01	2.67E-01	7.43E-02	5.29E-01	-3.63E-01	-1.60E+00	4.99E-02	3.14E-01	1.45E-01	-5.84E-01
10		-5.27E-01	-2.82E-01	6.87E-03	-2.62E-01	-1.07E+00	-1.47E-02	-1.97E-01	4.36E-01	9.05E-02	4.20E-02	2.81E-02
11		7.22E-01	6.20E-01	-6.18E-01	6.47E-01	-1.51E-01	-3.52E-01	2.01E-02	-5.83E-01	-3.32E-02	8.38E-02	7.03E-01
12		-1.42E-01	-1.15E-02	-3.33E-03	1.87E-03	2.34E-01	2.90E-02	5.17E-01	4.10E-01	2.76E-01	2.92E-01	-3.70E-01
13		1.08E+00	-1.34E-01	-1.23E-01	1.24E-01	3.55E-03	-4.75E-01	-8.27E-01	1.90E-01	-3.49E-01	-3.14E-01	3.48E-01
Pesos w_{ij}		23	24	25								
1		1.16E-01	-1.62E-01	-2.29E-01								
2		-8.89E-01	-6.31E-01	7.00E-01								
3		-8.57E-02	-2.99E-01	-4.65E-01								
4		3.40E-01	-5.78E-01	-5.94E-02								
5		-3.82E-01	-8.67E-01	-3.72E-01								
6		1.48E-01	-4.06E-01	6.86E-01								
7		2.05E-01	1.95E-01	3.99E-01								
8		-7.67E-02	-3.51E-01	-3.51E-01								
9		-4.13E-01	4.46E-01	1.96E-01								
10		2.46E-01	8.09E-01	-7.81E-01								
11		4.55E-01	3.21E-01	-3.03E-01								
12		-1.84E-01	9.34E-01	1.72E-02								
13		4.75E-01	-1.46E-01	5.19E-01								

Camada	4	Arquitetura	1	neurônio	x	13	inputs	RNA	de	FW	Cadeira	F3
Bias b_{ij}			1	2	3	4	5	6	7	8	9	11
1	3.30E-01	1	2.48E-01	-4.15E-01	-9.05E-02	-1.56E-01	-1.86E-01	1.08E+00	-4.43E-01	-4.35E-01	-2.38E-01	1.13E-01
		Pesos w_{ij}	12	13								
		1	-7.82E-01	1.67E-01								

[illegible]

PARÂMETROS LIVRES		RNA	FW	Cadeira	F4
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	11	neurônios			x	11	inputs		RNA	de	FW	Cadeira	F4	
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11			
1	-3.41E+00	1	3.21E+00	8.40E-01	1.90E+00	3.73E+00	-5.63E-01	-3.07E-02	1.61E-02	6.21E-03	4.81E-01	3.46E-01	1.40E-03			
2	-1.99E+01	2	-3.34E+00	-5.17E-01	1.42E+00	-1.22E+00	3.93E-02	6.64E-02	-2.60E-02	7.26E-03	-2.49E-01	4.15E-01	1.94E-03			
3	1.10E+01	3	-4.49E+00	1.23E-01	1.03E+00	-1.43E+00	1.94E-01	-5.63E-02	2.23E-02	1.86E-02	-4.56E-01	7.68E-01	4.91E-03			
4	-1.21E+01	4	-9.36E-01	7.02E-03	-2.25E+00	1.03E+00	-2.07E+00	5.98E-02	-1.50E-02	8.64E-03	9.68E-01	-1.26E+00	-7.36E-03			
5	-3.89E-01	5	-2.20E+00	-1.75E-01	3.68E+00	-4.20E+00	-1.74E+00	1.98E-02	-2.81E-02	1.07E-03	-4.33E-01	-3.63E-01	5.58E-03			
6	-4.98E+00	6	2.01E+00	-8.86E-01	3.60E+00	7.16E-01	1.82E+00	7.34E-02	-4.12E-02	1.38E-02	-9.70E-01	-3.63E-01	-5.09E-03			
7	1.11E+01	7	-1.27E+00	-5.43E-01	-1.44E+00	2.49E+00	-3.00E+00	-1.46E-02	6.91E-03	-1.07E-03	-1.97E+00	2.98E+00	-7.55E-03			
8	-1.55E-01	8	-5.84E+00	-1.27E+00	-2.39E-01	2.51E+00	-1.20E+00	3.55E-02	-1.73E-02	-1.52E-02	-6.20E-01	9.29E-01	8.20E-03			
9	2.51E+01	9	8.80E-01	-1.76E+00	1.57E-03	-4.48E+00	4.19E-01	-9.03E-03	-3.58E-02	-1.04E-02	-7.13E-01	6.33E-01	-1.23E-02			
10	-2.31E+01	10	3.61E+00	2.20E+00	3.17E+00	1.39E+00	-8.30E-01	-6.88E-02	3.28E-02	-3.07E-03	-4.07E-02	4.52E-01	4.02E-02			
11	1.83E+01	10	-1.88E+00	2.44E+00	-8.77E-01	1.37E+00	2.44E+00	-2.02E-02	3.22E-03	-3.32E-02	1.58E+00	-1.65E+00	-1.67E-02			

Camada	2	Arquitetura	25	neurônios		x	11	inputs		RNA	de	FW	Cadeira		F4
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11		
1	2.16E+00		-7.75E-01	-7.05E-01	1.06E+00	-5.02E-01	5.76E-01	-7.04E-01	-1.21E-01	6.28E-02	4.91E-01	-8.80E-03	-3.40E-01		
2	1.98E+00		-5.37E-01	1.35E+00	-1.81E+00	5.59E-01	-5.25E-01	-6.49E-02	-8.96E-01	1.02E+00	6.51E-01	-1.53E+00	2.43E-02		
3	-1.66E+00		1.17E+00	2.75E+00	6.84E-01	1.47E-01	1.99E+00	1.34E+00	-3.79E-01	-1.01E+00	1.08E+00	9.03E-01	1.22E+00		
4	1.34E+00		3.53E-02	2.42E+00	1.30E-01	-1.97E+00	-7.07E-01	-3.75E-01	1.55E+00	-7.48E-01	2.91E-01	-3.06E-01	1.06E+00		
5	8.43E-01		-6.76E-01	-3.84E-02	1.03E+00	-7.50E-01	-8.45E-02	-9.27E-01	7.00E-02	-5.85E-01	-2.18E-01	3.07E-01	-4.25E-01		
6	1.51E+00		-1.37E+00	-8.50E-01	1.39E+00	-1.51E+00	-6.87E-01	-7.30E-03	1.28E+00	-8.00E-01	-9.22E-02	4.77E-01	1.74E-01		
7	-8.09E-01		1.45E-01	-6.98E-01	-1.24E+00	-4.78E-01	-5.53E-01	2.40E-01	7.93E-03	-3.99E-02	1.00E+00	-3.86E-03	8.97E-01		
8	-1.35E+00		1.04E+00	2.32E+00	1.64E-01	6.84E-02	-1.59E+00	3.18E-01	-2.83E-01	6.25E-01	1.38E-01	-1.45E-02	-1.25E+00		
9	3.76E-02		-5.98E-01	-7.38E-01	-1.90E+00	2.01E+00	-1.09E+00	-1.76E-01	6.69E-01	3.49E-01	1.00E+00	-6.31E-01	3.73E-01		
10	-1.81E+00		-1.22E+00	1.26E-02	1.67E+00	-3.78E-01	1.13E+00	2.18E-01	1.34E+00	-2.13E-01	2.01E+00	4.89E-01	-1.21E+00		
11	-7.38E-02		-6.37E-01	1.35E-01	1.65E+00	2.60E-01	5.33E-02	-3.02E-02	-9.68E-01	5.54E-01	1.13E+00	-9.02E-01	6.66E-01		
12	-7.70E-01		-2.33E-01	2.10E+00	2.54E-01	3.08E+00	-5.27E-01	3.89E-01	1.16E-01	3.23E+00	3.98E-02	-9.75E-01	5.17E-01		

PARÂMETROS LIVRES					RNA	FW	Cadeira	F4				
13	5.33E-01	13	-5.59E-01	-2.48E-01	-9.97E-01	-5.41E-01	-4.01E-01	1.75E+00	6.56E-02	-5.64E-01	2.45E-01	-9.45E-01
14	2.85E-01	14	1.17E+00	-3.84E-01	1.08E+00	-1.77E+00	3.27E-01	-8.96E-01	-1.15E+00	-8.51E-01	1.43E+00	3.29E-01
15	-5.68E-01	15	1.34E+00	3.07E-01	2.03E+00	-9.48E-01	1.28E+00	2.99E-01	-2.43E+00	-2.29E-02	2.87E-01	3.38E-01
16	-6.27E-01	16	-6.02E-01	6.42E-02	-1.00E+00	-1.73E-01	-8.23E-01	6.76E-02	-2.95E-02	1.37E-01	4.70E-01	2.82E-01
17	-8.85E-01	17	-5.21E-01	7.50E-01	3.92E-01	8.06E-01	-3.84E+00	9.53E-01	-2.76E-01	4.93E-01	7.19E-01	-1.43E+00
18	-9.12E-01	18	1.49E-02	2.10E+00	7.27E-01	2.05E+00	2.79E-01	-6.87E-01	-4.85E-01	1.72E+00	2.25E-02	5.19E-01
19	-1.10E+00	19	-2.03E+00	-7.52E-01	-2.40E+00	-4.23E+00	-2.58E-01	-6.49E-02	-3.95E+00	-6.42E-02	1.05E+00	-2.18E-01
20	-1.70E+00	20	1.17E-01	2.36E-01	7.83E-01	1.06E+00	1.58E-02	7.91E-01	7.59E-01	-1.24E+00	-7.04E-01	7.65E-02
21	1.01E+00	21	8.35E-01	1.41E+00	1.12E+00	-1.78E+00	-3.07E-01	8.87E-01	2.82E-02	3.91E-01	-4.30E-02	2.50E-01
22	7.70E-01	22	1.05E+00	3.72E-04	2.83E-01	-5.88E-01	2.80E-01	-5.20E-01	-1.32E+00	5.68E-01	-1.16E-01	5.12E-01
23	-1.00E+00	23	-4.55E-01	9.06E-01	-4.49E-01	-1.79E+00	-5.20E-02	-1.41E+00	-1.58E+00	1.91E-01	-7.94E-01	-4.48E-01
24	-2.58E+00	24	-9.46E-01	2.03E+00	1.93E-01	1.15E+00	-3.60E-01	6.32E-01	1.96E+00	-9.52E-01	-1.00E+00	-3.21E-01
25	-1.20E+00	25	-4.39E-01	-2.69E-01	9.95E-01	-1.00E+00	9.53E-01	9.21E-01	-9.86E-01	6.40E-01	-7.74E-01	1.50E-01

Camada	3	Arquitetura	13	neurônios	x	25	4	inputs	RNA	de	FW	Cadeira	F4
Bias b_{ij}		Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11
1	1.99E+00	1	-2.02E-01	-1.62E-01	1.04E+00	-9.13E-02	1.16E-01	-4.02E-01	3.43E-01	-3.47E-01	-7.03E-01	-3.78E-01	2.19E+00
2	-8.19E-01	2	6.56E-01	-1.33E+00	1.18E+00	-5.96E-01	4.50E-01	6.45E-01	-8.51E-01	-1.23E+00	2.32E-01	-2.42E-01	5.26E-01
3	9.96E-01	3	-1.87E-01	-1.19E+00	-6.06E-01	-1.03E+00	8.30E-01	2.29E-02	-5.99E-01	9.86E-02	-3.51E-01	-1.14E-01	1.66E-01
4	-8.19E-01	4	4.96E-01	2.93E-01	-2.53E-01	1.27E+00	1.18E-01	6.14E-01	7.10E-01	1.10E+00	-1.26E+00	-3.08E-01	3.61E-01
5	8.53E-01	5	6.67E-02	6.49E-01	-4.48E-01	3.32E-01	7.22E-01	3.08E-01	2.57E-01	-1.04E+00	-4.72E-01	4.84E-01	2.15E-01
6	3.07E-01	6	-3.22E-01	1.22E+00	-1.08E+00	-5.93E-01	6.10E-02	-3.44E-01	-5.06E-01	2.44E-01	6.64E-01	6.57E-02	1.13E-01
7	-1.76E-01	7	4.36E-01	3.00E-01	-2.10E-01	6.48E-01	5.94E-02	-1.05E+00	6.69E-02	-1.45E-01	9.92E-02	8.95E-01	-3.79E-01
8	7.02E-02	8	3.16E-02	-3.39E-01	-2.14E-01	-9.27E-01	1.05E-01	6.97E-01	-7.43E-01	3.92E-01	5.25E-01	2.36E-01	7.89E-01
9	3.26E-01	9	-2.07E-01	6.91E-01	2.04E+00	-1.77E+00	-2.23E-01	1.86E-03	3.36E-01	-7.05E-01	-8.50E-01	-1.07E+00	-3.51E-01
10	9.98E-01	10	-2.87E-02	7.45E-01	-6.19E-01	4.34E-01	-8.79E-01	1.19E-01	-4.61E-01	1.43E+00	-3.54E-01	-2.14E-01	-3.50E-01
11	-1.11E+00	11	-1.81E-01	-1.04E+00	4.99E-01	1.05E+00	2.55E-02	-4.92E-01	-2.29E-01	8.30E-01	6.29E-01	-8.04E-01	1.16E+00
12	9.68E-01	12	3.76E-02	-4.73E-02	1.12E-02	7.66E-01	-6.38E-01	1.72E-02	-3.59E-01	-2.51E-01	-1.82E-01	-1.21E-01	4.15E-01
13	1.59E+00	13	5.73E-01	1.05E+00	-3.01E-01	3.71E-01	2.70E-01	-9.14E-01	-8.82E-02	-8.82E-02	5.46E-01	-8.37E-01	4.93E-01
		Pesos w_{ij}	12	13	14	15	16	17	18	19	20	21	22
1		1	-1.41E+00	9.43E-01	-1.13E-01	-8.25E-01	-5.76E-01	7.69E-02	6.40E-02	1.34E+00	4.95E-01	-5.77E-01	6.49E-01
2		2	7.03E-01	-1.52E-01	1.33E+00	-3.39E-01	-1.28E-01	-4.39E-01	-3.20E-01	3.12E-01	-9.49E-01	-1.08E+00	-4.16E-02
3		3	2.13E+00	-7.02E-01	-6.25E-01	-4.63E-01	-1.07E+00	4.75E-01	1.18E-01	4.55E-01	-1.30E-01	7.64E-01	9.91E-01

PARÂMETROS LIVRES												
		RNA		FW		Cadeira		F4				
	4	3.54E-01	-1.28E+00	-1.10E-02	-1.76E+00	-5.14E-01	6.23E-01	-4.27E-01	-3.03E-01	-2.03E-01	4.45E-01	1.40E+00
	5	7.25E-01	3.17E-01	2.96E-01	-1.26E+00	-1.27E+00	-5.06E-01	-6.37E-01	2.82E-01	1.30E+00	5.66E-01	4.01E-01
	6	-2.88E-01	-4.46E-01	-2.95E-01	8.05E-01	-6.15E-01	-4.62E-01	1.09E+00	-6.33E-01	-2.23E+00	3.63E-01	-2.06E-01
	7	1.11E+00	-9.21E-01	-4.18E-01	3.99E-01	-1.56E+00	1.76E-01	-1.68E-01	6.57E-01	-5.50E-01	-5.77E-01	1.08E+00
	8	1.41E+00	-1.38E-01	5.93E-01	2.42E-01	5.86E-01	-4.67E-01	3.29E-01	1.08E+00	6.21E-01	-1.34E+00	-2.90E-01
	9	-1.70E+00	3.11E-01	-2.18E-01	-5.45E-01	-7.50E-02	3.03E+00	1.02E+00	-2.45E-01	5.40E-01	-1.85E+00	3.57E-01
	10	-3.80E-01	1.79E-01	-1.82E-01	-4.21E-01	-1.42E-01	5.74E-02	-4.84E-02	-4.28E-01	4.56E-01	6.25E-01	1.32E+00
	11	6.24E-01	-7.56E-01	8.27E-02	9.25E-02	4.68E-01	-6.06E-01	-1.11E-01	7.94E-01	1.13E-02	4.55E-01	1.54E-01
	12	4.73E-01	4.91E-01	-4.02E-02	3.83E-02	6.97E-02	-6.28E-02	1.01E-01	1.71E-01	-5.19E-02	-4.35E-01	3.22E-02
	13	8.60E-01	1.11E+00	1.84E-01	9.20E-01	1.59E-01	-7.37E-01	6.08E-01	4.18E-02	4.16E-01	3.40E-01	-6.07E-02
Pesos w_{ij}		23	24	25								
	1	-2.43E+00	8.27E-01	-2.68E+00								
	2	-3.83E-02	1.30E+00	-7.23E-01								
	3	4.53E-01	7.35E-01	-6.01E-01								
	4	-1.32E+00	-6.87E-01	3.42E-02								
	5	-5.54E-01	-9.70E-01	-4.64E-01								
	6	-4.28E-01	-1.94E-01	6.49E-01								
	7	-3.23E-01	-1.21E+00	-9.89E-02								
	8	1.08E+00	5.01E-02	8.20E-01								
	9	5.59E-01	-1.87E-01	1.10E+00								
	10	-7.80E-01	-5.01E-01	-8.98E-02								
	11	3.70E-01	-9.02E-01	6.75E-01								
	12	4.45E-01	-6.20E-01	-6.05E-01								
	13	1.18E+00	-2.12E+00	-4.71E-01								

Camada	4	Arquitetura	1	neurônio	x	13	inputs	RNA	de	FW	Cadeira	F4
Bias b_{ij}			1	2	3	4	5	6	7	8	9	10
1	5.30E-01	Saída	1.70E-01	8.85E-02	1.20E-01	-1.20E-01	2.71E-01	-1.76E-01	2.21E-01	1.32E-01	3.22E-02	3.42E-01
		Pesos w_{ij}	12	13								
		1	-6.38E-01	1.41E-01								

PARÂMETROS LIVRES		RNA	FW	Cadeira	F5
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	neurônios				x	11	inputs		RNA	de	FW	Cadeira	F5
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11		
1	-2.54E+01	1	1.04E+00	1.61E+00	-3.24E+00	-4.79E-01	-6.06E-01	1.11E-01	-4.40E-02	-9.34E-03	5.01E-01	-3.08E-01	-4.76E-03		
2	1.84E+01	2	-1.66E+00	-8.68E-01	-3.13E+00	-8.45E-01	-2.72E+00	1.75E-01	-3.10E-02	8.33E-03	5.62E-01	7.71E-01	-9.01E-02		
3	-1.94E+01	3	-4.36E+00	4.97E-01	-1.21E+00	6.50E-01	-2.57E+00	3.73E-02	-6.32E-03	-4.56E-03	-1.33E+00	1.70E+00	8.28E-03		
4	-8.79E+00	4	3.47E+00	-7.76E-01	-1.47E+00	3.46E+00	-3.03E+00	-2.88E-02	1.48E-02	4.78E-03	-4.35E-01	3.08E-01	1.82E-02		
5	7.81E+00	5	5.97E-01	2.22E+00	-2.20E+00	3.31E+00	-9.01E-02	-1.19E-02	4.03E-03	1.88E-02	1.58E+00	-2.17E+00	-5.96E-03		
6	1.47E+01	6	3.56E+00	1.48E-01	1.31E+00	4.23E-01	2.51E+00	-2.23E-02	1.43E-03	-4.40E-03	6.46E-01	-6.84E-01	-9.39E-03		
7	1.51E+01	7	3.93E-01	4.40E-01	-2.69E-01	-4.16E+00	-1.43E-01	-3.59E-02	7.69E-03	-8.24E-04	8.28E-01	-1.75E-01	-6.74E-03		
8	3.55E+00	8	6.19E+00	-6.16E-01	3.31E+00	-2.89E+00	9.14E-01	-1.44E-03	-9.67E-05	-4.70E-03	-1.60E-01	1.93E-01	-4.01E-03		
9	-1.75E+01	9	-1.32E+00	-1.21E+00	3.04E+00	-2.17E+00	1.69E+00	8.01E-02	-2.81E-02	-1.28E-02	1.47E+00	-2.33E+00	-4.15E-03		
10	-4.24E+00	10	6.66E-01	-4.69E-01	1.66E+00	2.89E+00	-3.07E+00	-5.20E-02	1.98E-02	-8.34E-04	-1.39E+00	1.71E+00	2.16E-02		
11	-9.50E+00	10	-9.40E-01	7.07E-01	-3.77E+00	-1.73E+00	-3.57E+00	1.14E-02	-1.87E-02	2.13E-02	-1.57E-01	1.90E-01	1.15E-02		

Camada	2	Arquitetura	neurônios			x	11		inputs		RNA	de	FW	Cadeira			F5	
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	3	4	4	5	6	7	8	9	10	11			
1	-2.46E+00	1	8.01E-01	-1.83E-01	5.58E-04	1.88E-01	9.96E-01	9.71E-01	-1.02E+00	-8.57E-01	2.11E+00	-3.62E-01	-1.28E+00					
2	1.85E+00	2	-8.78E-01	-5.37E-01	-1.18E+00	8.35E-01	1.06E+00	3.61E-01	-1.23E+00	-1.91E+00	-5.82E-01	4.32E-01						
3	1.64E+00	3	-2.14E-01	-6.06E-01	5.92E-02	6.00E-01	6.29E-01	1.99E-01	1.67E+00	8.36E-01	6.02E-01	-2.71E-01						
4	-1.42E+00	4	-1.14E-01	-4.86E-01	-3.35E-01	-3.45E-01	-6.03E-01	-9.00E-01	9.78E-01	8.95E-01	6.77E-01	-7.34E-02	3.65E-01					
5	1.31E+00	5	-8.31E-01	-7.52E-01	-3.97E-01	-5.12E-01	-4.69E-01	1.50E-01	-6.26E-01	4.26E-01	-6.27E-02	-5.12E-01						
6	-7.71E-01	6	7.50E-02	-7.39E-01	-1.36E-01	-1.33E+00	-6.51E-02	7.00E-02	-4.64E-01	1.19E+00	-7.54E-01	-8.02E-01						
7	1.65E+00	7	-1.02E+00	-7.70E-01	7.80E-01	3.74E-01	5.94E-01	-6.97E-01	-1.16E+00	-4.29E-01	1.00E+00	-6.14E-01						
8	-2.90E-01	8	6.13E-01	6.34E-01	1.05E-01	-6.38E-01	-8.67E-01	-9.35E-01	-7.17E-01	7.27E-01	-1.75E-01	-9.04E-01						
9	4.52E-01	9	-4.90E-01	-4.31E-01	6.45E-01	-3.73E-01	9.02E-01	1.66E+00	-2.31E-02	1.74E+00	-2.06E+00	-2.08E+00						
10	-5.17E-01	10	1.48E+00	-3.93E-01	-5.13E-01	3.18E-01	1.60E+00	2.84E-02	6.47E-01	1.45E-01	7.78E-01	-4.81E-01	-1.19E+00					
11	3.54E-01	11	-6.46E-01	-1.30E-01	1.28E+00	-1.86E+00	5.36E-01	1.29E+00	3.70E-01	-8.91E-01	1.31E-01	-1.90E-01	-1.23E+00					
12	-4.00E-02	12	-5.14E-01	3.50E-01	-5.03E-02	1.25E-01	1.30E+00	-1.53E-01	3.85E-01	-5.34E-01	1.44E-01	1.37E+00	-1.65E+00					

PARÂMETROS LIVRES				RNA	FW	Cadeira	F5						
13	1.70E-01	13	-7.83E-01	7.31E-01	-8.51E-01	-6.29E-01	-1.13E-01	-6.42E-01	2.16E-01	2.12E+00	-2.61E-01	-1.11E-01	3.54E-01
14	5.89E-01	14	2.86E-01	-2.76E-01	-1.18E+00	1.22E+00	-5.70E-01	4.78E-01	-3.90E-01	8.71E-01	-4.97E-01	5.93E-01	1.42E+00
15	3.18E-01	15	-1.19E+00	-5.75E-01	-2.32E-01	1.01E+00	-4.07E-02	3.65E-01	-1.71E+00	-1.15E-01	-5.07E-01	1.09E+00	-9.86E-01
16	7.08E-01	16	3.48E-01	-2.34E-01	-6.54E-01	-1.64E+00	7.91E-01	-9.54E-01	-1.17E+00	1.12E+00	8.64E-01	1.09E+00	-1.58E-01
17	4.28E-02	17	3.02E-01	4.62E-01	1.53E+00	5.68E-01	1.95E-01	-1.11E+00	2.69E-01	1.13E+00	-1.18E+00	6.44E-01	-1.91E-01
18	-2.36E-01	18	-4.72E-01	-4.66E-01	3.54E-01	-1.55E+00	-2.38E-01	6.83E-01	6.91E-01	-7.95E-01	-8.10E-01	-9.91E-02	-2.09E-01
19	9.61E-01	19	1.25E+00	2.59E-01	1.14E-01	-8.99E-01	4.45E-01	-7.45E-01	1.56E-01	-4.38E-01	-5.33E-01	-5.05E-01	-1.88E-01
20	1.45E+00	20	2.63E-01	2.80E-01	7.55E-01	-1.17E+00	-2.60E-01	1.12E-01	2.35E+00	2.11E-01	-5.22E-01	7.00E-01	3.65E-01
21	-1.21E+00	21	-8.91E-01	-1.85E-01	-5.00E-01	-1.55E-01	1.24E-01	1.10E+00	-2.84E-01	-1.45E-01	4.77E-01	-2.30E-01	8.54E-01
22	1.39E+00	22	6.81E-01	4.42E-01	9.00E-01	-5.19E-02	-2.07E-01	-3.08E-01	4.71E-01	7.88E-01	-7.36E-01	7.63E-01	2.93E-01
23	1.96E+00	23	6.99E-01	-2.83E-01	-5.31E-01	1.07E+00	1.61E-01	-3.32E-01	1.59E-02	-5.10E-01	6.06E-02	6.90E-02	-1.16E+00
24	1.66E+00	24	7.81E-01	-8.23E-01	8.10E-01	-4.89E-01	-3.33E-01	-8.90E-01	-1.29E-01	-1.20E-01	-3.69E-01	5.87E-01	-8.69E-01
25	-1.41E+00	25	7.36E-03	5.76E-01	3.48E-01	-9.41E-01	4.72E-01	-9.33E-01	-9.13E-01	1.58E+00	-1.43E+00	-3.26E-01	-1.10E-01

Camada	3	Arquitetura	13	neurônios		x	25	inputs		RNA	de	FW	Cadeira		F5
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11		
1	-1.62E+00	1	3.54E-01	6.91E-01	-8.98E-01	3.22E-01	5.65E-01	-1.24E-01	-3.93E-01	-8.22E-01	-5.04E-01	-3.80E-01	4.22E-01		
2	-1.18E+00	2	7.33E-01	2.84E-01	4.93E-01	3.29E-01	4.19E-02	-4.15E-01	-4.27E-01	1.68E-01	3.95E-01	1.90E+00	-5.53E-01		
3	-1.04E+00	3	1.46E+00	2.72E-01	-3.96E-01	-1.32E-01	2.24E-01	7.64E-02	-4.83E-01	8.38E-03	7.75E-01	-2.01E-02	-6.53E-01		
4	3.74E-01	4	1.30E+00	-5.10E-01	-1.30E+00	4.13E-01	4.33E-01	-5.58E-01	3.40E-01	2.37E-02	1.34E+00	6.68E-02	-5.43E-01		
5	4.03E-01	5	5.17E-02	4.49E-01	2.54E-01	-3.38E-01	-8.70E-02	2.59E-02	-4.43E-01	4.18E-01	2.26E-01	-3.64E-02	3.61E-01		
6	1.54E-01	6	-8.69E-01	4.34E-02	-3.68E-01	-2.28E-01	3.16E-01	3.56E-01	4.78E-01	5.77E-02	-2.98E-01	-1.17E-01	3.92E-03		
7	1.01E-02	7	-2.42E-01	3.45E-01	1.39E-01	-2.86E-01	2.61E-01	4.79E-02	-5.14E-01	9.66E-02	-7.70E-01	2.29E-01	1.10E+00		
8	-2.92E-01	8	4.24E-01	9.64E-06	-1.11E-01	7.39E-02	-1.03E+00	-1.84E-01	-2.32E-01	7.66E-02	3.84E-01	-1.13E-01	4.20E-01		
9	4.38E-01	9	2.00E-01	-2.10E-01	-5.30E-01	6.80E-01	3.01E-01	3.72E-01	7.00E-01	-8.53E-01	1.31E-01	5.32E-02	5.29E-01		
10	9.13E-01	10	1.18E-01	-7.87E-01	-8.74E-01	-1.93E-01	3.79E-02	8.10E-01	8.40E-01	-3.95E-02	1.73E-01	5.25E-01	-2.64E-01		
11	-8.82E-01	11	-2.73E-01	2.56E-01	-6.13E-01	1.43E-01	1.12E+00	4.66E-01	-1.84E-01	-4.45E-01	-4.82E-01	-5.26E-01	6.05E-01		
12	1.30E+00	12	1.32E-01	-6.70E-01	-8.67E-01	1.70E-01	-5.08E-01	-4.17E-01	1.24E+00	6.58E-01	1.06E+00	5.13E-01	-7.95E-02		
13	-1.60E+00	13	-3.39E-01	3.34E-01	-7.88E-02	1.58E-01	6.18E-01	-1.20E-01	2.29E-01	4.68E-02	-3.30E-01	2.66E-01	-8.93E-01		
		Pesos w_{ij}	12	13	14	15	16	17	18	19	20	21	22		
		1	4.98E-01	-4.88E-01	-1.86E-01	3.41E-01	4.43E-01	-1.30E-01	4.64E-01	5.63E-02	-7.87E-02	-9.50E-02	3.90E-01		
		2	6.54E-01	-2.91E-01	-4.84E-01	-7.34E-01	1.27E-01	1.44E-01	-6.24E-02	2.74E-02	-2.12E-01	-2.92E-01	3.59E-01		
		3	-4.17E-02	-2.35E-01	7.58E-01	-4.25E-01	2.32E-01	4.92E-01	1.02E+00	4.05E-01	4.29E-01	-6.01E-02	3.96E-01		

PARÂMETROS LIVRES		RNA	FW	Cadeira	F6
-------------------	--	-----	----	---------	----

Convenção	k =	camada	j =	neurônio	i =	conexão
-----------	-----	--------	-----	----------	-----	---------

Camada	1	Arquitetura	11	neurônios		x	11	inputs		RNA	de	FW	Cadeira	F6
Bias b_{ij}	Entrada	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11	
1	-1.31E+01	1	-7.66E-01	1.41E+00	-2.77E+00	4.17E+00	-5.06E-01	-1.60E-02	1.00E-02	1.74E-02	7.86E-01	-5.90E-02	1.51E-02	
2	1.43E+01	2	-2.83E+00	-4.08E-02	-1.95E+00	3.55E+00	1.79E+00	-1.36E-01	6.45E-02	-1.15E-02	4.39E-01	-3.32E-01	3.20E-02	
3	-8.28E+00	3	3.13E+00	4.96E-01	2.80E+00	-2.58E+00	-2.71E+00	2.73E-03	4.34E-03	-7.92E-04	-5.40E-01	1.10E+00	3.41E-03	
4	6.74E-01	4	-3.54E-01	-7.37E-01	3.27E-01	-3.06E+00	1.11E+00	1.21E-02	-1.00E-02	6.24E-03	-7.98E-02	9.78E-01	-3.50E-03	
5	1.71E+01	5	1.68E+00	5.78E-01	-3.33E+00	1.43E+00	5.51E-01	-1.50E-02	3.36E-03	-6.42E-03	-1.89E+00	1.51E+00	-1.09E-02	
6	2.24E+00	6	1.35E+00	-1.39E+00	2.57E+00	3.13E-01	-3.79E-01	-4.64E-03	3.40E-03	2.95E-03	6.87E-01	-6.79E-01	-2.51E-03	
7	-5.09E+00	7	2.69E+00	7.23E-01	-5.00E+00	-3.35E+00	1.63E+00	4.57E-02	-2.23E-02	5.69E-03	5.00E-02	-5.73E-01	-5.14E-03	
8	1.07E+00	8	-2.06E+00	-1.71E+00	1.65E+00	-2.22E+00	-2.29E+00	3.53E-03	-1.03E-04	-2.65E-03	1.26E+00	-1.21E-01	-6.60E-03	
9	7.53E+00	9	-5.13E+00	7.62E-02	1.08E+00	-1.93E+00	7.28E-01	5.52E-04	5.01E-04	3.03E-03	-1.02E+00	1.20E+00	-9.17E-03	
10	1.66E+01	10	-6.10E-01	3.70E+00	3.31E+00	9.34E-01	-3.50E-01	-4.14E-02	1.45E-02	-3.43E-03	-7.13E-01	8.97E-01	-6.42E-03	
11	-1.45E+01	10	4.13E+00	-5.76E-01	-1.54E+00	3.52E+00	8.72E-01	-2.98E-03	-1.89E-03	4.49E-03	-2.20E-01	6.08E-01	1.75E-02	

Camada	2	Arquitetura	neurônios			x	11			inputs	RNA	de	FW	Cadeira	F6
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11		
1	1.95E+00	1	1.65E-01	1.68E+00	-1.75E+00	8.77E-02	-1.33E+00	-2.25E-01	-1.24E+00	1.21E+00	5.87E-01	-4.36E-01	-5.51E-01		
2	1.25E+00	2	8.55E-01	3.82E-01	5.89E-01	-1.42E+00	-9.44E-01	1.63E-01	1.50E+00	3.38E-01	1.52E+00	-8.72E-02	-5.81E-01		
3	-1.36E+00	3	-2.12E-01	1.20E+00	7.28E-02	-1.13E+00	-8.74E-02	-4.10E-01	-1.39E+00	-9.40E-01	8.07E-02	-2.46E-01	1.40E+00		
4	-1.41E+00	4	7.79E-01	-4.28E-01	1.66E-01	6.11E-01	-3.05E-01	1.42E+00	-2.09E+00	1.85E+00	1.22E+00	-1.66E-02	1.91E+00		
5	-1.27E+00	5	5.28E-01	-1.15E-01	-9.61E-01	-8.59E-02	1.14E+00	1.09E+00	8.17E-01	1.03E+00	9.56E-01	-1.23E-02	5.55E-01		
6	-4.46E-01	6	1.08E+00	3.66E-01	-1.90E-01	5.50E-01	1.73E+00	-1.18E-01	-1.34E+00	8.45E-01	-1.07E-02	5.01E-01	4.19E-02		
7	-7.84E-01	7	1.64E+00	-3.11E-01	-6.38E-01	1.10E+00	1.09E+00	2.43E-01	-5.17E-01	1.46E+00	-9.12E-01	2.38E-01	-1.70E+00		
8	-6.33E-01	8	-1.12E+00	6.91E-01	1.16E+00	9.89E-01	-7.04E-01	6.90E-02	4.98E-01	3.48E+00	-3.27E-01	1.53E+00	1.65E+00		
9	3.17E-01	9	-4.00E-01	-1.04E+00	4.17E-01	1.04E+00	8.31E-01	-4.89E-01	1.37E+00	-2.45E-02	1.62E-01	-9.41E-01	-2.45E-01		
10	9.64E-02	10	1.19E+00	-1.11E-01	1.86E+00	-1.21E+00	8.61E-02	1.95E-02	6.68E-01	-3.28E-01	-9.16E-01	-4.51E-01	-7.95E-01		
11	-1.41E-02	11	-6.14E-01	2.51E-01	5.67E-01	1.72E-01	-1.17E+00	1.11E+00	1.48E-01	7.19E-01	1.13E+00	1.06E+00	2.06E+00		
12	-5.92E-02	12	-2.10E-01	7.21E-01	-1.39E+00	-3.47E-01	-1.40E+00	5.92E-01	9.68E-01	-3.62E-01	5.28E-01	1.51E-01	6.34E-01		

PARÂMETROS LIVRES						RNA		FW		Cadeira		F6	
13	1.55E-01	13	8.38E-02	3.50E-01	-1.54E+00	1.85E-01	-1.40E-01	-3.98E-01	-1.49E+00	6.31E-01	4.23E-02	3.96E-01	-5.57E-01
14	2.14E-01	14	2.60E-01	-2.55E-01	1.42E+00	-1.21E-01	4.08E-01	1.88E-01	-1.41E+00	4.75E-02	-1.42E+00	4.60E-01	-3.51E-01
15	1.02E+00	15	1.14E-03	4.59E-01	-5.69E-01	4.63E-02	-2.20E+00	8.33E-01	-1.84E+00	-1.26E+00	3.57E-02	1.32E+00	-1.19E+00
16	5.31E-01	16	-9.28E-02	2.19E-01	-2.40E+00	5.18E-01	-1.67E+00	-5.19E-01	1.86E-01	-2.56E-01	1.29E+00	-1.56E-01	-9.58E-01
17	4.51E-01	17	8.67E-01	-8.64E-01	4.98E-01	8.26E-01	-1.48E+00	5.97E-01	-4.89E-01	-8.61E-01	5.63E-02	2.38E-01	-1.31E+00
18	7.85E-01	18	3.01E-01	-4.21E-01	1.18E-01	1.15E-01	-1.01E+00	-1.85E-01	5.62E-01	4.44E-01	-1.12E+00	-3.79E-01	-1.29E+00
19	-7.38E-01	19	1.21E+00	-1.97E+00	5.79E-01	3.84E-01	1.42E+00	7.69E-01	1.20E+00	-4.66E-01	-9.26E-01	1.42E+00	3.53E-01
20	-1.69E+00	20	-1.08E-01	6.97E-01	-4.07E-01	-1.59E+00	-6.70E-01	-2.69E-01	1.15E+00	-2.72E-01	8.54E-01	2.67E+00	5.23E-01
21	-5.21E-01	21	-8.59E-01	5.13E-01	-3.75E-01	7.37E-01	3.20E-01	-1.15E+00	-3.03E-01	-4.81E-02	4.27E-01	-3.52E-01	-1.49E-01
22	-1.74E+00	22	-1.00E+00	2.39E-01	2.04E-01	-9.15E-01	3.36E-01	-1.43E-01	2.94E-01	3.15E-01	-1.67E-01	-5.83E-01	-6.47E-01
23	1.84E+00	23	1.08E-01	1.38E-01	2.26E-01	2.38E+00	3.00E-02	1.96E+00	1.74E+00	7.47E-01	-8.70E-01	1.64E+00	-3.20E-03
24	1.86E+00	24	1.63E-01	7.95E-01	9.36E-01	4.90E-01	-1.05E+00	-5.54E-01	6.14E-02	1.35E+00	6.32E-01	7.33E-01	2.05E-02
25	-2.17E+00	25	7.32E-02	4.40E-01	-1.26E+00	1.65E-01	5.34E-01	7.56E-01	-2.35E-01	9.74E-01	-1.99E+00	2.57E-01	1.21E+00


Camada	3	Arquitetura	13	neurônios	x	25	inputs	RNA	de	FW	Cadeira	F6	
Bias b_{ij}	Intermediária	Pesos w_{ij}	1	2	3	4	5	6	7	8	9	10	11
1	1.24E+00	1	-4.64E-01	-4.49E-01	2.11E-01	1.19E+00	4.59E-02	1.72E-01	-4.23E-01	-5.28E-02	6.90E-01	-8.35E-01	-3.60E-01
2	1.50E+00	2	-6.16E-01	4.74E-01	1.80E-01	1.60E+00	1.88E-01	9.09E-01	-5.06E-01	4.89E-01	-3.02E-01	1.75E-01	-2.67E-01
3	-1.20E+00	3	7.81E-01	1.14E+00	-5.26E-01	-4.24E-01	9.07E-02	-6.55E-01	1.89E-01	7.62E-01	-8.72E-01	1.10E-01	-7.95E-01
4	1.11E+00	4	-6.93E-01	-8.19E-01	2.74E-01	5.11E-01	-6.80E-02	1.65E-02	4.58E-02	-8.68E-01	3.77E-01	2.30E-01	9.31E-01
5	7.12E-01	5	-5.26E-01	1.52E-01	-4.33E-01	-4.33E-01	-1.22E+00	-9.53E-01	3.58E-01	3.44E-01	1.01E+00	-9.47E-01	2.72E-02
6	2.14E-01	6	-2.77E-01	4.99E-02	-1.24E-01	-5.44E-01	-1.20E+00	2.81E-01	-7.50E-01	-3.37E-01	-5.90E-01	-4.03E-01	-6.78E-03
7	-5.19E-01	7	-6.73E-01	6.93E-01	2.66E-01	-9.75E-03	4.78E-01	-6.64E-01	4.73E-01	-5.07E-01	-7.45E-01	-6.74E-01	-3.70E-01
8	3.93E-01	8	-2.38E-01	-6.19E-01	-3.19E-01	3.44E-01	-9.20E-01	4.70E-01	-5.94E-01	-8.52E-01	-1.34E+00	-7.44E-01	3.45E-01
9	4.75E-04	9	-1.33E-01	-3.69E-01	-4.95E-01	-2.19E-01	3.51E-01	-8.80E-01	5.82E-03	-1.37E+00	5.08E-01	5.25E-01	1.25E+00
10	5.92E-01	10	-1.19E-01	4.28E-01	-9.79E-01	-4.68E-01	1.82E-01	-3.33E-01	-1.04E+00	-7.38E-02	-4.16E-01	1.34E-01	-8.68E-02
11	1.17E+00	11	1.44E-01	-2.85E-01	1.81E-01	1.21E-01	-2.08E-01	-1.70E-02	1.01E+00	6.72E-01	6.67E-02	2.62E-01	-3.50E-01
12	-1.46E+00	12	-1.08E+00	-8.34E-01	-2.03E-01	5.04E-01	4.03E-01	-4.78E-01	6.48E-01	9.15E-01	-5.48E-01	-3.60E-01	-1.00E+00
13	-1.13E+00	13	2.85E-01	4.21E-01	-1.34E-01	-4.39E-01	-1.31E+00	-8.77E-01	2.20E-01	-7.10E-01	-8.92E-01	-2.05E-01	-2.54E-01
		Pesos w_{ij}	12	13	14	15	16	17	18	19	20	21	22
		1	-1.60E+00	1.53E-01	-2.03E-01	6.84E-02	9.95E-01	-1.31E+00	1.16E-01	-1.59E-02	-3.72E-01	-1.51E+00	3.55E-01
		2	8.95E-01	-1.84E-01	3.21E-01	5.99E-01	1.90E-01	-8.61E-01	4.50E-01	-5.80E-01	3.55E-01	-2.16E-01	-2.02E-01
		3	1.29E-01	-4.45E-01	5.86E-01	7.36E-01	1.06E-01	-1.65E+00	-7.04E-02	-1.53E-01	6.84E-01	2.78E-01	5.55E-01

PARÂMETROS LIVRES

	RNA	FW	Cadeira	F6	
4	-6.17E-01	-2.15E-01	-1.32E+00	-5.07E-01	-3.82E-01
5	-6.07E-01	-6.65E-01	6.92E-01	-3.96E-01	-1.67E+00
6	-3.79E-01	1.27E-01	-1.24E+00	-3.31E-01	1.68E-01
7	-4.63E-01	4.40E-01	-6.19E-01	-1.07E+00	-2.01E-01
8	-3.17E-01	-6.60E-01	7.23E-01	-8.84E-01	1.66E+00
9	-5.94E-01	-2.07E-01	3.20E-01	7.03E-01	-9.23E-01
10	3.41E-01	3.35E-01	-2.43E-01	3.33E-01	5.49E-01
11	3.74E-02	8.17E-02	3.17E-01	2.12E-01	-1.12E-01
12	2.45E-02	5.48E-01	-6.54E-01	-5.91E-01	-8.36E-02
13	-1.90E-01	4.23E-01	-2.98E-01	-9.42E-02	1.84E-01
Pesos w_{ij}	23	24	25		
1	-5.75E-01	-1.81E-01	-4.18E-01		
2	1.12E+00	-6.63E-02	-8.39E-02		
3	7.56E-01	3.95E-01	1.53E-01		
4	-1.38E+00	5.85E-01	-1.02E-04		
5	2.74E-02	-1.49E-01	-1.16E-01		
6	-5.35E-01	4.26E-01	1.84E-03		
7	-5.68E-01	-7.30E-01	1.50E-01		
8	-7.74E-01	4.56E-01	5.13E-01		
9	-1.77E-01	-8.25E-01	-8.66E-01		
10	-8.52E-01	3.96E-01	1.04E+00		
11	9.48E-01	-6.54E-01	1.00E-01		
12	1.47E+00	2.13E-01	-1.11E+00		
13	-2.01E-01	1.94E-01	-6.58E-01		

Camada	4	Arquitetura	1	neurônio	x	13	inputs	RNA	de	FW	Cadeira	F6
Bias b_{ij}	Saída		1	2	3	4	5	6	7	8	9	10
1	5.76E-01		-2.79E-01	-1.43E+00	-5.63E-01	-6.38E-01	-2.63E-01	-8.23E-01	-8.39E-01	-2.55E-01	2.25E-01	4.08E-01
		Pesos w_{ij}	12	13								
		1	3.31E-01	7.98E-01								

APÊNDICE J – Referência do software utilizado no desenvolvimento das RNA's



Nota: COSIPA é uma empresa do Sistema USIMINAS de siderurgia.