

ADEMAR DE AZEVEDO CARDOSO

**REDES NEURAIIS ARTIFICIAIS NA
AVALIAÇÃO DE CONCENTRAÇÃO DE TENSÕES
EM JUNTAS TUBULARES SOLDADAS**

Tese apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título
de Doutor em Engenharia.

São Paulo
1999

ADEMAR DE AZEVEDO CARDOSO

**REDES NEURAIIS ARTIFICIAIS NA
AVALIAÇÃO DE CONCENTRAÇÃO DE TENSÕES
EM JUNTAS TUBULARES SOLDADAS**

Tese apresentada à Escola
Politécnica da Universidade de São
Paulo para obtenção do título
de Doutor em Engenharia.

Orientador:
Prof. Dr. Oscar Brito Augusto.

São Paulo
1999

Cardoso, Ademar de Azevedo

Redes Neurais Artificiais na Avaliação de Concentração
De Tensões Em Juntas Tubulares Soldadas. São Paulo, 1999.
99p.

Tese(Doutorado)- Escola Politécnica da Universidade de
São Paulo. Departamento de Engenharia Naval.

1. Juntas Tubulares 2. Concentração de Tensões 3. Redes
Neurais Artificiais. I. Universidade de São Paulo. Escola
Politécnica. Departamento de Engenharia Naval II. t

À Irene,
pela paciência.

AGRADECIMENTOS

Ao Prof. Dr. Oscar Brito Augusto pela orientação, apoio e incentivo.

Ao Prof. Dr. Carlos Alberto Nunes Dias pelas sugestões e colaboração.

Ao amigo Antonio Carlos Silva de Carvalho pela revisão do texto.

Às seguintes entidades:

Departamento de Engenharia Naval e Oceânica da EPUSP.

CAPES e CNPq pelo apoio financeiro.

MOTIVAÇÃO

Meu contato com processos de otimização começou no trabalho de mestrado, no qual foi desenvolvido um sistema especialista para síntese da estrutura transversal de embarcações, de sorte que o peso da estrutura seja minimizado.

Terminado o mestrado, cursei algumas disciplinas na área de inteligência artificial, buscando um melhor entendimento sobre sistemas especialistas e outras ramificações abrangidas por aquela área. Foi assim que comecei a estudar um tema chamado redes neurais artificiais (RNA). Depois de estudar o assunto por um tempo fiquei muito interessado no enfoque das RNA e na possibilidade de utilizá-las em problemas das mais variadas áreas do conhecimento. Nessa época, em uma das muitas conversas com o meu orientador, ele levantou as dificuldades do prof. Nunes na condução de sua pesquisa, centralizada no cálculo do fator de concentração de tensões (FCT) em juntas soldadas de plataformas. Esse cálculo exigia, entre outras etapas, o estabelecimento de uma expressão matemática parametrizada a ser ajustada através de um conjunto de dados.

Daquela conversa — e outras posteriores — com o prof. Oscar e o prof. Nunes decidimos investir em um novo caminho para a estimativa do FCT em juntas soldadas de plataformas e assim o fizemos nos últimos dois anos.

O trabalho ora apresentado foi realizado porque o autor teve satisfação em fazê-lo. Espera-se agora que tenha utilidade.

SUMÁRIO

Lista de Figuras.....	i
Lista de Tabelas.....	iv
Nomenclatura.....	v
Definições	vii
Resumo	viii
<i>Abstract</i>	ix
1. INTRODUÇÃO.....	1
1.1 Considerações Iniciais	1
1.2 Equações Paramétricas para o Cálculo do FCT.....	3
1.3 Justificativas e Objetivos do Trabalho	6
1.4 Apresentação do Trabalho	9
2. REVISÃO DA LITERATURA	11
2.1 Evolução das Equações Paramétricas para Cálculo do FCT	15
3. JUNTAS TUBULARES SOLDADAS	19
3.1 Introdução.....	19
3.2 Características Geométricas de Juntas Tubulares Soldadas.....	19
3.3 Condições de Contorno e Carregamentos em Juntas Tubulares Soldadas	22
3.4 Tensões em Juntas Tubulares Soldadas	24
3.5 Definição de Tensão Crítica (<i>hot spot stress</i>)	27
3.6 Conjunto de Dados para Treinamento do <i>Modelo RNA</i>	29

4. REDES NEURAIAS ARTIFICIAIS.....	32
4.1 Breve Histórico	32
4.2 Treinamento de Redes Neurais Artificiais.....	36
4.3 Arquitetura de Redes Neurais Artificiais	44
4.4 Aspectos Importantes do Algoritmo de Retro-Propagação.....	47
4.4.1 Escalonamento dos Valores de Entrada e de Saída.....	47
4.4.2 Taxa de Aprendizado (h) e Constante de Momento (a).....	48
4.4.3 Conjunto de Treinamento, Conjunto de Teste e Generalização.....	50
4.4.4 Programa de Computador NEUROWELD	52
5. DESENVOLVIMENTO DO <i>MODELO RNA</i>	54
5.1 Introdução.....	54
5.2 Treinamento com um Conjunto de Treinamento Menor	54
5.3 Variação nos Limites de Escalonamento das Variáveis de Entrada.	58
5.4 Modificação na Função Resíduo.	60
5.5 Treinamento do <i>Modelo RNA</i>	64
6. RESULTADOS E DISCUSSÕES	65
6.1 Introdução.....	65
6.2 Comparação de Resultados Obtidos: RNA x MEF.....	65
6.3 Comparação de Resultados Obtidos: RNA x Equações Paramétricas	82
6.4 Comparação de Resultados Obtidos: RNA x Ensaios em Bancos de Prova.	93
7. CONCLUSÕES E PERSPECTIVAS	97

REFERÊNCIAS BIBLIOGRÁFICAS

BIBLIOGRAFIA RECOMENDADA

APÊNDICE A

APÊNDICE B

APÊNDICE C

APÊNDICE D

LISTA DE FIGURAS

Figura 1.1 – Dimensões e Adimensionais Característicos da Junta Tubular.	4
Figura 2.1 – Exemplo de Falha em Juntas Soldadas.....	13
Figura 2.2 – Modelo de Scordelis e Bouwkamp: Deslocamento Constante ao Longo da Junta.	14
Figura 2.3 – Localização da Coroa e da Sela na Junta Soldada.	17
Figura 3.1 – Nomenclatura dos Principais Tipos de Juntas Tubulares Soldadas.	20
Figura 3.2 – Representação Esquemática de uma Junta Y Típica.....	21
Figura 3.3 – Parâmetros Adimensionais da Geometria do Cordão de Solda.	22
Figura 3.4 – Casos de Carregamentos Analisados com o Modelo RNA.	24
Figura 3.5 – Exemplo de Plataforma Fixa.	26
Figura 3.6 – Deformações no Primário sob Ação de Carga Axial no Secundário.	27
Figura 3.7 – Extrapolação das Tensões para o Pé da Solda.	28
Figura 3.8 – Distribuição de Tensões na Região do Cordão de Solda.....	29
Figura 3.9 – Definição do Parâmetro ξ	30
Figura 4.1 – Modelo de Transmissão de Impulso em Neurônios Biológicos.	32
Figura 4.2 – Modelo Básico do Neurônio Artificial.....	33
Figura 4.3 – Função de Ativação Utilizada por McCulloch e Pitts.....	34
Figura 4.4 – Funções de Ativação Sigmóide: (a) logística e (b) tangente hiperbólica	35
Figura 4.5 – Exemplo da Aprendizagem do Cachorro.	37
Figura 4.6 – Modelo do Perceptron de Roseblatt.	38
Figura 4.7 – Duas Classes Linearmente Separáveis com Duas Variáveis de Entrada.....	39
Figura 4.8 – Fluxograma do Treinamento do ADALINE.....	40
Figura 4.9 – Representação da Função Booleana OU exclusivo (XOR).	42
Figura 4.10 – Exemplo de Redes Recorrentes.	45
Figura 4.11 – Rede Neural Multi-Camadas.	46
Figura 4.12 – Cálculo Iterativo do Mínimo da Função pelo Método do Gradiente.....	49
Figura 4.13 – Rede Treinada: (a) boa generalização. (b) generalização ruim.....	51
Figura 5.1 – Diferença para o Conjunto de Treinamento com 3100 Pontos.....	56
Figura 5.2 – Diferença para o Conjunto de Teste com 7232 Pontos	56
Figura 5.3 – Erro Médio no Conjunto de Treinamento para o Caso 1.....	59
Figura 5.4 – Erro Médio no Conjunto de Treinamento para o Caso 2.....	59
Figura 5.5 – Erro Médio no Conjunto de Treinamento para a função $y = 0.5x^2$	62

Figura 5.6 – Erro Médio no Conjunto de Treinamento para a função $z = x^3 / y$.	62
Figura 5.7 – Erro Médio no Conjunto de Treinamento para Equação 5.2.	63
Figura 5.8 – Erro Médio no Conjunto de Treinamento para Equação 5.4.	63
Figura 6.1 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	70
Figura 6.2 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	70
Figura 6.3 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	70
Figura 6.4 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	71
Figura 6.5 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	71
Figura 6.6 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	71
Figura 6.7 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	72
Figura 6.8 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	72
Figura 6.9 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	72
Figura 6.10 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	73
Figura 6.11 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	73
Figura 6.12 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	73
Figura 6.13 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	74
Figura 6.14 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.	74
Figura 6.15 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	74
Figura 6.16 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	75
Figura 6.17 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	75
Figura 6.18 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	75
Figura 6.19 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	76
Figura 6.20 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	76
Figura 6.21 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	76
Figura 6.22 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	77
Figura 6.23 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	77
Figura 6.24 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	77
Figura 6.25 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	78
Figura 6.26 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.	78
Figura 6.27 – Distribuição do Erro Médio no Conjunto de Treinamento – FNP.	78
Figura 6.28 – Distribuição do Erro Médio no Conjunto de Teste – FNP.	79
Figura 6.29 – Distribuição do Erro Médio no Conjunto de Treinamento – MNP.	79
Figura 6.30 – Distribuição do Erro Médio no Conjunto de Teste – MNP.	79
Figura 6.31 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda Recomendada pela UEG ¹⁹ –FNP.	80

Figura 6.32 – Distribuições de Tensões ao Longo do Comprimento do Cordão de Solda para o modelo RNA–FNP.	80
Figura 6.33 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda Recomendada pela UEG ¹⁹ –MNP.	81
Figura 6.34 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda Recomendada pela UEG ¹⁹ –MNP.	81
Figura 6.35 – Comparação de Resultados: RNA x Equações Paramétricas - FNP	86
Figura 6.36 – Comparação de Resultados: RNA x Equações Paramétricas - FNP	86
Figura 6.37 – Comparação de Resultados: RNA x Equações Paramétricas - FNP	86
Figura 6.38 – Comparação de Resultados: RNA x Equações Paramétricas - FNP	87
Figura 6.39 – Comparação de Resultados: RNA x Equações Paramétricas - MNP.....	87
Figura 6.40 – Comparação de Resultados: RNA x Equações Paramétricas - MNP.....	87
Figura 6.41 – Comparação de Resultados: RNA x Equações Paramétricas - MNP.....	88
Figura 6.42 – Comparação de Resultados: RNA x Equações Paramétricas - MNP.....	88
Figura 6.43 – Variação do FCT com o parâmetro β – FNP.....	88
Figura 6.44 – Variação do FCT com o parâmetro τ – FNP.	89
Figura 6.45 – Variação do FCT com o parâmetro α – FNP.....	89
Figura 6.46 – Variação do FCT com o parâmetro γ – FNP.....	89
Figura 6.47 – Variação do FCT com o parâmetro θ – FNP.	90
Figura 6.48 – Variação do FCT com o parâmetro β – MNP.....	90
Figura 6.49 – Variação do FCT com o parâmetro τ – MNP.	90
Figura 6.50 – Variação do FCT com o parâmetro γ – MNP.	91
Figura 6.51 – Variação do FCT com o parâmetro θ – MNP.....	91
Figura 6.52 – Variação do FCT com os Parâmetros da Junta ¹¹	92
Figura 6.53 – Comparação dos Resultados da RNA com Ensaios Experimentais – FNP.	94
Figura 6.54 – Comparação dos Resultados da RNA com Ensaios Experimentais – FNP.	94
Figura 6.55 – Comparação dos Resultados da RNA com Ensaios Experimentais – FNP.	94
Figura 6.56 – Comparação dos Resultados da RNA com Ensaios Experimentais –FNP.	95
Figura 6.57 – Comparação dos Resultados da RNA com Ensaios Experimentais – FNP.	95
Figura 6.58 – Comparação dos Resultados da RNA com Ensaios Experimentais –MNP.....	95
Figura 6.59 – Comparação dos Resultados da RNA com Ensaios Experimentais – MNP.....	96
Figura 6.60 – Comparação dos Resultados da RNA com Ensaios Experimentais – MNP.....	96

LISTA DE TABELAS

Tabela 3.1 – Parâmetros Utilizados no <i>Modelo RNA</i>	31
Tabela 4.1 – Algoritmo de Retro-Propagação.....	43
Tabela 5.1 – MEF x RNA: Conjunto de Teste com 7232 Pontos.....	57
Tabela 5.2 – Comparação dos Tempos de Treinamento par os <i>Casos 1 e 2</i>	59
Tabela 5.3 – Características do Treinamento do <i>modelo RNA</i>	64
Tabela 6.1 – Diferenças Absolutas Maiores que 10% para o Caso MNP.....	69

NOMENCLATURA

- D, d diâmetro dos tubos primário e secundário, respectivamente.
- G abertura (*gap*) ou folga na raiz do cordão.
- L comprimento do tubo primário.
- T, t espessura dos tubos primário e secundário, respectivamente.
- MEF Método dos Elementos Finitos.
- RNA Redes Neurais Artificiais.
- α_s ângulo de chanfro no secundário, medido em relação à tangente da superfície do primário, no plano da seção transversal do cordão de solda.
- $a = L/D.$
- $b = d/D.$
- $\gamma = D/2T$
- $t = t/T.$
- $\theta =$ ângulo entre os tubos primário e secundário.
- $\xi =$ porcentagem do comprimento do cordão de solda medido a partir da coroa situada no lado do ângulo obtuso entre os tubos.
- $h =$ taxa de aprendizado.
- $d_j =$ gradiente local no neurônio $j.$
- $q_j =$ limiar do neurônio $j.$
- $W =$ vetor de pesos de uma rede neural artificial.
- $w_{ij} =$ ligação (peso) entre o neurônio i e o neurônio $j.$

DEFINIÇÕES

Juntas Tubulares Soldadas

- secundário** tubo que recebe os esforços externos significativos para as tensões na junta.
- primário** tubo que recebe os esforços externos através da junta.
- sela** região de contato entre o primário e o secundário mais afastada do plano de simetria da junta.
- coroa** regiões do cordão de solda situadas no plano de simetria da junta. A coroa situada na região de ângulo agudo é chamada de *toe*. A outra é também conhecida como *heel*.
- overlap** ocorre nas juntas tubulares com mais de um secundário quando existe intersecção entre os tubos secundários.

Redes Neurais Artificiais

- variáveis independentes** aquelas utilizadas para representar o problema.
- variáveis dependentes** aquelas calculadas de alguma forma a partir das variáveis independentes.
- vetor de entrada** variáveis utilizadas para alimentar a rede, normalmente contêm as variáveis independentes do problema.
- vetor de saída** vetor associado que contêm as variáveis dependentes do problema.
- par de treinamento** um vetor de entrada e o seu respectivo vetor de saída.
- conjunto de dados** conjunto com os pontos representativos do problema que se deseja estudar.

conjunto de treinamento	conjunto com todos os pares de treinamento, formado como uma porcentagem do conjunto de dados.
conjunto de teste	conjunto de dados – conjunto de treinamento.
camada de entrada	camada utilizada para receber os vetores de entrada.
camada de saída	camada que fornece o resultado calculado pela rede.
camadas oculta	camadas localizadas entre a camada de entrada e a camada de saída.
função de ativação	função que fornece o valor de saída do neurônio.
função resíduo	função que define uma medida de erro, usualmente utilizada como critério de parada no treinamento da rede.
<i>epoch</i>	apresentação à rede de todos os pares de treinamento que formam o conjunto de treinamento em uma iteração.

RESUMO

Neste trabalho está apresentada uma alternativa para o cálculo do fator de concentração de tensões (FCT) em juntas tubulares soldadas do tipo Y. Redes Neurais Artificiais (RNA) foram utilizadas para representar a distribuição de tensões ao longo da junta tubular para os casos de carregamento força axial no plano e momento fletor no plano.

As RNA podem aprender a partir de um conjunto de dados, sem a necessidade de uma expressão matemática entre as variáveis dependentes e independentes; representa uma vantagem sobre o procedimento normalmente utilizado, ou seja, as equações paramétricas. Além disso, as RNA permitem a inclusão de parâmetros geométricos característicos do cordão de solda.

O modelo proposto representa um avanço no projeto de juntas tubulares, uma vez que evita a necessidade de se conhecer uma expressão matemática para representar a distribuição de tensões na junta e fornece um método mais preciso para avaliar a distribuição de tensões ao longo da junta soldada.

O conjunto de dados utilizado foi formado a partir de simulações numéricas das juntas soldadas através do MEF, considerando os parâmetros geométricos do braço e do tubo principal e, também, a geometria do cordão de solda. Os resultados obtidos com as RNA foram comparados com resultados provenientes de equações paramétricas e de ensaios experimentais em bancos de prova.

ABSTRACT

An alternative approach to calculate stress concentration factors (SCF) in Y-type welded tubular joints is presented. Artificial Neural Networks (ANN) were used to represent the stress distribution along the tubular joints in both in-plane axial force and in-plane bending moment load cases.

ANN can learn from a database without establishing a mathematical expression between dependent and independent variables, which is an advantage over the usual parametric equations approach. Besides, with ANN it is possible to include welded fillet geometric parameters.

The proposed model represents an improvement in the tubular joints design, since it avoids the previous knowing of a mathematical expression to represent the stress distribution in the joint and provides an accurate method to evaluate the stress distribution along the welded fillet joint.

The database herein used was completed with FE simulations of tubular joints which consider the geometrical parameters of chord and brace members, and also the geometry of the weld fillet. The ANN results were compared with traditional equations and experimental tests results.

CAPÍTULO 1

INTRODUÇÃO

1.1 Considerações Iniciais.

As estruturas de plataformas de perfuração ou exploração de petróleo são construídas predominantemente com membros tubulares unidos pela soldagem da extremidade cortada de um tubo na superfície externa de outro. Essa união é conhecida como *junta tubular soldada* e exerce papel fundamental na integridade estrutural da plataforma.

A intrincada geometria da junta tubular e os problemas causados pelo processo de soldagem introduzem tensões elevadas em pontos isolados da região soldada. As referidas concentrações de tensões são particularmente importantes na avaliação dos carregamentos variáveis que agem sobre a plataforma, eminentemente provenientes de ondas, ventos e correntezas marítimas. Essas cargas causam flutuações no nível de tensões na junta tubular, possibilitando nucleação e propagação de trincas e podendo, ainda, levar a uma falha estrutural da junta por processo de fadiga¹.

A análise da vida em fadiga em juntas tubulares soldadas está diretamente associada à concentração de tensões². Na avaliação de Kallaby³, uma tensão máxima na junta superestimada em 50% pode aumentar o valor da espessura da junta na mesma proporção, acarretando considerável aumento da quantidade de material empregado e no peso da estrutura. Segundo Gibstein⁴, se a tensão máxima atuante na junta for subestimada em 18% a vida em fadiga poderá ser superestimada em 100%. Do ponto

de vista dos acionistas da companhia petrolífera mesmo a perda de uma pequena plataforma de perfuração ou exploração pode significar prejuízos da ordem de dezenas de milhões de dólares¹.

A estreita relação entre as máximas tensões na junta soldada e sua vida em fadiga justifica a preocupação com a correta avaliação daquelas no projeto de uma plataforma. Nesse sentido, uma possibilidade para a estimativa da vida em fadiga é a utilização da mecânica de fraturas, com a qual é possível acompanhar o crescimento do comprimento de trincas na junta soldada. Apesar de pouco utilizado, esse método é importante para prever comprimentos de trincas permissíveis nas manutenções periódicas feitas nas juntas^{5,6,7}. O outro método, largamente empregado na análise de vida em fadiga de juntas tubulares, é baseado nos *diagramas de Whöler*, mais conhecidos como *curvas S-N*^{8,9}.

Neste enfoque são calculadas, inicialmente, as tensões máximas nas juntas soldadas. Para facilitar o cálculo foram definidos parâmetros adimensionais que consideram as principais características geométricas da junta, conforme mostrado na Figura 1.1. Além disso, foi estabelecido o *fator de concentração de tensões* (FCT)*. Esse fator avalia quantas vezes a máxima tensão na junta, denominada *tensão crítica*[†], é maior em relação às tensões nominais em um ponto suficientemente afastado da junta, no membro secundário.

De outro lado, curvas de fadiga das juntas são levantadas experimentalmente a partir de ensaios com protótipos de dimensões reais e também com modelos em escala

* Existem algumas divergências na definição de FCT, basicamente, com relação à forma como a tensão é medida. No capítulo 3 o FCT será definido de acordo com os propósitos deste trabalho.

[†] Tradução do inglês que será adotada neste texto para *hot spot stress*.

reduzida¹⁰. A vida em fadiga da junta é estimada confrontando-se, através de algum critério, as tensões máximas e as *curvas S N*.

Conforme será visto no capítulo 3, existem vários meios para avaliação das tensões máximas na junta tubular soldada; um deles é a utilização de equações paramétricas.

1.2 Equações Paramétricas para o Cálculo do FCT.

Não obstante o elevado número de pesquisas sobre o cálculo de tensões em juntas soldadas*, é fato que a complexidade do problema não permite uma solução teórica para representar o estado de tensões nessas juntas¹². No outro extremo, avaliar todas as juntas da estrutura de uma plataforma, uma a uma, é tarefa árdua. A solução adotada está a meio caminho: consiste, basicamente, em avaliar algumas juntas soldadas e arbitrar uma equação matemática que possa representar a distribuição de tensões na junta. Em seguida, as duas partes são concatenadas, calibrando-se a equação arbitrada a partir dos resultados obtidos para as juntas avaliadas. Dessa forma, obtém-se um modo de estimar o FCT para outras juntas, de geometria e carregamentos semelhantes, a um custo muito menor do que a execução de novos testes experimentais ou a elaboração de modelos para simulação numérica pelo método dos elementos finitos (MEF).

Segundo Branco¹³, essas equações têm a forma geral dada por:

$$FCT = C \cdot a^a \cdot b^b \cdot g^c \cdot t^d \cdot (\sin q)^n \quad (1.1)$$

* os principais trabalhos estão listados nos itens *referências bibliográficas e bibliografia recomendada*. Uma lista mais completa das publicações sobre cálculo de tensões em juntas tubulares soldadas está disponível na obra de Wardenier¹¹.

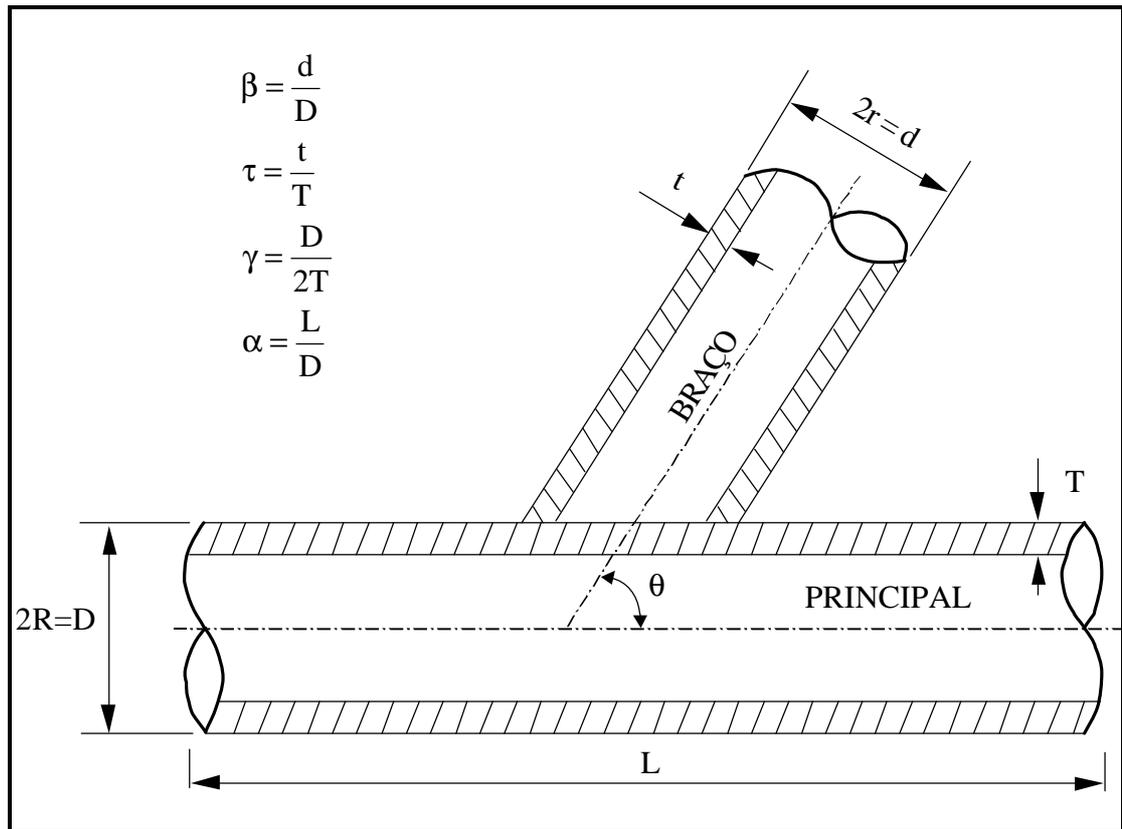


Figura 1.1 – Dimensões e Adimensionais Característicos da Junta Tubular.

em que C é uma constante a, b, c, d e n são expoentes e a, b, t, g e q são parâmetros geométricos, definidos na Figura 1.1.

Assim, utilizando resultados conhecidos para algumas juntas soldadas, os coeficientes a, b, c, d e n são ajustados, usualmente pelo Método dos Mínimos Quadrados (MMQ)*, resultando na expressão de cálculo do FCT. Observa-se, ainda, que a definição dessas expressões é influenciada mais por critérios estatísticos, que determinam o melhor ajuste da expressão ao conjunto de dados modelado, do que pelo fenômeno físico que elas tentam representar. Efthymiou¹⁶, por exemplo, utiliza quatro

* nas referências 14 e 15 esse assunto é tratado com detalhe.

equações para o cálculo do FCT em juntas T, uma para a sela e outra para a coroa* do tubo primário, e outras duas para o tubo secundário. Essas equações, mostradas no *Apêndice C*, revelam a preocupação em desenvolver expressões que apresentem boa correlação com os dados medidos em cada ponto citado, claramente uma consequência da dificuldade de representação da distribuição de tensões na junta através de uma única expressão.

As dificuldades no cálculo do FCT a partir de uma expressão previamente definida se avolumam quando são considerados os efeitos da geometria do cordão de solda que une os tubos primário e secundário. Esse efeito é praticamente desprezado nos modelos utilizados para produzir os dados de ajuste das equações e nas próprias equações, baseadas essas, principalmente, em modelos de simulação numérica e em modelos deacrílico^{17,18,19}. Nas simulações é comum a utilização do elemento de casca fina, em que a intersecção entre os dois tubos fica representada apenas por uma linha; nos modelos deacrílico a geometria do cordão de solda não é considerada.

Dentre os poucos trabalhos que avaliam a influência da geometria do cordão de solda no cálculo do FCT em juntas soldadas está o desenvolvido por Massaroti²⁰. Utilizando o elemento finito do tipo sólido para elaborar o modelo da junta o autor fez um estudo paramétrico da geometria do cordão de solda. A partir do conjunto de dados levantado foram determinadas expressões com boa correlação para o carregamento de momento no plano, embora o mesmo não tenha ocorrido para o caso de força no plano. Registra-se, também, que Gibstein¹⁰ estudou os efeitos da geometria do cordão de solda

* Sela e coroa são regiões distintas da junta soldada, definidas com propriedade no capítulo 3. Neste trabalho será utilizado tubo principal como sinônimo de tubo primário e tubo secundário como sinônimo de braço.

no cálculo do FCT através de testes experimentais. Em ensaios nos laboratórios da *DnV (Det Norske Veritas)* o autor empregou *strain gages* com filamentos de até 0.5 mm de comprimento para medir deformações (tensões) em regiões próximas ao cordão de solda, levantando valores de FCT e também curvas S-N para juntas dos tipos Y* e K. A utilização desse enfoque para o projeto de juntas soldadas, no entanto, traz como consequência a necessidade de levantamento de novas — e onerosas[†] — curvas S-N para os outros tipos de juntas.

1.3 Justificativas e Objetivos do Trabalho.

Dentro deste contexto, o modelo para cálculo do FCT em juntas tubulares soldadas ora apresentado institui um novo e promissor horizonte para o cálculo de juntas tubulares soldadas. Esse modelo é baseado na utilização de Redes Neurais Artificiais (RNA) e permite incluir a geometria do cordão de solda na avaliação do FCT em juntas tubulares soldadas.

Criadas por pesquisadores da área da ciência da computação, as RNA vêm ganhando espaço também na engenharia de estruturas. Uma rede para estimar as características geométricas de vigas de concreto foi apresentada por Mukherjee e Deshpande²¹. Barai e Pandey²² analisaram o problema de vibrações em pontes treliçadas com o auxílio de redes neurais. Wu et al²³ e Szewczyk²⁴ utilizaram

* as juntas tubulares do tipo Y e do tipo T se diferenciam somente pelo ângulo \mathbf{q} entre os tubos, mostrado na Figura 1.1. No primeiro caso, esse ângulo é menor do que 90° e, no segundo, o ângulo é reto. Por simplificação gramatical, salvos os casos explícitos, doravante os dois tipos serão mencionados por juntas tubulares do tipo Y, ou simplesmente junta Y. A nomenclatura dos tipos de juntas será retomada no capítulo 3.

† Segundo Branco¹³, o custo de ensaios de juntas tubulares em bancos de teste é de cerca de vinte a cinquenta vezes mais elevado que o de uma máquina convencional de ensaios de fadiga para pequenos corpos de prova.

RNA para detecção de avarias em edifícios concretados. Processos de otimização estrutural em asas de aeronaves e em estruturas reticuladas foram investigados com RNA, respectivamente, nos trabalhos de Berke *et al*²⁵, Sadek²⁶ e Kang²⁷.

Com o auxílio das RNA é possível estabelecer uma relação entre os parâmetros geométricos adimensionais e o valor do FCT sem a necessidade de uma expressão matemática explícita que os relacione. Conforme será visto no capítulo 3, podem ser incluídos parâmetros representativos da geometria do cordão de solda, além daqueles apresentados na Figura 1.1. Essa característica ganha importância na medida em que a determinação teórica da distribuição de tensões nas juntas tubulares soldadas ainda não foi demonstrada²⁸. Por outro lado, as RNA podem, virtualmente, aproximar qualquer função que governa determinado fenômeno a partir de um conjunto de pontos representativos da mesma²⁹. Introduz-se, assim, um ganho significativo no processo de cálculo do FCT em juntas tubulares soldadas. Com as regressões o procedimento usual consiste em formular um modelo matemático para as observações experimentais — com medições de *strain gages* ou modelos de elementos finitos —, validar esse modelo, efetivamente através de um ajuste de parâmetros pelo MMQ e, então, utilizá-lo para projeto de novas juntas, similares em carregamento e geometria. O cálculo do FCT utilizando redes neurais, por outro lado, é baseado diretamente no conjunto de dados. Assim, as RNA treinadas* com um conjunto de dados não apenas possuem um modelo embutido do fenômeno representado por esses dados mas também codificam uma função representativa desse fenômeno²⁹. Depois de treinadas as RNA podem ser utilizadas para avaliar o FCT para novas juntas.

* o processo de treinamento será devidamente aclarado no capítulo 4.

Vislumbra-se ainda a possibilidade de avaliar a distribuição de tensões ao longo do cordão de solda, ultrapassando a barreira do cálculo de tensões apenas em alguns pontos predeterminados. Conhecida a distribuição de tensões para cada carregamento é possível fazer um projeto mais otimizado para as juntas soldadas pois, em cada ponto, o valor da tensão está mais bem representado. Em função do grande número de juntas numa plataforma pode-se conseguir uma estrutura com menor peso e também a um custo menor.

Os aspectos positivos no tratamento do cálculo do FCT em juntas soldadas utilizando redes neurais, delineados acima, juntamente com a característica de inovação que essa abordagem introduz na análise de juntas soldadas relevam a proposta deste trabalho como uma importante contribuição para aqueles que atuam nessa área.

Isso posto, e com o intuito de comprovar a viabilidade da proposta do cálculo do FCT com o auxílio de redes neurais, convém aqui estabelecer os objetivos e as limitações do trabalho.

1. O objetivo deste trabalho é estabelecer um modelo, baseado em RNA, doravante denominado *modelo RNA*, capaz de avaliar o FCT em juntas tubulares soldadas do tipo Y considerando-se a geometria do cordão de solda. Para isso será utilizado o conjunto de dados apresentado no trabalho de Massaroti²⁰, no qual estão incluídos parâmetros representativos da geometria do cordão de solda. Serão utilizados os carregamentos força axial e momento fletor no plano, aplicados separadamente no membro secundário. Esses carregamentos serão definidos adequadamente no capítulo 3.

2. Como resultado secundário, mas não menos importante, é propósito utilizar as RNA para avaliar, ao longo do cordão de solda, as distribuições de tensões causadas pelos carregamentos mencionados no item anterior.
3. Espera-se, por fim, que este trabalho seja referência para futuras pesquisas nestas áreas.

A utilização de juntas do tipo Y não deve ser entendida como uma restrição do modelo proposto. De fato, o modelo aqui delineado pode ser utilizado para outros tipos de juntas, desde que haja dados suficientes para representá-las. Além disso, é importante mencionar que somente os aspectos geométricos da junta soldada serão considerados na distribuição de tensões provocada por cada carregamento. Não faz parte do escopo deste trabalho, portanto, avaliar outros efeitos na junta soldada, como aqueles provocados pelo processo de soldagem ou de outra natureza.

1.4 Apresentação do trabalho.

Uma perspectiva da evolução histórica do cálculo de tensões em juntas tubulares soldadas será apresentada no próximo capítulo. No capítulo 3 será definido o problema da distribuição de tensões em juntas soldadas, com enfoque para a geometria da junta soldada, os carregamentos considerados e a definição do fator de concentração de tensões.

O capítulo 4 será reservado para as RNA. Será exibida uma visão panorâmica da evolução dos estudos com RNA e, em seguida, um detalhamento do tipo de rede escolhido para representar a distribuição de tensões nas juntas soldadas. Convém destacar que as RNA foram utilizadas neste trabalho como ferramentas para a resolução do problema do cálculo do FCT em juntas soldadas, descrito no capítulo terceiro.

Portanto, não existe nenhuma expectativa de fornecer ao leitor material além do suficiente para o entendimento do modelo de cálculo ora apresentado. Aos interessados em mergulhar um pouco mais nesse fascinante campo de pesquisas existem referências que focalizam a teoria envolvida^{30,31,32}, trabalhos direcionados para a elaboração de programas de computador na implementação de redes neurais^{29,33} e, também, textos que enfocam a representação do conhecimento por meio de redes neurais^{34,35}.

Em face dos problemas encontrados durante o desenvolvimento do trabalho foi montado o capítulo 5, que registra as tentativas malogradas. Ademais, nesse capítulo também foram inseridas as configurações finais das redes definidas para cada caso de carregamento.

Os resultados obtidos com o uso de RNA para o cálculo do FCT em juntas soldadas serão exibidos e discutidos no capítulo 6. Os resultados produzidos pela RNA serão inicialmente comparados com aqueles utilizados para configurá-las. Ainda nesse capítulo serão apresentadas comparações com as principais equações existentes bem como com resultados de ensaios experimentais em bancos de prova.

Finalizando, no capítulo 7 serão colocadas as principais conclusões e as perspectivas de utilização do modelo apresentado neste trabalho.

CAPÍTULO 2

REVISÃO DA LITERATURA

Os projetos das primeiras plataformas de petróleo no final da década de 40 eram, eminentemente, semi-empíricos, em decorrência, principalmente, do pouco conhecimento teórico sobre o comportamento de estruturas tubulares soldadas sob a ação de carregamentos cíclicos. Segundo Branco¹³, essa deficiência era compensada pelo emprego de reforçadores nas juntas soldadas e pela manutenção periódica, o que evitava o comprometimento das estruturas projetadas. Dentre os reforçadores mais utilizados destacavam-se as *gusset-plates*, a sobreposição dos tubos soldados, o uso de espessuras maiores na região de solda ou até mesmo a combinação desses, no intuito de construir estruturas com resistência estrutural suficiente para suportar os carregamentos.

O projeto de juntas tubulares nas décadas de 50 e 60 foi caracterizado por um misto de estudos teóricos e testes experimentais³⁶. Muitas vezes os projetos eram fundamentados em formulações analíticas com base na teoria de cascas finas, com destaque para os trabalhos de Bijllard^{37,38}. Essa abordagem, no entanto, era aplicável somente a geometrias simplificadas, notadamente cilindros de cascas finas sujeitos a carregamentos axiais, levando a resultados igualmente simplificados. Na construção das estruturas tubulares, no entanto, conforme focado no trabalho de Bouwkamp³⁹, ainda era comum o emprego dos reforçadores mencionados no parágrafo anterior.

Ao mesmo tempo em que as formulações analíticas então existentes não conseguiam representar adequadamente a distribuição das tensões nas juntas soldadas, surgiam os testes experimentais, em dimensões reais e também em modelos reduzidos,

como ferramenta efetiva de apoio no projeto das mesmas. Segundo Carter et al⁴⁰, no início da década de 60 já havia uma quantidade considerável de testes experimentais, com predomínio do uso de extensômetros elétricos na medição das deformações nas juntas soldadas.

As primeiras tentativas de um projeto racional reportam ao trabalho de Toprac⁴¹. Introduzindo o conceito de tensão de arrombamento* para definir as tensões máximas na região da junta soldada o autor comparou seus resultados com as curvas S-N levantadas para as juntas estudadas. A hipótese básica nessa abordagem é que a carga do tubo secundário é transferida por cisalhamento para a parede do tubo primário⁴². Esse conceito foi fundamentado em vários casos de falhas em juntas, em que o tubo secundário arrancava um pedaço da parede do tubo primário, como ilustrado na Figura 2.1. Embora esse tipo de falha fosse plausível e até mesmo freqüente, o procedimento analítico adotado para descrevê-lo não considerava efeitos relevantes no comportamento das juntas como, por exemplo, a flexão das paredes dos tubos e a variação de tensão na região de interseção entre eles.

As primeiras evidências analíticas de elevadas concentrações de tensões nas juntas soldadas vieram com o trabalho de Scordelis e Boukamp⁴³. Partindo das equações de Bijllard^{37,38} e trabalhando com juntas do tipo T, os autores estudaram juntas tubulares sob a luz de várias hipóteses para o carregamento. Destacam-se os bons resultados obtidos aplicando-se um deslocamento constante, distribuído sobre a linha de contato entre os dois tubos, conforme ilustrado na Figura 2.2. No modelo foi admitido que a elevada rigidez axial do tubo secundário, em relação à rigidez radial do tubo principal, é

* tradução do inglês, doravante neste texto, para “punching shear stress”.



Figura 2.1 – Exemplo de Falha em Juntas Soldadas.

suficiente para que os deslocamentos na intersecção entre os dois tubos possam ser considerados constantes, o que representou um avanço sobre os modelos de Bijllard^{37,38}. Através de programas de computador específicos os autores conseguiram bons resultados, com destaque para a boa representação da aguda variação de tensões na região de contato entre os tubos. Ainda não havia, no entanto, condições para incluir nos modelos características importantes das juntas soldadas como, por exemplo, a geometria do cordão de solda. Além disso, à medida que o ângulo entre os tubos se afasta de 90°, ou o parâmetro b se aproxima da unidade, essa hipótese fica menos verdadeira e os resultados obtidos, conseqüentemente, mais pobres. Prenunciava-se, no entanto, a utilização da análise matricial implementada em computadores para o cálculo de estruturas tubulares.

No final da década de 60 e início da década de 70 houve uma grande expansão de pesquisas na área de projeto de plataformas, notadamente bancadas pelas companhias petrolíferas que investiam através de seus centros de pesquisas ou por meio de convênios com universidades, principalmente nos Estados Unidos, em alguns países da

Europa e no Japão. Paralelamente, foram organizadas conferências para exposição e intercâmbio de novas tecnologias *offshore* entre as várias comunidades científicas, destacando-se a *OTC (Offshore Technology Conference)*, a partir de 1969.

Surgiram, assim, novas propostas para o cálculo de tensões em juntas tubulares. Holliday³⁶, utilizando técnicas de foto-elasticidade, conseguiu resultados encorajadores com modelos reduzidos para juntas do tipo T. A partir desses modelos foram levantadas as distribuições de tensões ao longo da junta e do membro primário, na região da junta. Paralelamente, a utilização de computadores no projeto de juntas tubulares foi acelerada, possibilitando a criação e implementação de novos algoritmos. Isso, juntamente com a elaboração de novas formulações para o elemento finito de casca⁴², possibilitou um aumento significativo na utilização da simulação numérica por computador nas análises de juntas soldadas^{17,44}. O Método dos Elementos Finitos(MEF) surgia como uma boa ferramenta para a análise de juntas soldadas, ainda que a um preço proibitivo.

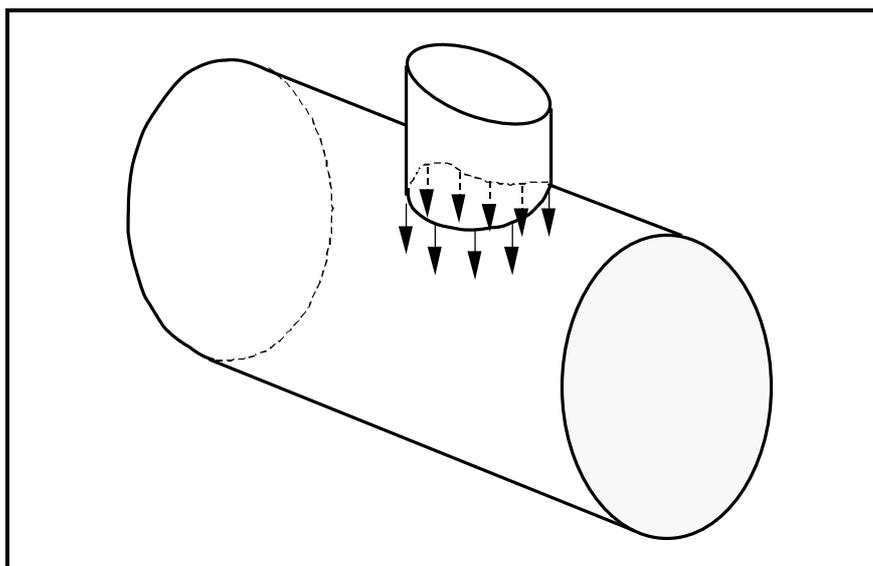


Figura 2.2 – Modelo de Scordelis e Bouwkamp: Deslocamento Constante ao Longo da Junta.

O aparecimento dos computadores de terceira geração, com maior capacidade de armazenamento e velocidade de processamento, possibilitou o desenvolvimento de programas de computador^{2,45,46} específicos para construção e análise de modelos de juntas tubulares. Nessas condições o projeto de juntas tubulares a partir do começo da década de 70 passou a ser mais e mais pautado na técnica do MEF²⁸. Na década de 80 a utilização do MEF no cálculo de juntas soldadas aumentou significativamente, principalmente com a produção de micro-computadores em larga escala e o seu conseqüente barateamento. Com isso, programas para análise, pré e pós-processamento de malhas de elementos finitos^{47,48,49,50} ficaram mais acessíveis eliminando, assim, a onerosa tarefa de construção manual de modelos. Fornecendo resultados compatíveis com os obtidos por testes experimentais, na metade da década de 80, a simulação numérica já era a mais eficiente, confiável e econômica ferramenta para análise detalhada de juntas tubulares soldadas¹².

2.1 Evolução das Equações Paramétricas para Cálculo do FCT.

No que tange à evolução das equações paramétricas, serão mostradas aqui somente as equações para o carregamento de força axial agindo sobre o tubo secundário para juntas do tipo Y. No *Apêndice A* serão apresentadas as principais equações também para o caso de momento fletor aplicado no plano.

Uma das primeiras expressões para cálculo do FCT foi apresentado por Toprac⁴¹, e está identificada na Equação 2.1. Na pesquisa os autores utilizaram as relações entre os raios dos tubos primário e secundário e também entre suas espessuras na elaboração de uma expressão para o cálculo do FCT em quatro pontos de uma junta soldada submetida a carregamento axial.

$$FCT_p = 277.5 \left(\frac{L}{R}\right)^{0.213} \left(\frac{r}{R}\right)^{-0.772} \left(\frac{R}{T}\right)^{-1.145} \left(\frac{t}{T}\right)^{3.585} \quad (2.1)$$

Resultado semelhante foi obtido por Reber⁴⁴ introduzindo, no entanto, o ângulo entre os tubos como variável independente. Em acordo com a nomenclatura definida na Figura 1.1, as expressões obtidas por Reber⁴⁴ para carregamento axial aplicado no tubo secundário foram:

$$FCT_p = 1.7 \frac{t}{T} \left(\frac{R}{T}\right)^{0.6} \sin^{1.5} \mathbf{q} \quad (2.2)$$

e

$$FCT_b = 1.6 \frac{t}{T} + 0.6 \left(\frac{R/T}{r/t}\right)^{0.5} \cdot FCT_p \quad (2.3)$$

com

$$0.4 < \frac{r}{R} < 1.0 \quad (2.4)$$

Visser² propôs a seguinte expressão de cálculo do FCT para o caso de força axial agindo no secundário, também incluindo o efeito do ângulo entre os dois tubos:

$$FCT_p = \frac{t}{T} \left(10 + 0.3 \frac{R}{T}\right) \left(1.4 - 0.75 \frac{r}{R}\right) \sin^2 \mathbf{q} \quad (2.5)$$

No trabalho de Kuang et al¹⁷ foram apresentadas expressões para cálculo do FCT em vários tipos de juntas, para carregamentos de força axial e momento fletor atuando no membro secundário. Para o carregamento axial o cálculo do FCT no tubo primário era efetuado por

$$FCT_p = 1.177 \left(\frac{T}{2R}\right)^{-0.808} e^{-1.2(d/D)^3} \left(\frac{t}{T}\right)^{1.333} \left(\frac{2R}{L}\right)^{-0.057} \sin^{1.694} \mathbf{q} \quad (2.6)$$

As expressões de Kuang foram levantadas a partir de um conjunto de dados obtido através do MEF em um programa de computador específico para análise de

juntas tubulares. O autor utilizou o elemento finito de casca para representar a junta, levantando expressões também para juntas dos tipos K e KT.

Efthymiou¹⁶ analisou mais de 150 configurações utilizando o programa PMBSHELL, com o qual é possível modelar a geometria do cordão de solda. A partir desse conjunto de configurações o autor levantou equações cobrindo juntas T/Y e também juntas K. Para o caso de carregamento de força axial em juntas T foram obtidas as seguintes expressões:

$$\begin{aligned} (FCT_p)_{coroa} = & \left(\frac{R}{T}\right)^{0.2} \left(\frac{t}{T}\right) \left[2.65 + 5 \left(\frac{r}{R} - 0.65\right)^2 \right] + \\ & \left(\frac{t}{T}\right) \left(\frac{r}{R}\right) \left(0.25 \frac{L}{R} - 3\right) \sin \mathbf{q} \end{aligned} \quad (2.7)$$

e

$$(FCT_p)_{sela} = \left(\frac{R}{T}\right) \left(\frac{t}{T}\right)^{1.1} \left[1.11 - 3 \left(\frac{r}{R} - 0.52\right)^2 \right] \sin^{1.6} \mathbf{q} \quad (2.8)$$

nas regiões de *sela* e *coroa* do tubo primário, definidas na Figura 2.3.

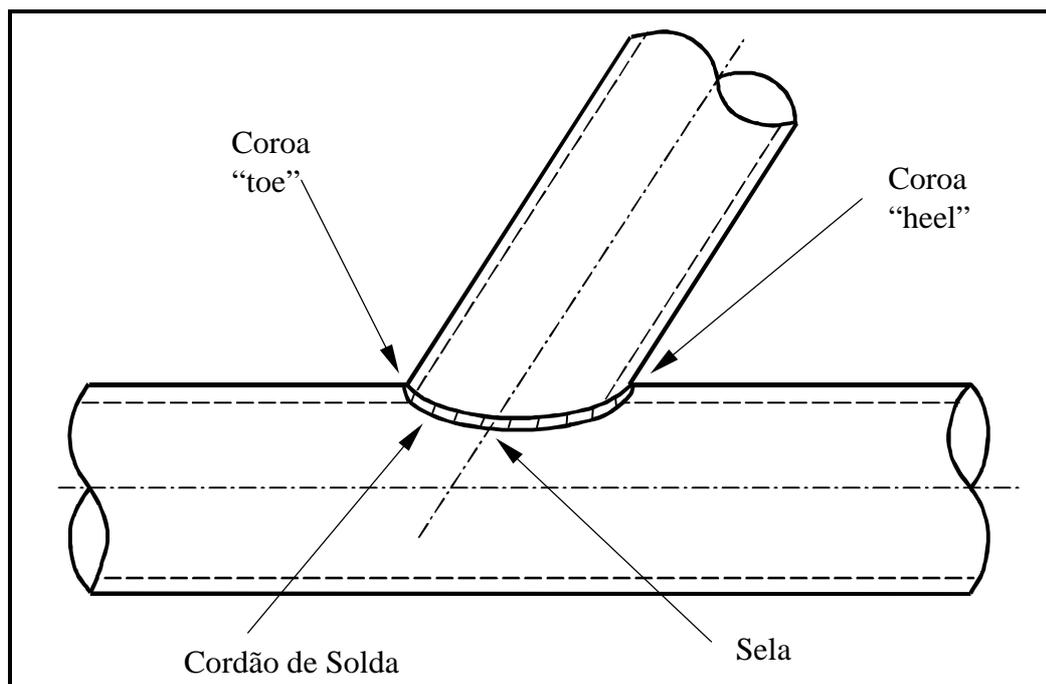


Figura 2.3 – Localização da Coroa e da Sela na Junta Soldada.

Em 1997 o *Lloyd's Register*⁵¹ publicou uma série de equações baseadas em dados obtidos com modelos reduzidos de acrílico e modelos de aço em tamanho natural. Para o caso de força axial em juntas Y foram publicadas quatro expressões, identificadas nas Equações 2.9 a 2.12, nos pontos de sela e coroa, para os tubos primário e secundário, respectivamente:

$$FCT_s = \mathbf{t} \mathbf{g}^{1.2} (2.12 - 2 \mathbf{b}) \sin^2 \mathbf{q} \quad (2.9)$$

$$FCT_c = \mathbf{t} \mathbf{g}^{0.2} (3.5 - 2.4 \mathbf{b}) \sin^{0.3} \mathbf{q} + B0.B1 \quad (2.10)$$

$$FCT_s = 1 + \mathbf{t}^{0.6} \mathbf{g}^{1.3} \mathbf{b} (0.76 - 0.7 \mathbf{b}) \sin^{2.2} \mathbf{q} \quad (2.11)$$

$$FCT_c = 2.6 \mathbf{b}^{0.65} \mathbf{g}^{(0.3-0.5 \mathbf{b})} \quad (2.12)$$

em que *B0* e *B1* estão definidos no *Apêndice C*.

Além das equações o trabalho traz a compilação dos principais resultados de ensaios em laboratório, para juntas Y, X e K, levantados até o ano de sua publicação.

CAPÍTULO 3

JUNTAS TUBULARES SOLDADAS

3.1 Introdução.

Em benefício do melhor entendimento do trabalho, o problema estudado será apropriadamente definido neste capítulo. Para levar a cabo essa tarefa serão examinados os elementos básicos que influenciam a distribuição de tensões em juntas tubulares soldadas, a saber: a geometria da junta e os carregamentos nela aplicados. Sob a luz dos objetivos estabelecidos no capítulo 1 será utilizada a geometria tipo Y, definida a seguir, para representar as juntas tubulares soldadas.

3.2 Características Geométricas de Juntas Tubulares Soldadas.

A classificação mais utilizada para juntas tubulares simples*, e que será adotada nesse trabalho, é baseada na geometria da junta, identificada com a letra do alfabeto a que se assemelha. Conforme ilustrado na Figura 3.1 existe uma variedade de juntas, por exemplo, T, X, K, Y e outras formadas pela junção de duas das juntas citadas configurando, assim, as juntas KT, DT, YT, etc. Esse critério de classificação não é o único. A norma API⁹, por exemplo, exige que na definição do tipo de junta sejam considerados os aspectos geométricos e também os carregamentos típicos aos quais a junta será submetida.

* uma junta tubular é dita simples quando todos os tubos que a compõem estão no mesmo plano, sem que haja *overlap* (intersecção) dos membros secundários (quando houver mais de um) e sem a utilização de borboletas ou qualquer outro tipo de reforçador¹⁹.

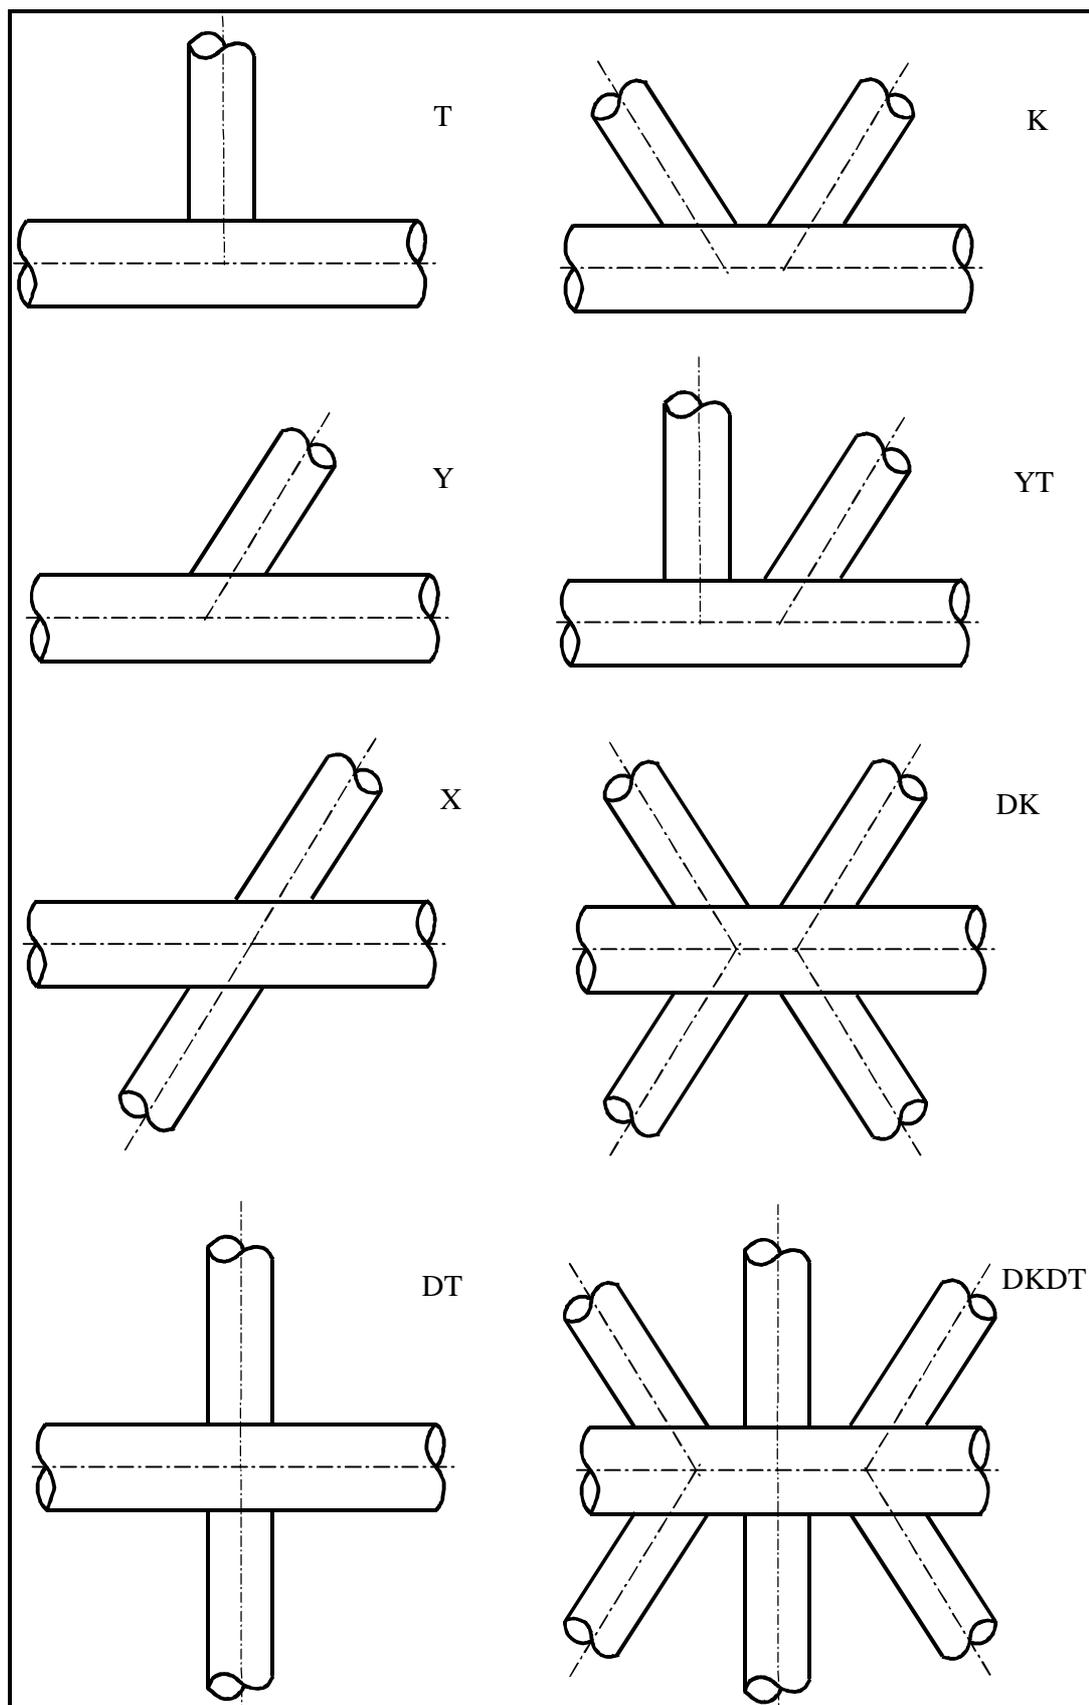


Figura 3.1 – Nomenclatura dos Principais Tipos de Juntas Tubulares Soldadas.

As dimensões geométricas básicas que descrevem as juntas Y estão identificadas na Figura 3.2, reproduzida do capítulo 1 a título de facilitar o acompanhamento do texto. Além dos diâmetros externos (D e d) e das espessuras (T e t), respectivamente dos tubos primário e secundário, são importantes o comprimento do tubo primário (L) e o ângulo (θ) entre os tubos.

O cálculo do FCT em juntas tubulares soldadas fica melhor equacionado se as variáveis geométricas forem tomadas na forma de relações adimensionais¹. A utilização de adimensionais facilita o processo de descrição das juntas permitindo extrapolar resultados obtidos com modelos reduzidos e também comparar ensaios em bancos de prova e modelos numéricos (MEF), independentemente das dimensões utilizadas. No caso específico das juntas Y são definidos os parâmetros adimensionais a , b , t , e g

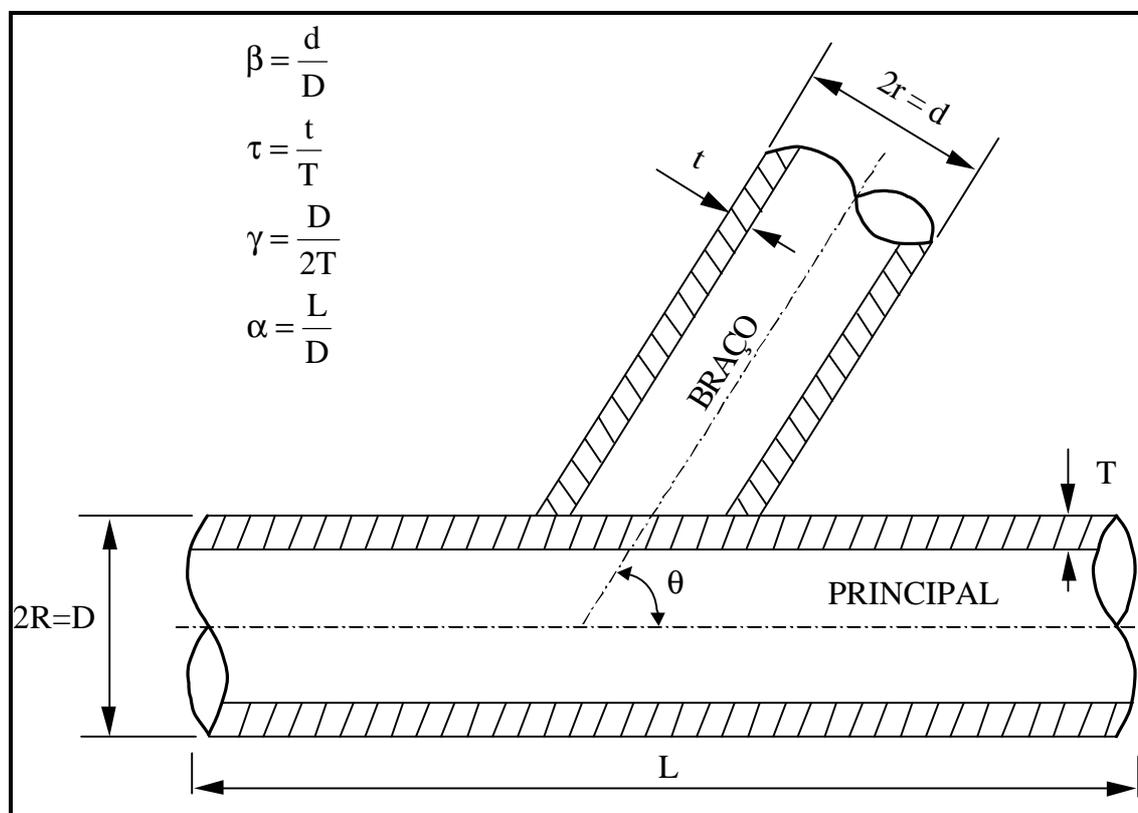


Figura 3.2 – Representação Esquemática de uma Junta Y Típica.

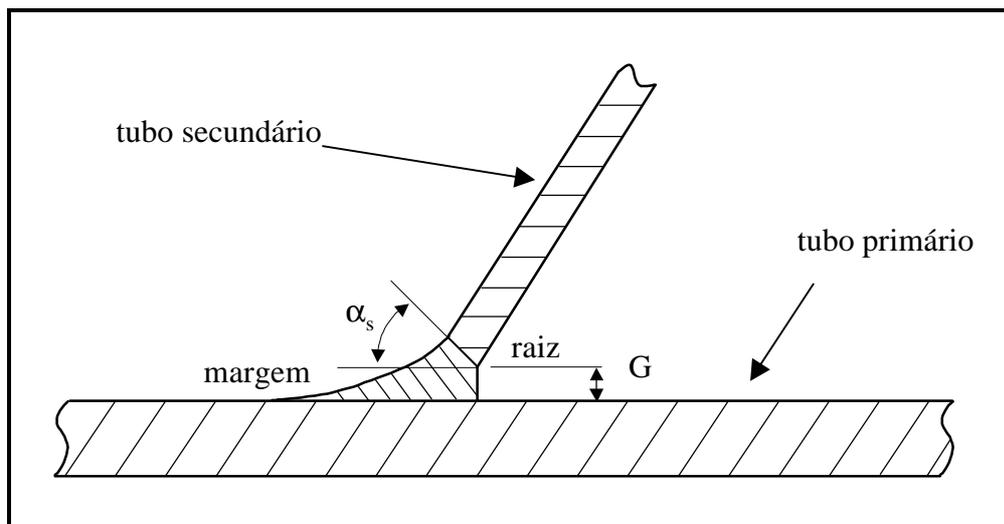


Figura 3.3 – Parâmetros Adimensionais da Geometria do Cordão de Solda.

No modelo elaborado por Massaroti²⁰ a inclusão da geometria do cordão de solda no modelo de cálculo do FCT foi representada pela distância entre os dois tubos (G) e pelo o ângulo de chanfro (α_s), mostrados na Figura 3.3. A distância G foi colocada sob a forma G/t para manter compatibilidade com os outros parâmetros geométricos, definidos na forma de adimensionais.

3.3 Condições de Contorno e Carregamentos em Juntas Tubulares Soldadas.

Para avaliar a influência do comprimento e das condições de contorno adotados para o tubo principal no cálculo do FCT é necessário, primeiramente, analisar o mecanismo de flexão local das paredes dos tubos primário e secundário.

Os momentos fletores atuantes em cada lado da união soldada, como esforços internos definidos na teoria simples de viga, causam tensões de membrana que, por definição, são constantes ao longo das espessuras das paredes. Além disso, tais tensões de membrana atuam como carregamentos localizados que provocam flexão local dessas

paredes. Portanto, os momentos fletores são responsáveis por duas componentes distintas de tensões: de membrana e de flexão.

Assim, como a concentração de tensões está relacionada com o efeito de flexão local na união soldada, depreende-se que o FCT deva depender da magnitude dos momentos fletores. Com isso, se o montante de sollicitação interna por momento fletor depende dos comprimentos dos membros tubulares pode-se esperar que, para um certo caso de carregamento, essa dependência seja evidenciada no cálculo do FCT.

Foram analisados dois casos de carregamento*: o primeiro é uma força axial (FNP), aplicada no membro secundário na direção do eixo de revolução que o define; o segundo, é um momento fletor aplicado no membro secundário perpendicularmente ao plano que define a junta. Esse caso é conhecido como momento fletor no plano (MNP).

Nessas condições, examinando os dois casos de carregamentos utilizados nesse trabalho, FNP e MNP, ilustrados na Figura 3.4, conclui-se que apenas o caso FNP tem esforço sollicitante interno por momento fletor dependendo do comprimento do membro principal. Logo, o parâmetro a é relevante apenas para o caso FNP.

A rigor, na maioria dos trabalhos sobre o cálculo de FCT baseados em ensaios ou em simulação numérica as condições de contorno utilizadas nas extremidades do tubo primário não são aclaradas. No trabalho de Massaroti, para as duas condições de carga, foram adotadas extremidades engastadas para o membro principal.

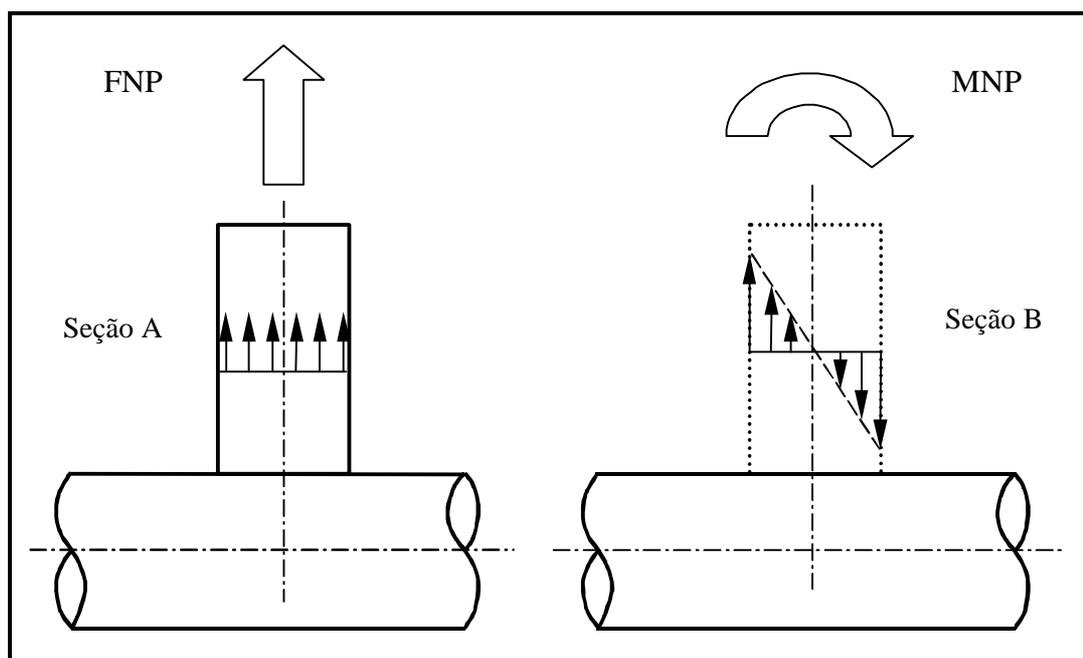


Figura 3.4 – Casos de Carregamentos Analisados com o Modelo RNA.

Admitiu-se, assim, que essas extremidades estão suficientemente longe da união soldada, evitando a influência da deformação local no engaste sobre as tensões naquela união.

Também inexistente dependência do comprimento do membro secundário para quaisquer dos casos de carregamento. Conforme ilustrado na Figura 3.4, pode-se aplicar um conjunto de forças na extremidade do tubo secundário de modo que a distribuição das tensões de membrana seja a mesma em quaisquer seções A e B.

3.4 Tensões em Juntas Tubulares Soldadas.

A complexidade da estrutura de uma plataforma pode ser ilustrada com o auxílio da Figura 3.5. Igualmente complexa é a distribuição de tensões na estrutura, com amplificação de até 20 vezes no valor da tensão nas juntas e gradientes de tensão

* Três carregamentos são usualmente estudados. Não foi incluído nesse trabalho o caso de momento fletor fora do plano.

igualmente elevados. Para um melhor entendimento da acentuada variação das tensões nas juntas tubulares é conveniente analisar os fatores que introduzem tensões na estrutura.

Nesse sentido, as causas das tensões nas juntas tubulares são usualmente separadas em três parcelas. A primeira delas, chamada de *tensão nominal*, corresponde aos esforços na junta quando se analisa a estrutura como um reticulado representado por vigas; não são considerados, portanto, efeitos localizados de ordem geométrica ou de concentração de tensões devido à geometria das ligações. Essas tensões são comumente obtidas através do cálculo matricial de estruturas, em que a estrutura pode ser analisada, por exemplo, por elementos de viga.

Outra contribuição importante para as tensões nas juntas advém da necessidade de manter a compatibilidade geométrica entre tubos contíguos sob a ação das cargas aplicadas. Essa continuidade da estrutura, formada por um tubo cortado unido à parede externa de outro, serve para transmitir os carregamentos do tubo secundário para o tubo primário. Sob o carregamento de uma força axial atuando no membro secundário a diferença das rizezas, axial do secundário e radial do primário, faz com que este último sofra deformações localizadas, conforme ilustrado na Figura 3.6. Além disso, também por conta da elevada rigidez do tubo secundário, praticamente todos os pontos de contato com o tubo primário têm o mesmo deslocamento para aquele carregamento. Dessa forma, sendo a rigidez na sela maior do que na coroa aparecem, para esse tipo de carga, elevados gradientes de tensão na região da junção dos tubos. Essas tensões, denominadas *tensões de deformação*, são localizadas e incluem ainda o efeito do aumento local de rigidez provocado pela presença do cordão de solda.

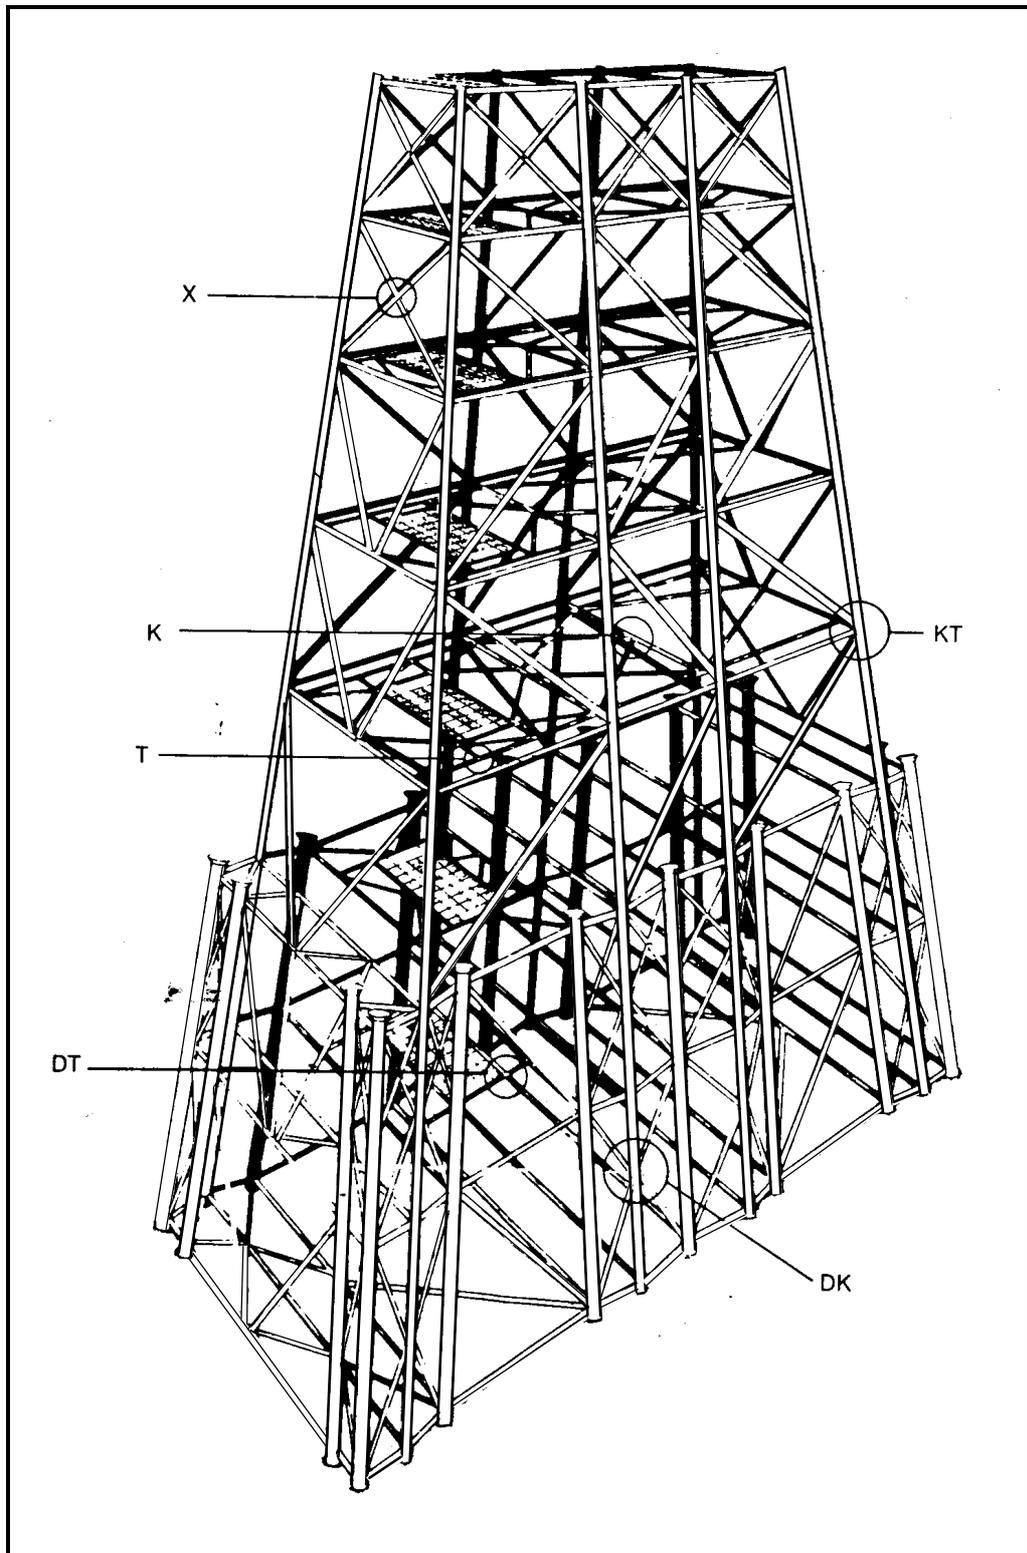


Figura 3.5 – Exemplo de Plataforma Fixa.

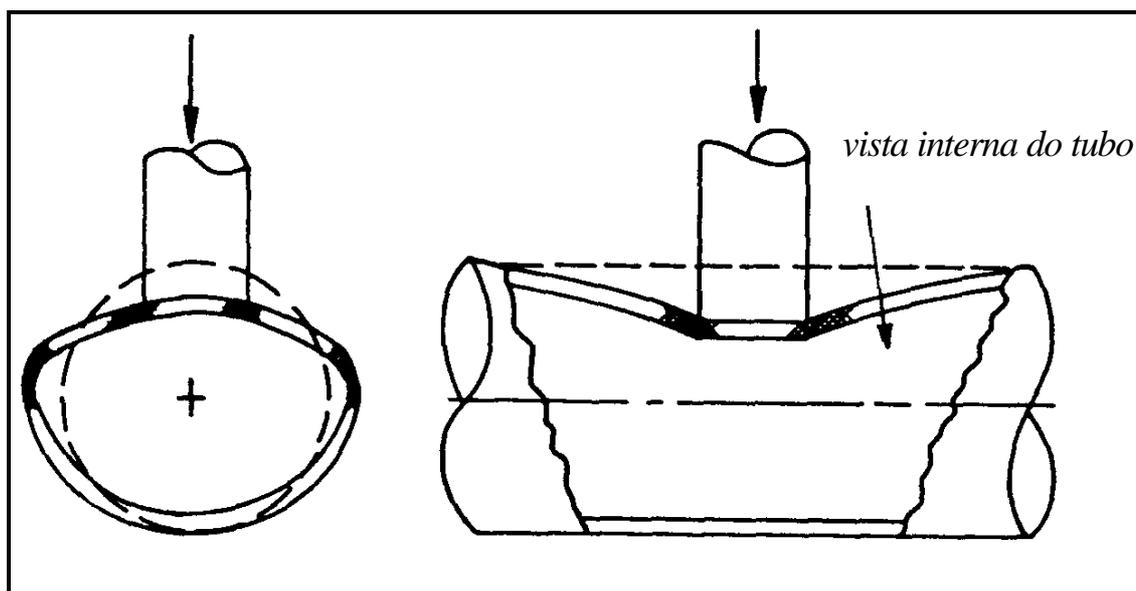


Figura 3.6 – Deformações no Primário sob Ação de Carga Axial no Secundário.

A terceira parcela relevante, chamada *tensão de entalhe*, está associada com o processo de soldagem. Essas tensões são devidas às imperfeições e descontinuidades extremamente localizadas na geometria da solda, acarretando elevados gradientes em pontos isolados da junta soldada.

3.5 Definição de Tensão Crítica (*hot spot stress*).

Segundo Branco¹³, a *tensão crítica* é a tensão na superfície exterior do pé do cordão de solda e ocorre numa região conhecida como *região crítica*. Essa tensão pode ser determinada por análise numérica através de um modelo de elementos finitos ou experimentalmente através de *strain gages*. Devido às limitações físicas dos *strain gages* e também ao fato de que comumente não se consideram os efeitos geométricos produzidos pelo cordão de solda no cálculo da tensão crítica, sua utilização exige uma extrapolação dos valores obtidos nas proximidades do cordão de solda até o pé do cordão, conforme exemplificado na Figura 3.7.

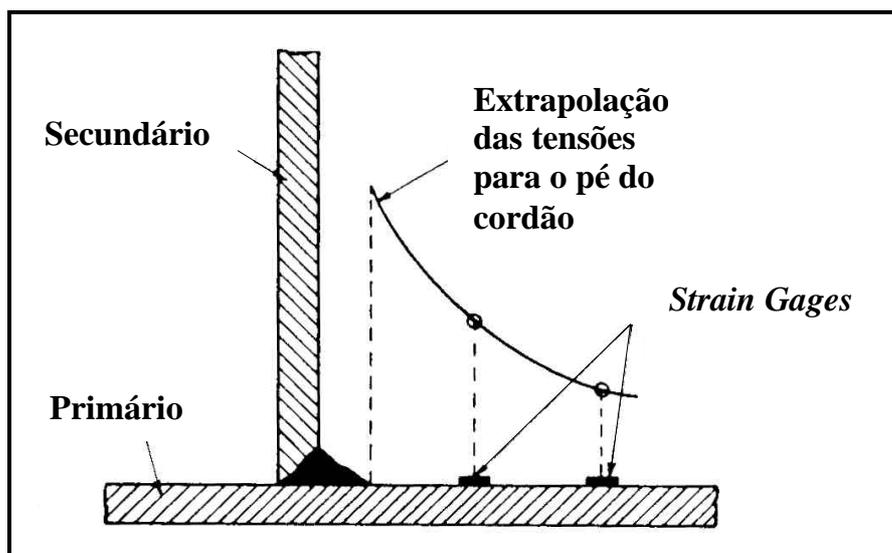


Figura 3.7 – Extrapolação das Tensões para o Pé da Solda.

A partir de testes experimentais executados nos laboratórios da *DnV*, Gibstein¹⁰ propôs uma definição para a tensão crítica considerando os efeitos geométricos do cordão de solda. Nessa definição foi considerada como tensão crítica o maior valor obtido no cordão de solda, sem o efeito da tensão de entalhe.

A definição para tensão crítica aqui adotada vai ao encontro daquela investigada por Gibstein¹⁰, incluindo também o efeito geométrico do cordão de solda, conforme ilustrado na Figura 3.8.

Dessas considerações decorre o conceito de FCT aqui adotado. Calculadas as tensões crítica — incluindo o efeito da geometria do cordão de solda — e nominal no tubo secundário o FCT é a razão, maior que um, entre os valores dessas tensões. Assim, para uma *tensão nominal* unitária o valor de *tensão crítica* calculado já é o próprio FCT.

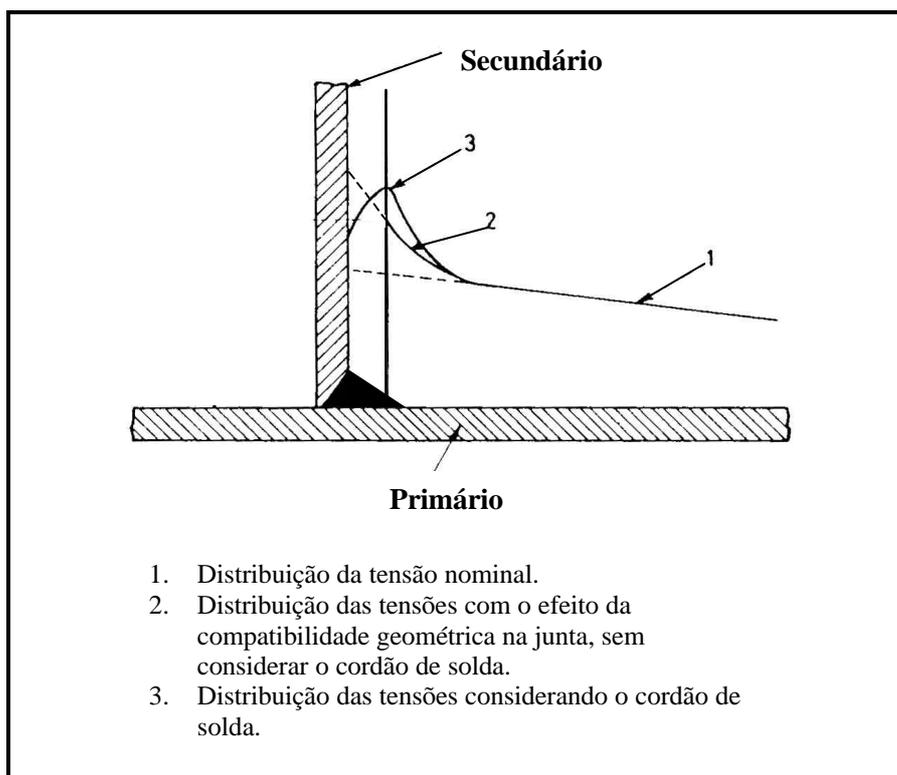


Figura 3.8 – Distribuição de Tensões na Região do Cordão de Solda.

3.6 Conjunto de Dados para Treinamento do *Modelo RNA*.

Massaroti²⁰ utilizou as variáveis adimensionais b , t , g , a , q , a_s e G/t para levantar um conjunto de valores de FCT, obtidos através de simulação numérica pelo MEF, utilizando o programa de computador ALGOR^{® 52}. Foram considerados 252 modelos de elementos finitos, variando-se os adimensionais nas faixas de valores apresentadas na Tabela 3.1. Ocorre que, além dos pontos de máxima tensão, o programa fornece os valores de tensão em outros pontos do modelo, particularmente, ao longo do comprimento do cordão de solda.

Nesse contexto, foram incluídos no conjunto de dados os valores calculados em 41 pontos ao longo do comprimento do cordão de solda*. Para descrever a posição de cada ponto foi incorporada ao problema uma nova variável (ξ) na forma de porcentagem do comprimento do cordão, conforme ilustrado na Figura 3.9. O *modelo RNA*, portanto, será treinado não apenas para descrever a posição do FCT mas, também, para representar a distribuição das tensões ao longo do cordão de solda.

Conforme foi mostrado no item 3.3 o comprimento do tubo primário não exerce influência no cálculo do FCT para o caso MNP. Dessa forma serão considerados, para este caso de carregamento, sete adimensionais, excluindo-se o parâmetro a . Para o caso FNP serão consideradas as oito variáveis mostradas na Tabela 3.1.

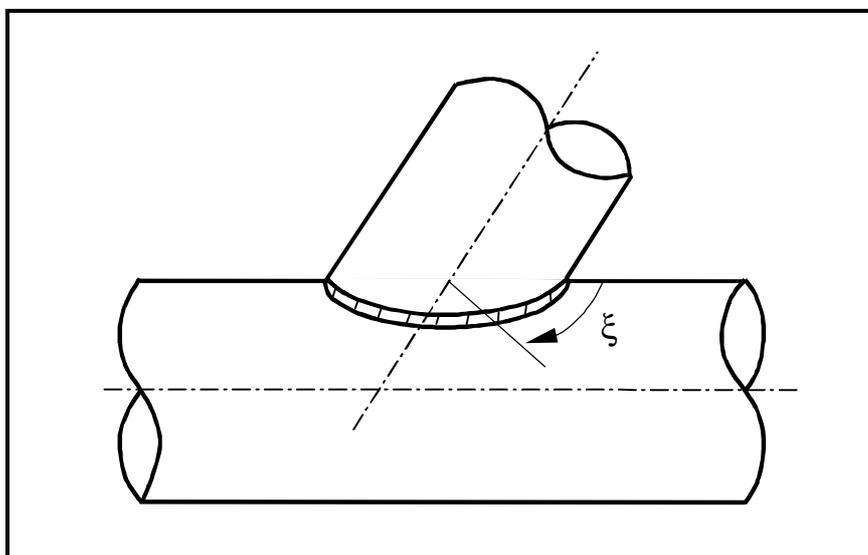


Figura 3.9 – Definição do Parâmetro ξ .

* uma descrição detalhada do levantamento das tensões nos pontos considerados está disponível no trabalho de Massaroti²⁰.

Tabela 3.1 –Parâmetros Utilizados no *Modelo RNA*

Parâmetro	Mínimo	Máximo
β	0.4	0.8
τ	0.4	0.8
γ	10	20
α	2.87	3.23
θ	40	90
G/t	0.1	0.8
α_s	10	45
ξ	0	100

Assim, foram levantados 10332 valores de tensões combinando-se as variáveis nas faixas indicadas na Tabela 3.1. Logo existem, para o *modelo RNA*, 10332 vetores, cada um com oito (ou sete) variáveis independentes, conforme descrito no parágrafo anterior, e uma variável dependente, a *tensão equivalente de von Mises (TEVM)*, calculada pelo programa ALGOR^{® 52} em cada um dos 10332 pontos.

CAPÍTULO 4

REDES NEURAIS ARTIFICIAIS

4.1 Breve Histórico.

O modelo básico de uma célula nervosa, também chamada de neurônio, está ilustrado na Figura 4.1. Nesse modelo o neurônio é formado por *dendritos*, ou seja, conexões pelas quais os sinais de outras células chegam até o neurônio. O corpo da célula é chamado de soma e o sinal de saída do neurônio acontece numa ramificação chamada *axônio*. A região entre o *axônio* de um neurônio e o *dendrito* de outro é chamada de *sinapse*.

O modelo de funcionamento desse neurônio é relativamente simples: os impulsos que chegam ao neurônio através de seus *dendritos* são “somados” e, caso a soma seja maior que um determinado valor limiar, o neurônio é ativado e dispara um impulso através do *axônio* para outras células.

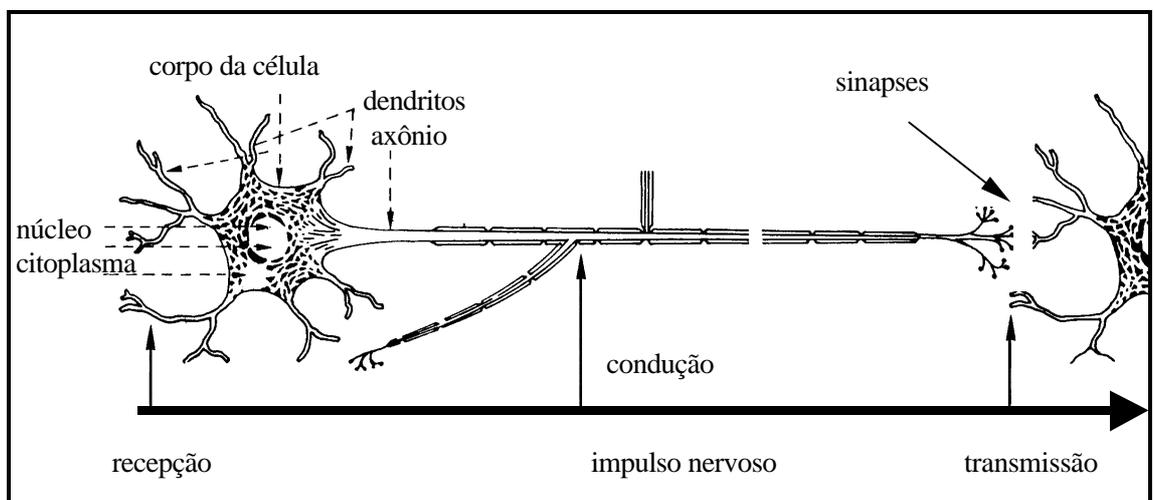


Figura 4.1 – Modelo de Transmissão de Impulso em Neurônios Biológicos.

O neurônio artificial — ou unidade de processamento — foi inspirado no neurônio biológico representado na Figura 4.1. Conforme mostrado na Figura 4.2, as *sinapses* foram representadas por pesos w_{ij} , os quais são responsáveis pela soma ponderada das entradas x_i . O núcleo da célula foi representado por uma função, chamada de *função de ativação*, usada para comparar as entradas x_i , ponderadas pelos pesos sinápticos w_{ij} , com o limiar do núcleo q_j . Por fim, o axônio foi representado pela saída y_j do neurônio.

A estrutura do neurônio artificial descrita no parágrafo anterior foi inicialmente apresentada por McCulloch e Pitts⁵³, que utilizaram a função degrau, ilustrada na Figura 4.3, para representar o núcleo. O modelo foi expresso por

$$y_j = F(u_j) = F\left(\sum_{i=1}^p w_{ij}x_i - q_j\right) \quad (4.1)$$

em que F é a função de ativação do neurônio, w_{ij} são os pesos, x_i ($i=1,2,\dots,p$) são as p entradas, q_j é o limiar do neurônio e y_j representa a saída do neurônio.

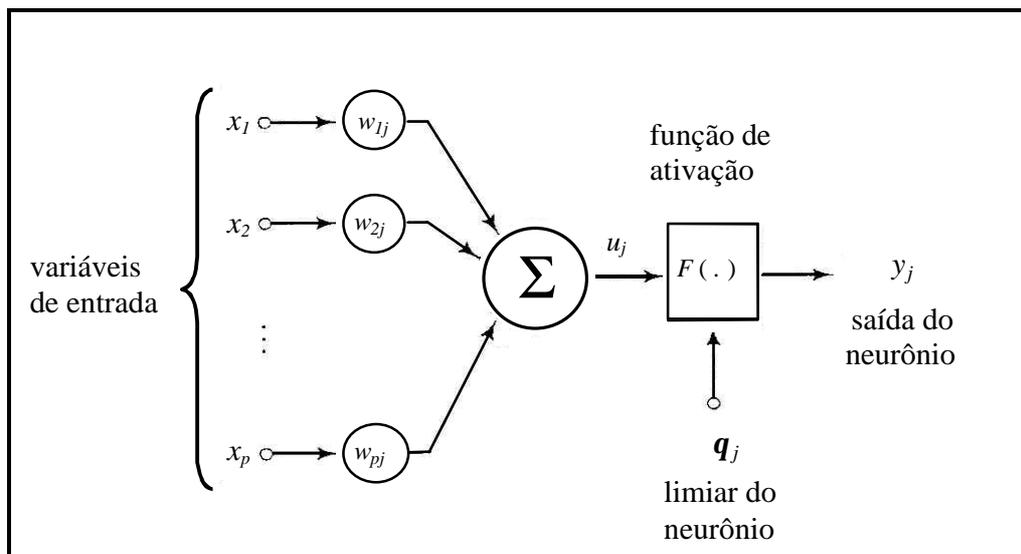


Figura 4.2 – Modelo Básico do Neurônio Artificial.

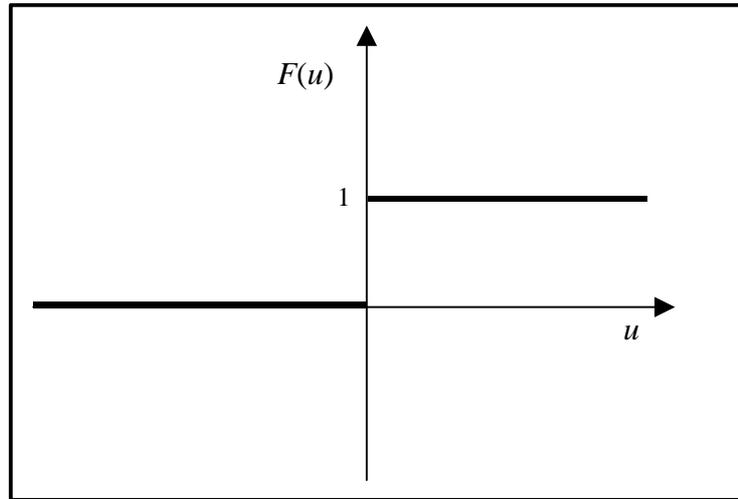


Figura 4.3 – Função de Ativação Utilizada por McCulloch e Pitts.

O limiar \mathbf{q}_j pode ser considerado através de uma entrada x_0 , igual a -1 , e o correspondente w_{0j} igual ao limiar \mathbf{q}_j . Assim, a equação 4.1 pode ser escrita como

$$y_j = F\left(\sum_{i=0}^p w_{ij}x_i\right) \quad (4.2)$$

em que

$$w_{0j} = \mathbf{q}_j \quad , \quad x_0 = -1$$

Desse modo, considerando a função degrau, a saída do neurônio é calculada por

$$\begin{aligned} y_j &= 0 & \text{se } \sum_{i=1}^p w_{ij}x_i < \mathbf{q}_j \\ y_j &= 1 & \text{se } \sum_{i=1}^p w_{ij}x_i \geq \mathbf{q}_j \end{aligned} \quad (4.3)$$

Esse modelo de neurônio artificial é a base de praticamente todas as redes neurais desenvolvidas a partir de então. As principais inovações no modelo de neurônio vieram com a utilização de novos tipos de função de ativação. Na Figura 4.4 estão ilustradas as principais funções utilizadas, conhecidas como *funções sigmóides*. Diferentemente da função degrau, essas funções são diferenciáveis em todos os pontos do domínio, característica importante nos principais processos de treinamento.

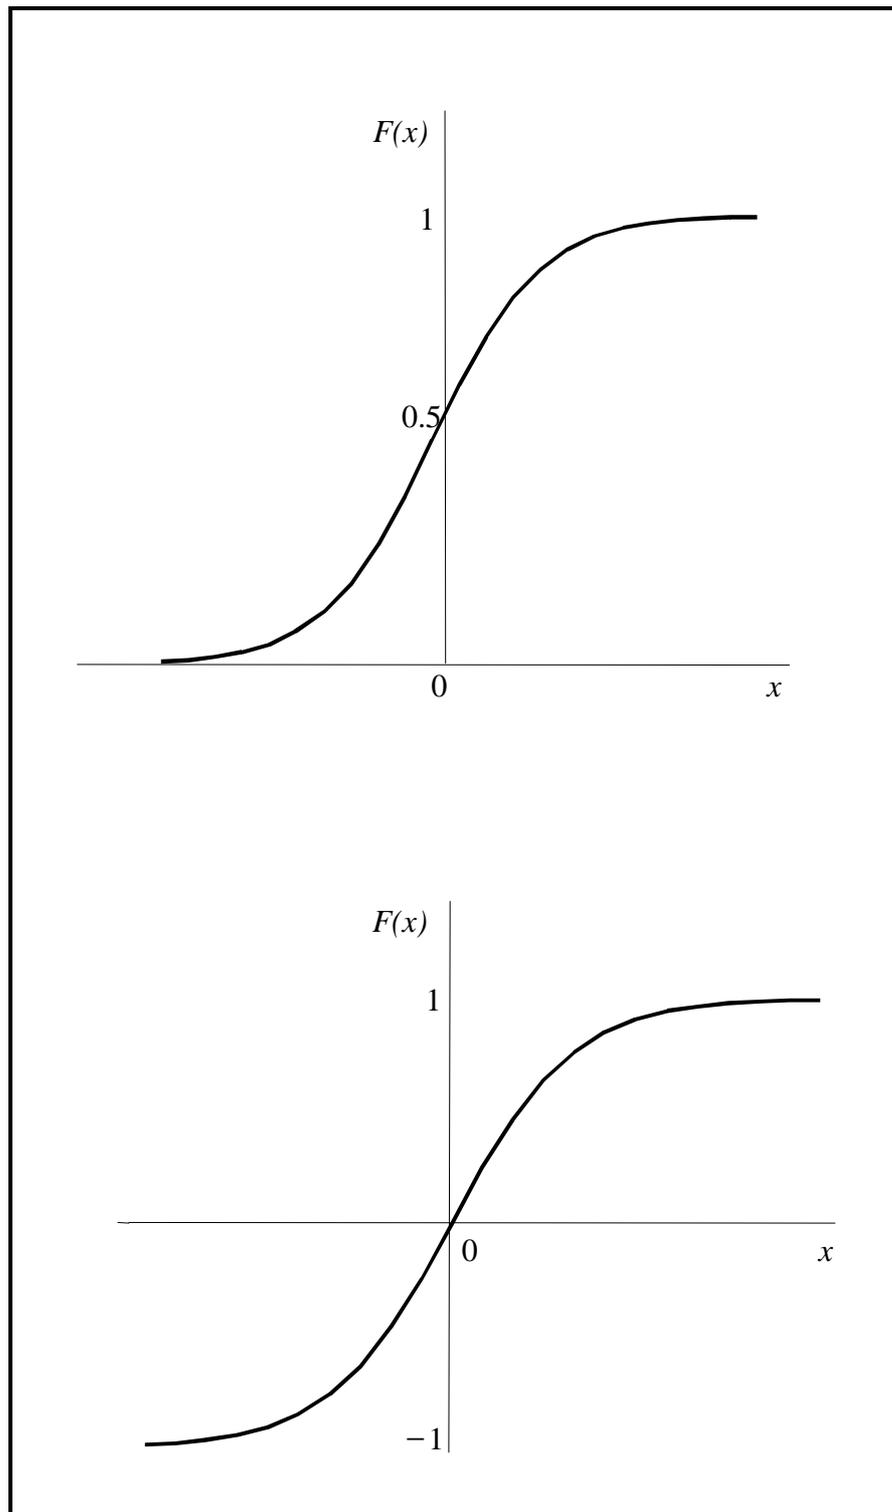


Figura 4.4 – Funções de Ativação Sigmóide:

- (a) função logística.
- (b) função tangente hiperbólica.

Nas últimas duas décadas os progressos mais significativos em RNA estão relacionados com o desenvolvimento de algoritmos de treinamento e com a elaboração de novas arquiteturas para as redes neurais, isto é, a forma como os neurônios estão estruturados dentro da rede. Essas duas frentes foram alavancadas paralelamente, uma vez que o modo como os neurônios de uma rede neural estão estruturados está intimamente ligado ao algoritmo utilizado para treinar a rede⁵⁴.

4.2 Treinamento de Redes Neurais Artificiais.

O trabalho de Hebb⁵⁵, pesquisador da área de neuro-fisiologia, introduziu um modelo para representar a característica de aprendizagem apresentada por sistemas biológicos. Para entender o modelo, considere o seguinte exemplo:

estágio 1: Um cachorro não saliva quando ouve um sino. No entanto, saliva quando vê a comida.

estágio 2: Por repetidas vezes, ao mesmo tempo em que a comida é mostrada ao cachorro, um sino é tocado.

estágio 3: Quando o sino é tocado, o cachorro saliva.

O experimento com o cachorro está ilustrado na Figura 4.5, na qual cada evento foi representado por um neurônio. Dessa forma, os neurônios *A* e *B* representam, respectivamente, o sino e a comida. O neurônio *C* representa o ato de salivar.

No *estágio 1* o peso w_{ac} não é forte o suficiente para ativar o neurônio *C*, o que não acontece com o peso w_{bc} . No *estágio 2* ocorre o processo de treinamento, em que o peso w_{ac} é “fortalecido” pelos estímulos externos. Finalmente, no *estágio 3*, o peso w_{ac} já é suficiente para ativar o neurônio *C*.

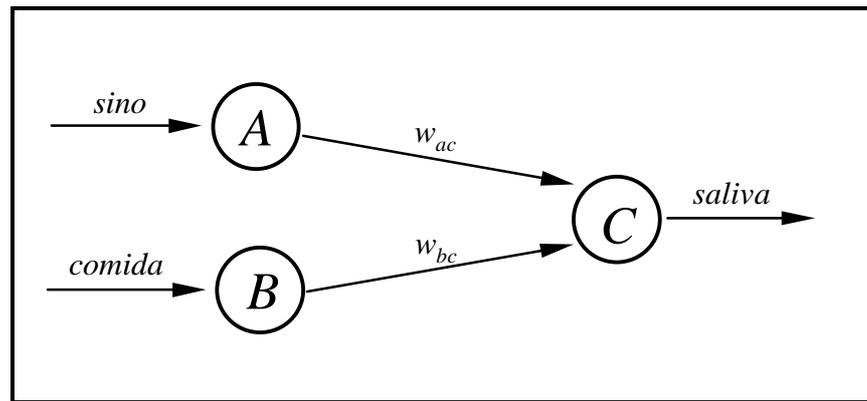


Figura 4.5 – Exemplo da Aprendizagem do Cachorro.

O modelo de aprendizagem descrito norteou os modelos de aprendizagem para as RNA. Convém precisar que *aprendizagem* ou *treinamento*, no âmbito das RNA, significa um processo de modificação e determinação dos pesos da rede, de modo que as saídas calculadas pela rede sejam iguais, ou muito próximas, das saídas reais.

Esse modelo de aprendizagem foi incorporado no trabalho de Roseblatt⁵⁶, no qual foi proposto um modelo para o cérebro e um procedimento para modificar os pesos. A unidade de processamento foi denominada *perceptron*.

A base do perceptron é o neurônio de McCulloch e Pitts⁵³, mostrado na Figura 4.1. O perceptron opera com uma combinação linear das entradas multiplicadas pelos respectivos pesos e com uma função de ativação do tipo degrau. Equacionando, obtém-se:

$$u = \sum_{i=1}^p w_i x_i - \mathbf{q} \quad (4.4)$$

com u , w , x , \mathbf{q} e p definidos na Figura 4.6.

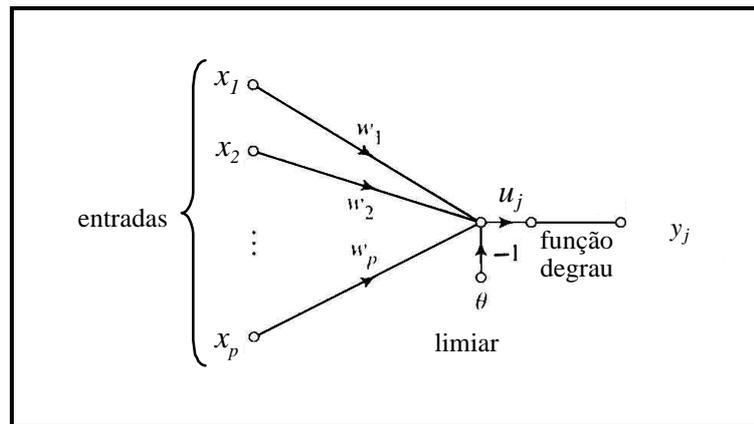


Figura 4.6 – Modelo do Perceptron de Rosemblatt.

O propósito do perceptron é distribuir um conjunto de treinamento, definido por vetores X_i , em duas classes, por exemplo, C_1 e C_2 . A regra de decisão para esta classificação é associar um ponto representado pelo vetor X_i à classe C_1 se a saída y do perceptron for +1 e, à classe C_2 , se a saída for 0.

Da equação 4.1 observa-se que as duas classes podem ser separadas por um *hiperplano* em um espaço p -dimensional dado por

$$\sum_{i=1}^p w_i x_i - q = 0 \quad (4.5)$$

Como exemplo, para o caso de duas variáveis, x_1 e x_2 , o separador de decisão é uma reta, conforme ilustrado na Figura 4.7.

Os valores dos pesos e do limiar são facilmente determinados para uma ou duas variáveis no vetor de entrada e para poucos pares de treinamento. Caso contrário, a determinação dos pesos é feita pelo algoritmo iterativo proposto por Rosemblatt⁵⁶, apresentado no *Apêndice B*.

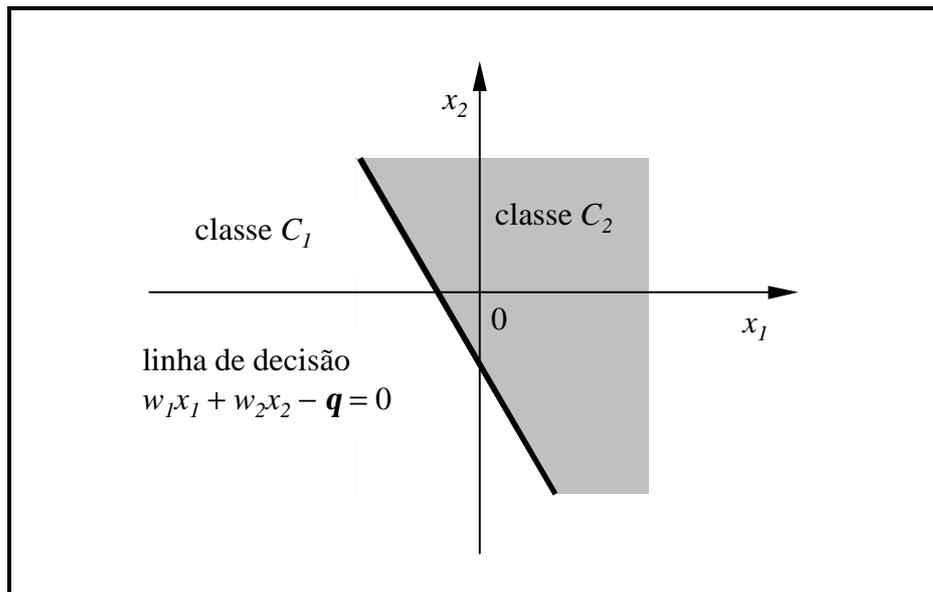


Figura 4.7 – Duas Classes Linearmente Separáveis com Duas Variáveis de Entrada.

Widrow⁵⁷ desenvolveu um modelo de neurônio* em que a saída y do neurônio é simplesmente a combinação linear das entradas, ou seja,

$$y = \sum_{i=1}^p w_i x_i \quad (4.6)$$

A modificação no modo de calcular a saída y do neurônio não trouxe nenhum ganho significativo na forma de representar o neurônio. A principal contribuição do *ADALINE*, todavia, foi o princípio de treinamento desenvolvido, denominado *regra delta*[†].

Essa regra, ilustrada no diagrama de bloco apresentado na Figura 4.8, é definida, para uma iteração n , pelas seguintes equações:

* o modelo foi chamado de *ADALINE*, acrônimo, na língua inglesa, para *adaptive linear element*

† o desenvolvimento matemático da regra delta está apresentado no *Apêndice B*.

$$y(n) = \sum_{i=1}^p w_i(n)x_i(n) \quad (4.7)$$

e

$$w_k(n+1) = w_k(n) + \mathbf{h}[d(n) - y(n)]x_k(n) \quad k = 1, 2, \dots, p \quad (4.8)$$

em que \mathbf{h} é denominado taxa de aprendizado, w é o peso, x é o vetor de entrada e d e y são, respectivamente, os valores desejado e calculado pela rede.

É importante mencionar que a comparação do valor calculado pela rede com o valor desejado exige que este último seja conhecido. Esse tipo de treinamento em que o valor calculado pela rede é comparado com o valor desejado é chamado de *treinamento supervisionado*. Por outro lado, quando não existe um valor desejado, como é comum em problemas de classificação, o treinamento é denominado *não-supervisionado*.

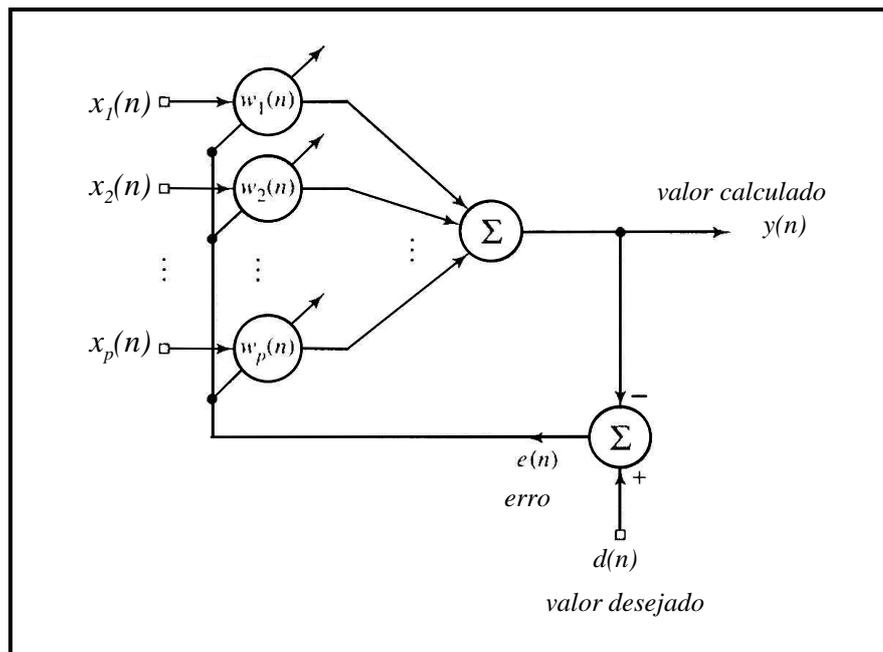


Figura 4.8 – Fluxograma do Treinamento do ADALINE

Outro aspecto importante do treinamento das RNA diz respeito à atualização dos pesos. Na *regra delta* estabelecida por Widrow⁵⁷, a atualização dos pesos é realizada após a apresentação de cada *par de treinamento* à rede. Esse método é conhecido como treinamento *on-line*. Por outro lado, a atualização também pode ser feita depois que todos os pares de treinamento tiverem sido apresentados no chamado treinamento *batch*. A opção por um ou outro depende do problema estudado. O treinamento *on-line* é usualmente mais rápido, principalmente quando os conjuntos de treinamento são grandes^{54,58}.

O modelo do *perceptron* e a *regra delta* de aprendizado trouxeram perspectivas no trato de problemas através de modelos neuronais na década de 60. O modelo era capaz de aprender tudo que pudesse representar.

Entretanto, em 1969, Minsky e Pappert⁵⁹ mostraram as limitações dos *perceptrons*, evidenciando que o *perceptron* não conseguia representar funções booleanas simples. De fato, os autores provaram que o *perceptron* podia representar somente funções linearmente separáveis, o que limitava sobremaneira o seu uso. No exemplo da função booleana *ou exclusivo (XOR)*, ilustrado na Figura 4.9, não é possível estabelecer uma reta que separe as saídas 0 das saídas 1. A opção de montar os neurônios em várias camadas esbarrava na inexistência, na época, de técnicas para treinamento desse tipo de rede.

A obra de Minsky e Papert desestimulou o apoio financeiro de empresas e agências de fomento à pesquisa e, como conseqüência, reduziu o desenvolvimento de novos trabalhos. Com isso, as pesquisas com redes neurais foram praticamente abandonadas até meados da década de 80.

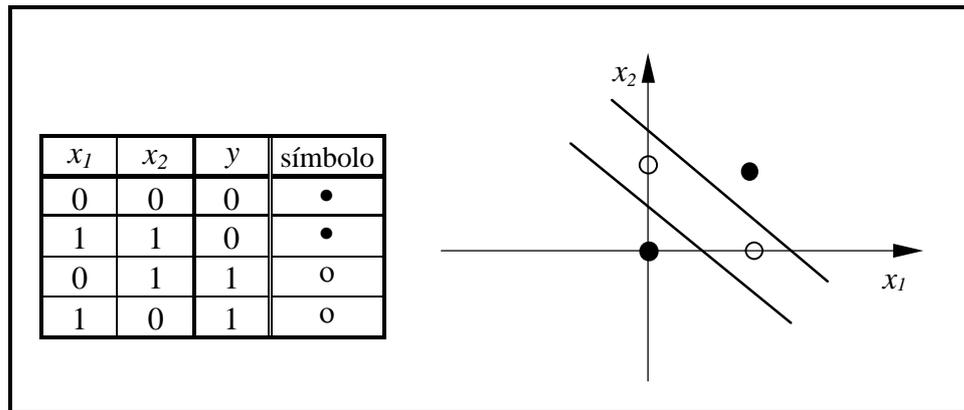


Figura 4.9 – Representação da Função Booleana OU exclusivo (XOR).

Em 1986 o algoritmo de treinamento de redes neurais multi-camadas, proposto por Rumelhart³², reacendeu a pesquisa no campo das redes neurais depois de um desinteresse de quase duas décadas*. Partindo da *regra delta*, Rumelhart estabeleceu um modo eficiente de alteração dos pesos de redes com camadas intermediárias entre a camada de entrada e a camada de saída, baseado no erro conhecido na camada de saída. Esse algoritmo, chamado de *regra delta generalizada* ou *algoritmo de retro-propagação*, está resumido na Tabela 4.1. O desenvolvimento matemático efetuado por Rumelhart³² está apresentado no *Apêndice B*.

* segundo Haykin⁵⁴, o algoritmo de retro-propagação foi enunciado, na mesma época, nos trabalhos independentes de Parker⁶⁰ e LeCun⁶¹. Além disso, depois da publicação do trabalho de Rumelhart foi descoberto que Werbos⁶², em 1974, já havia inventado o algoritmo de retro-propagação. Uma lacuna de 12 anos que dificilmente será recuperada, dado que não se sabe o que poderia ter acontecido...

Tabela 4.1 - Algoritmo de Retro-Propagação

Dado um conjunto de treinamento \mathbf{f} com L pares de treinamento.

$$\mathbf{f} = \{X_n, D_n\}_{n=1}^L$$

o treinamento de uma rede com K camadas, a partir do conjunto de treinamento \mathbf{f} , é feito pelo seguinte algoritmo:

1. Define-se um conjunto de pesos $W(0)$ e também uma taxa de aprendizado h .
2. Apresenta-se um par de treinamento (X_i, D_i) à camada de entrada e calculam-se as saídas de todos os j -ésimos neurônios da camada subsequente por

$$u_j = \sum w_i x_i - \mathbf{q}_j \quad (4.9)$$

$$y_j = F(u_j) \quad (4.10)$$

em que F é a função de ativação.

3. Repete-se o passo 2 para as camadas seguintes até que tenham sido calculadas as saídas de todos os neurônios da K -ésima camada.
4. Calculam-se o erro e o gradiente local para todos os neurônios da camada de saída por

$$e_j = d_j - y_j \quad (4.11)$$

$$\mathbf{d}_j = e_j F'(u_j) \quad (4.12)$$

5. Calcula-se o gradiente para todos os neurônios da camada anterior à camada de saída por

$$\mathbf{d}_j = F'(u_j) \sum_{l=1}^{J3} \mathbf{d}_l w_{jl} \quad (4.13)$$

em que $J3$ é o número de neurônios na camada de saída.

6. Repete-se o passo 5, sucessivamente, para todas as k camadas anteriores até a segunda camada. Observa-se que, aqui, $J3$ é o número de neurônios na camada posterior àquela em que estão sendo calculados os gradientes locais \mathbf{d} .
7. Calcula-se a correção para cada peso w_{ij} entre o neurônio i da camada k e o neurônio j da camada $k+1$ por

$$\mathbf{D}w_{ij} = h \mathbf{d}_j y_i \quad (4.14)$$

$$w_{ij}(1) = w_{ij}(0) + \mathbf{D}w_{ij} \quad (4.15)$$

com \mathbf{d}_j calculado pela equação 4.12 se o neurônio j pertencer à camada de saída. Caso contrário, \mathbf{d}_j é calculado pela equação 4.13.

8. Retorna-se ao passo 2 até que todos os pares de treinamento tenham sido apresentados.
9. Repetem-se os passos 2 a 8 até que algum critério de convergência tenha sido alcançado.

4.3 Arquiteturas de Redes Neurais Artificiais.

Recordando que o modelo do neurônio artificial foi inspirado no modelo do neurônio biológico descrito anteriormente, também o modo de conexão entre os neurônios para formar as redes neurais artificiais foi motivado pela estrutura na qual o neurônio biológico está inserido, isto é, o cérebro. O cérebro humano possui de 10^{10} a 10^{11} neurônios, cada um com 10^3 a 10^4 *dendritos*, ou seja, aproximadamente 10 bilhões de neurônios e 60 trilhões de conexões⁵⁴. Esse conjunto complexo e com alto grau de paralelismo pode realizar tarefas “simples” como reconhecimento visual e controle motor em um tempo da ordem de 100 a 200 milissegundos, ao passo que o computador mais rápido existente levaria dias para realizar até mesmo tarefas menos nobres*.

Com o objetivo de simular algumas características do cérebro, como aprendizagem e capacidade de generalização, os neurônios artificiais também foram interligados, formando as redes neurais artificiais. Duas arquiteturas básicas de conexão dos neurônios em RNA se destacam: a *recorrente* e a *feedforward*. Na rede recorrente, ilustrada na Figura 4.10, as saídas dos neurônios são utilizadas para alimentar as entradas. A rede de *Hopfield* é o tipo mais conhecido de redes recorrentes e é utilizada em problemas de otimização, memória associativa e para produzir conversores analógico-digitais³¹.

* Uma curiosidade histórica é que nos primórdios do que foi denominado “inteligência artificial” as preocupações eram com o desenvolvimento de modelos que pudessem executar tarefas que exigiam inteligência para ser executadas, tais como jogar xadrez e provar teoremas. Tarefas como reconhecimento visual, ou processamento da linguagem, facilmente executadas até por crianças, eram tidas como mais fáceis de serem implementadas e em pouco tempo estariam disponíveis. Ainda hoje, cerca de meio século depois, ainda não existem programas ou máquinas eficientes de reconhecimento visual nem de processamento da linguagem falada. Por outro lado, existem excelentes programas para se jogar xadrez.⁶³

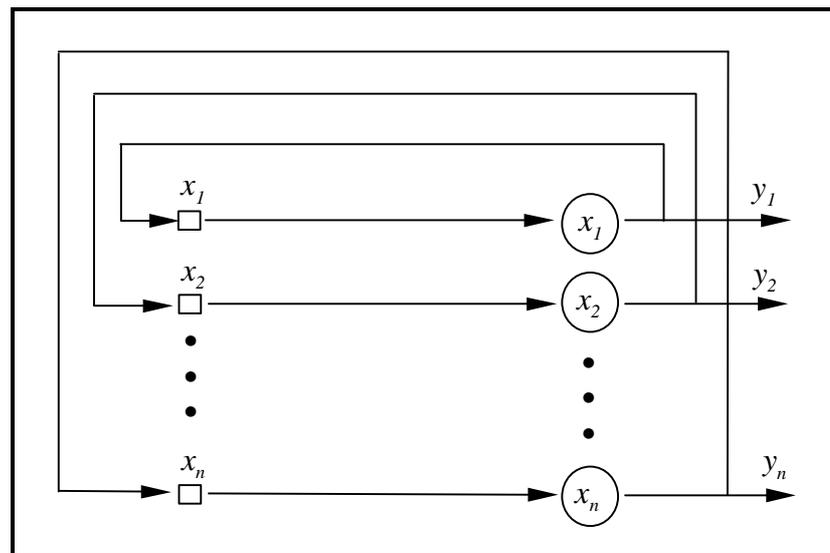


Figura 4.10 – Exemplo de Redes Recorrentes.

As redes do tipo *feedforward*, ilustradas na Figura 4.11, são compostas por uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas. Usualmente, todos os neurônios de uma camada são ligados aos neurônios da camada seguinte através de pesos sinápticos.

A função da camada de entrada é receber as variáveis independentes do vetor de treinamento. No *modelo RNA*, por exemplo, são necessários 8 neurônios na camada de entrada, um para cada parâmetro apresentado na Tabela 3.1.

O número de neurônios na camada de saída está diretamente ligado ao número de variáveis dependentes do problema analisado. No *modelo RNA* a tensão equivalente de von Mises (TEVM) aparece como única variável independente sendo necessário, então, somente um neurônio na camada de saída.

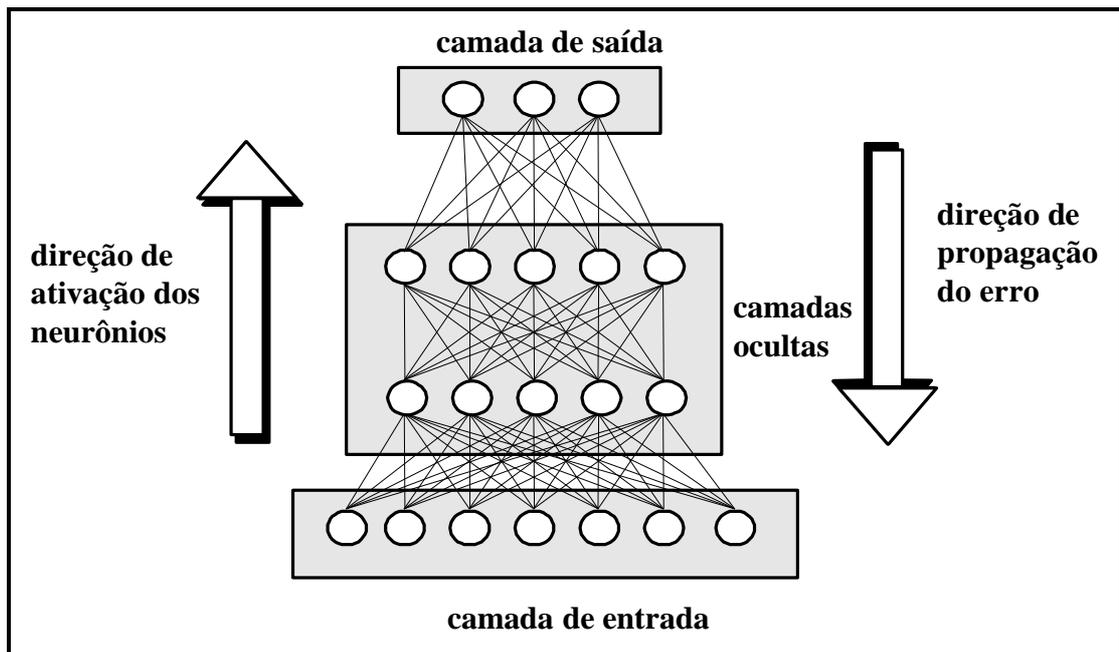


Figura 4.11 – Rede Neural Multi-Camadas.

Nas camadas ocultas não existe um número definido de neurônios; nem mesmo o número de camadas ocultas é pré-fixado. Embora teoricamente uma rede com apenas uma camada oculta possa aproximar qualquer função⁵⁴ muitas vezes o número de neurônios necessários para levar a cabo essa tarefa torna inviável o processo de treinamento. Nesse caso, considerar mais uma camada oculta pode diminuir o tempo de treinamento.

Segundo Welstead²⁹, as redes neurais do tipo *feedforward* correspondem a mais de 90% das aplicações com redes neurais existentes. O predomínio de aplicações com esse tipo de rede se deve a dois fatores principais⁶⁴.

1. são facilmente implementadas em programas de computador e também em “hardwares” dedicados;
2. são excelentes para aproximar funções.

Essas características pesaram na escolha das redes *feedforward*, treinadas com o algoritmo de retro-propagação, para representar a distribuição de tensões na junta soldada em função dos parâmetros geométricos apresentados na Tabela 3.1. Além disso, as RNA do tipo *feedforward* são ideais para representar processos determinísticos²⁹, como é o caso da distribuição de tensões em juntas soldadas.

4.4 Aspectos Importantes do Algoritmo de Retro-Propagação.

O algoritmo de retro-propagação é uma ferramenta poderosa no treinamento de RNA multi-camadas. À primeira vista sobra a impressão de que basta traduzir o algoritmo mostrado na Tabela 4.1 para uma linguagem de computador, executar o programa e aguardar os resultados. Na verdade, o processo é um pouco mais complicado e exige que alguns detalhes sejam observados no processo de treinamento.

Convém, pois, esclarecer esses detalhes, sempre que possível exemplificando com o problema tratado nesse trabalho.

4.4.1 Escalonamento dos Valores de Entrada e de Saída.

As funções de ativação mais utilizadas para definir os neurônios das redes neurais artificiais do tipo *feedforward* são as funções *logística* e *tangente hiperbólica*, ilustradas na Figura 4.4.

Conforme mostrado naquela figura os conjuntos *imagem* das referidas funções são, respectivamente, $]0,1[$ e $] -1,1[$. Dessa forma, é necessário redefinir as variáveis de saída da RNA, de modo que a comparação entre o valor de saída y calculado pela rede e o valor desejado d tenha algum significado. Do contrário, para um valor de tensão igual a 9.5, por exemplo, a rede não consegue minimizar adequadamente a diferença

entre o calculado e o desejado, uma vez que, em cada etapa do treinamento, o valor calculado estará entre os limites definidos pela função de ativação utilizada.

Com relação às variáveis de entrada o escalonamento é recomendado para facilitar a contabilização de cada variável pela rede. No problema aqui analisado, por exemplo, a posição em que a tensão é medida, representada pelo parâmetro \mathbf{x} , varia de 0% a 100%, ao passo que o parâmetro \mathbf{b} varia entre 0.4 e 0.8. Dessa forma, a contribuição de \mathbf{x} na soma ponderada da Equação 4.9 será mais significativa do que a contribuição do parâmetro \mathbf{b} . Uma vez que o fenômeno estudado é complexo não existe, a princípio, razão para favorecer um ou outro parâmetro, sendo mais razoável, então, redefinir os parâmetros para a mesma faixa de valores.

Outro aspecto relevante é que o escalonamento das variáveis de entrada ajuda a evitar a saturação do neurônio, ou seja, que o valor de saída do neurônio esteja nos extremos da função de ativação. Isso levaria a uma “paralisia” do treinamento da rede, pois as correções em cada iteração são significativamente pequenas.

Nessas condições, foram analisadas duas faixas de variação para as variáveis de entrada, com o objetivo de acelerar o treinamento da rede. Na primeira, as variáveis de entrada foram escalonadas entre 0 e 1; na segunda, entre -1 e 1 . Nas duas situações a faixa de escalonamento para as variáveis de saída foi a mesma, entre 0.1 e 0.9, dentro, portanto, da faixa de valores fornecidos pela função *logística* utilizada.

4.4.2 Taxa de Aprendizado (h) e Constante de Momento (a).

Na elaboração do algoritmo de retro-propagação, apresentado no *Apêndice B*, Rumelhart³² admitiu uma taxa de aprendizado h infinitesimal para desenvolver o

algoritmo de treinamento *on-line*. Essa taxa mede, em uma iteração qualquer, o tamanho do passo que será dado no sentido contrário do gradiente da função, conforme ilustrado na Figura 4.12. Um valor alto para h significa um passo grande naquele sentido, característica desejável para uma convergência mais rápida até o ponto de mínimo. Nem sempre, no entanto, a curva estudada é simples e um valor elevado de h pode levar a oscilações em torno do ponto de mínimo, aumentando o tempo de treinamento.

Na verdade, não existe uma forma única de definir a taxa de aprendizado e nem de como ela deve se comportar durante o treinamento. Várias sugestões estão disponíveis na literatura^{54,58}, mas é consenso que cada problema deve ser analisado separadamente. Nesse trabalho foi utilizada a seguinte expressão, sugerida por Cichocki⁵⁸

$$h_k = h_o \frac{1}{1 + \frac{k}{k_o}} \quad (4.16)$$

em que k_o é uma iteração a ser escolhida (tipicamente entre 100 e 500) e h_o é a taxa de aprendizado inicial.

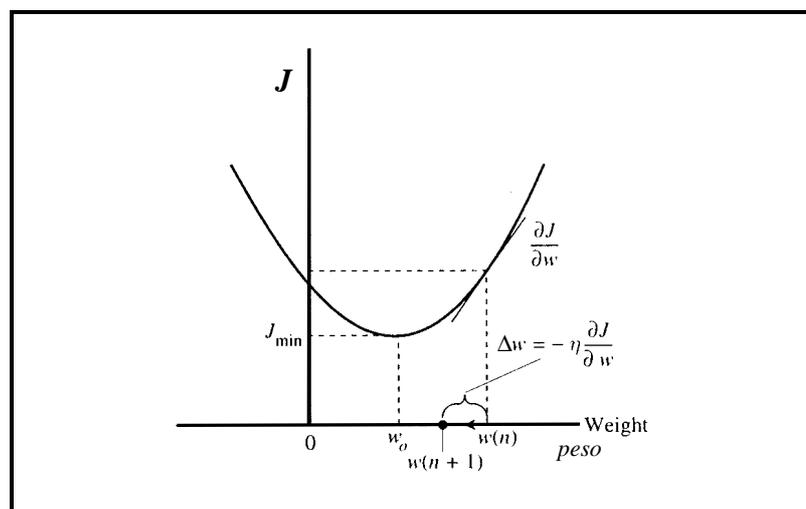


Figura 4.12 – Cálculo Iterativo do Mínimo da Função J pelo Método do Gradiente.

Com a Equação 4.16 a rede inicia o treinamento com uma taxa de aprendizado alta e praticamente constante e depois da k_o iteração a taxa decresce exponencialmente. Para o *modelo RNA* a taxa de aprendizado inicial \mathbf{h}_o estabelecida foi 0.85, ao passo que a taxa de treinamento \mathbf{h}_k foi alterada no decorrer do treinamento pela Equação 4.16.

Outra consideração feita por Rumelhart³² é a possibilidade de inclusão de um termo de *momento*, \mathbf{a} , na alteração dos pesos dada pelas Equações 4.14 e 4.15. Dessa forma a Equação 4.14, para a n -ésima iteração, pode ser reescrita como:

$$\Delta w_{ij}(n) = \mathbf{a}\Delta w_{ij}(n-1) + \mathbf{hd}(n)_j y_i(n) \quad (4.17)$$

em que \mathbf{a} é o termo de momento. O valor inicial de alfa também foi arbitrado em 0.85 e modificado durante o treinamento pela Equação 4.16.

4.4.3 Conjunto de Treinamento, Conjunto de Teste e Generalização.

Os parâmetros apresentados na Tabela 3.1, combinados, formam 10332 vetores, cada um associado a um vetor com o valor da *TEVM*. Cada par de vetores — $X = \{\mathbf{b}, \mathbf{t}, \mathbf{g}, \dots, \mathbf{x}\}$ e $Y = \{\mathbf{s}\}$ — é chamado de *par de treinamento*, ou seja, um ponto calculado da função que representa o fenômeno de distribuição de tensões na junta soldada. O conjunto formado por todos os pares de treinamento é denominado *conjunto de treinamento*.

Durante o treinamento, a RNA aprende a partir dos pontos da função incluídos no conjunto de treinamento. Depois de treinada, ou seja, depois de definido um conjunto de pesos que satisfaça um critério de convergência pré-definido, um *conjunto de teste* é apresentado à rede. Esse conjunto servirá para avaliar a capacidade de *generalização* da rede, ou seja, se ela fornece resultados aceitáveis para pontos não contidos no conjunto

de treinamento. Isso é importante, conforme exemplificado na Figura 4.13, pois evita que a rede “decore” os pontos do conjunto de treinamento, ou seja, forneça boa aproximação para os pares de treinamento mas não adquira as características básicas da função estudada.

É importante observar que essas considerações são válidas quando o conjunto de teste é gerado a partir da mesma população usada para gerar o conjunto de treinamento²⁹. Para garantir que os dois conjuntos sejam representativos do mesmo fenômeno, eles foram gerados aleatoriamente a partir do conjunto total de dados, obtido conforme descrito no capítulo anterior. Nesse trabalho, a divisão adotada foi de 70% para o conjunto de treinamento e 30% para o conjunto de teste.

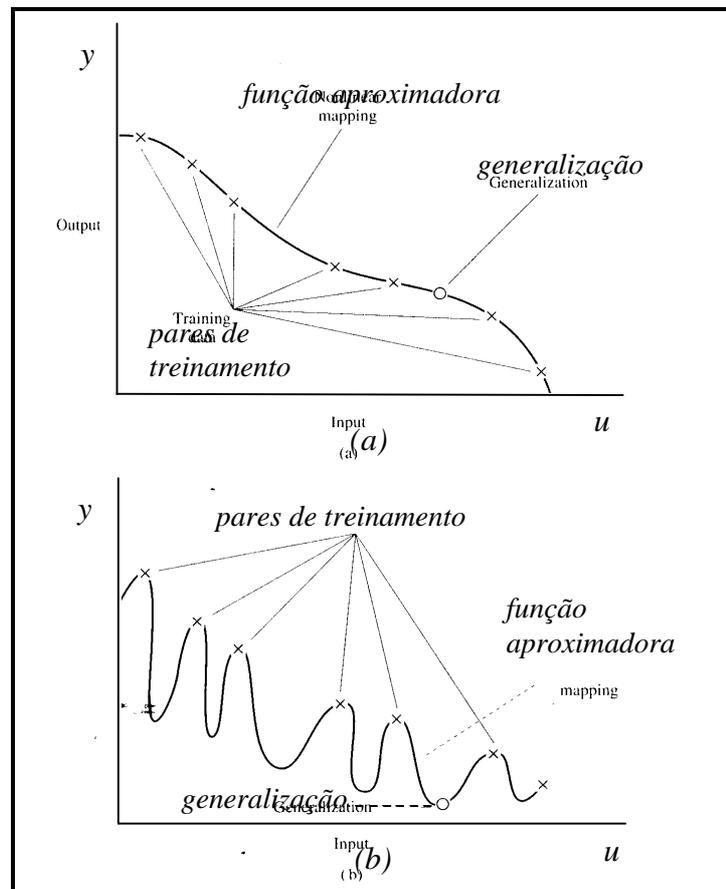


Figura 4.13 – Rede Treinada: (a) boa generalização. (b) generalização ruim.

4.5 Programa de Computador NEUROWELD.

Para avaliar a concentração de tensões em juntas soldadas através do *modelo RNA* foi desenvolvido um programa de computador, denominado NEUROWELD, com o objetivo de treinar e testar as redes neurais desenvolvidas para representar cada um dos casos de carregamento.

Basicamente o programa executa o algoritmo descrito na Tabela 4.1, sem perder de vista os detalhes mencionados nos itens 4.4.1 a 4.4.3. A formatação do arquivo de entrada de dados para o programa NEUROWELD está formalizada no *Apêndice A*.

Segundo alguns autores^{54,64} a apresentação dos pares de treinamento de modo aleatório pode diminuir significativamente o tempo de treinamento da rede. Para um conjunto de treinamento com mais de 7000 pontos torna-se um problema, do ponto de vista de ônus computacional, a geração aleatória da ordem de apresentação dos pares de treinamento. Isso porque cada vez que um novo par de treinamento é apresentado à rede é necessário verificar se o mesmo já não foi utilizado naquele *epoch* *.

Para evitar essa verificação foi elaborado um procedimento de apresentação aleatória dos pares de treinamento. A idéia central é utilizar um vetor auxiliar, que contenha a localização de todos os pares de treinamento, para “coordenar” a ordem de apresentação dos pares de treinamento. De um *epoch* para outro os valores de cada posição do vetor são trocados aleatoriamente, sem a necessidade de conferir os pares de treinamento já apresentados. Esse procedimento está detalhado no *Apêndice B*.

* um *epoch* corresponde à apresentação de todos os pares de treinamento em uma iteração.

Depois de treinar a rede o programa gera um arquivo com os pesos levantados durante o treinamento. É possível, também, levantar comparações dos resultados obtidos pela RNA com aqueles utilizados nos conjuntos de treinamento e de teste. Novas configurações de juntas podem ser analisadas pelo programa, desde que sejam verificadas as faixas de validade de cada parâmetro adimensional.

O programa foi desenvolvido na linguagem DELPHI e é executável na plataforma IBM-PC.

CAPÍTULO 5

DESENVOLVIMENTO DO *MODELO RNA*

5.1 Introdução.

Na busca das configurações finais de rede para cada caso de carregamento estudado, ou seja, da definição do número de camadas, número de neurônios em cada camada e dos pesos que definem as ligações entre os neurônios foram identificados vários fatores, alguns mais efetivos que outros, que influenciam no tempo de treinamento. Dado o cunho investigativo do trabalho foi decidido incorporar esses resultados no texto, uma vez que poderão delinear caminhos em pesquisas futuras. Serão analisados, assim, a utilização de um conjunto de treinamento menor, a influência da faixa de escalonamento das variáveis de entrada e também a definição da função resíduo. Para tanto, será utilizado o caso de carregamento FNP como conjunto de dados a ser representado pela RNA.

Por fim serão apresentadas as principais características de treinamento do *modelo RNA* para os dois casos de carregamento aqui analisados.

5.2 Treinamento com um Conjunto de Treinamento Menor.

O principal problema no tratamento de problemas com RNA é o elevado tempo de treinamento da rede^{29,30,32}. Inúmeros fatores contribuem para o elevado tempo de treinamento: número de neurônios e/ou de camadas insuficientes, conjunto de treinamento muito grande, paralisia do treinamento devido às deficiências do algoritmo utilizado, etc. Nesse contexto, foi analisada a idéia de diminuir o tempo de treinamento

utilizando-se um conjunto de treinamento menor. O objetivo, nesse caso, é tentar extrair as características do fenômeno em estudo a partir de um conjunto de treinamento reduzido. Assim, 30% do conjunto total foi definido como conjunto de treinamento e os 70% restantes como conjunto de teste.

Para verificar essa situação foi analisado o caso de carregamento FNP. Uma rede com duas camadas ocultas foi construída, a primeira com 15 neurônios e a segunda com 5. Depois de 40000 iterações, em um tempo de aproximadamente 8 horas, a rede ainda apresentava resultados díspares em pontos do conjunto de teste, conforme mostrado na Tabela 5.1. Nas Figuras 5.1 e 5.2 estão mostrados histogramas de diferenças para os conjuntos de treinamento e de teste, respectivamente. A diferença* foi definida como:

$$dif = \frac{d - y}{d} \quad (5.1)$$

sendo d o valor desejado, calculado pelo MEF, segundo Massaroti²⁰, e y o valor calculado pelo *modelo RNA*.

Na Tabela 5.1 estão apresentados alguns pontos do conjunto de teste nos quais foram verificados diferenças absolutas maiores que 10%. Essas diferenças foram calculadas através da Equação 5.1. No cálculo das diferenças relativas foi considerado no denominador da Equação 5.1 o valor máximo de *TEVM* observado no conjunto de dados, igual a 11.05 para o caso FNP. Obtém-se, assim, uma forma de verificar a importância da diferença absoluta observada. No caso do ponto 2, por exemplo, o erro absoluto de 13,43%, não é, do ponto de vista de engenharia, uma diferença significativa.

* serão utilizadas nesse texto, indistintamente, os termos *diferença* e *erro* para definir o valor obtido na Equação 5.1, a despeito das controvérsias sobre a nomenclatura mais adequada.

No caso dos pontos 12 e 15, no entanto, é necessário mais cuidado na utilização dos valores de tensões obtidos.

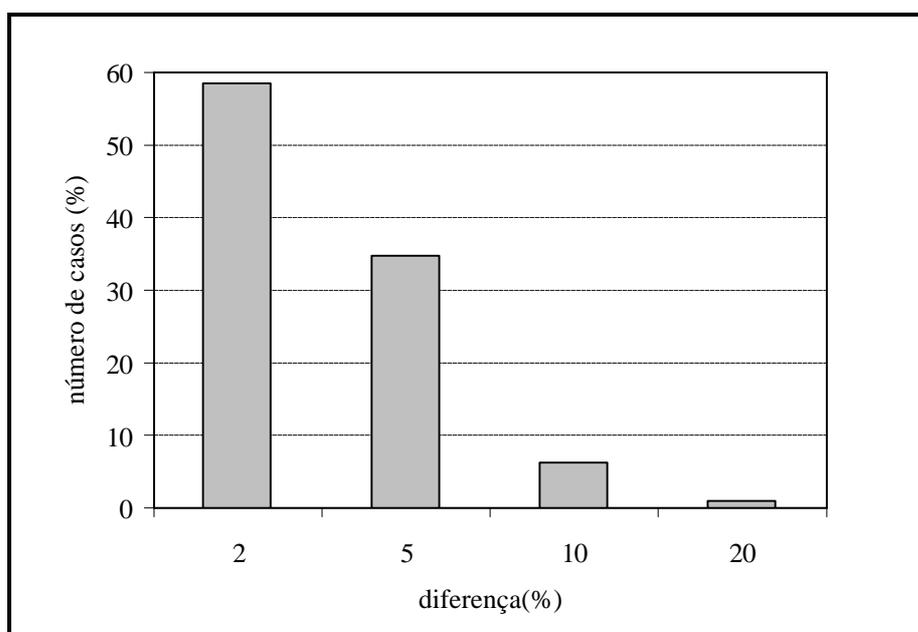


Figura 5.1 – Diferença para o Conjunto de Treinamento com 3100 Pontos.

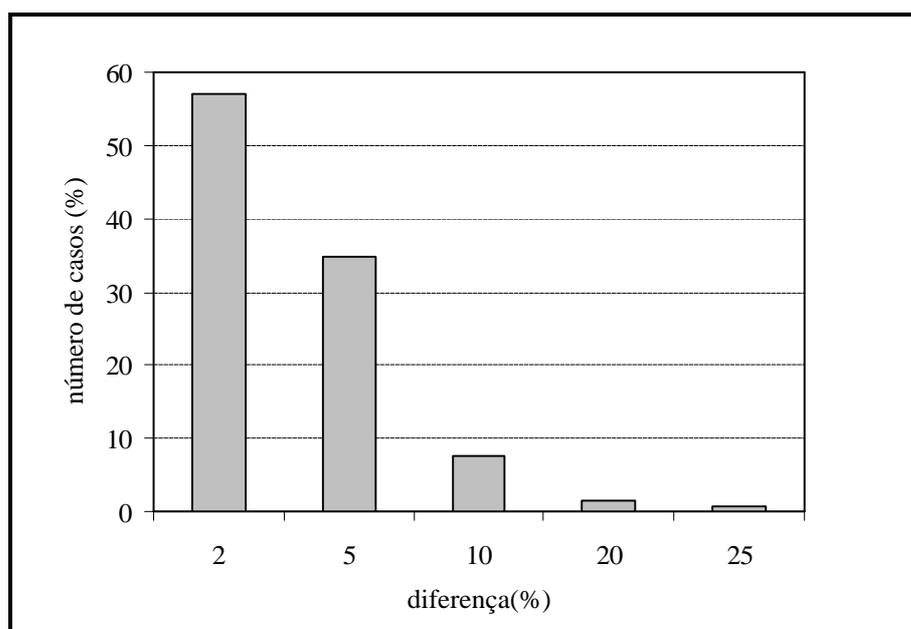


Figura 5.2 – Diferença para o Conjunto de Teste com 7232 Pontos.

Tabela 5.1 – MEF x RNA: Conjunto de Teste com 7232 Pontos.

ponto	TEVM		Diferenças	
	RNA	MEF	Relativa	Absoluta
1	3.001	2.684	2.87	11.8
2	0.963	1.112	-1.36	-13.43
3	1.526	1.350	1.6	13.06
4	2.139	1.847	2.65	15.79
5	1.819	1.584	2.13	14.82
6	1.541	1.375	1.5	12.05
7	1.798	1.522	2.5	18.13
8	1.447	1.679	-2.1	-13.81
9	1.802	2.022	-2	-10.89
10	2.065	1.870	1.77	10.41
11	1.954	2.212	-2.34	-11.64
12	3.149	5.072	-17.40	-37.91
13	1.579	1.826	-2.25	-13.55
14	2.029	1.840	1.71	10.26
15	2.889	4.363	-13.34	-33.78
16	1.102	1.326	-2.03	-16.88
17	1.130	1.339	-1.9	-15.6
18	1.624	1.451	1.57	11.93
19	1.953	2.232	-2.53	-12.51
20	1.350	1.214	1.23	11.17
21	1.647	1.480	1.52	11.3
22	1.552	1.735	-1.66	-10.54
23	1.094	1.336	-2.19	-18.1

Assim, sob o ponto de vista de estratégia de treinamento, conclui-se que a divisão, 30% para o conjunto de treinamento e 70% para o conjunto de teste, é uma boa opção para a escolha das primeiras configurações de pesos. Conforme observado nas Figuras 5.1 e 5.2 a configuração de pesos obtida com um conjunto de treinamento de apenas 30% do conjunto total fornece resultados razoáveis, com a ressalva dos pontos citados no parágrafo anterior.

Optou-se, então, pela busca de uma configuração de pesos que melhor pudesse representar o fenômeno, treinando a rede a partir de um conjunto de treinamento com mais pontos da função que se deseja aproximar.

5.3 Variação nos Limites de Escalonamento das Variáveis de Entrada.

De acordo com o descrito no item 4.4.1 as variáveis de entrada foram escalonadas entre 0 e 1, no *caso 1*[†], e entre -1 e 1, no *caso 2*. Embora para os dois casos o treinamento tenha sido iniciado com o mesmo conjunto de pesos houve uma melhora significativa no tempo de treinamento da rede para o escalonamento das variáveis de entrada entre -1 e 1.

Na Tabela 5.2 está apresentado um resumo do treinamento para os dois casos aqui investigados. Após 6000 iterações os erros[‡] médios para o *caso 2* eram aproximadamente 10% menores que os correspondentes no *caso 1*. Para os erros máximos foi observada uma melhoria de mais de 40%. De fato, para perfazer resultados semelhantes aos do *caso 2*, para o erro máximo, foram necessárias 14000 iterações no treinamento do *caso 1*. Por outro lado, para 14000 iterações os erros médios no *caso 2* são, aproximadamente, 30% menores que os correspondentes para o *caso 1* para o mesmo número de iterações.

Nas Figuras 5.3 e 5.4 estão ilustradas as variações do erro médio do conjunto de treinamento, respectivamente para o *caso 1* e o *caso 2*. Nota-se, pois, que o erro cai rapidamente no *caso 2*, justificando em parte a diferença de tempo de 50% observada na Tabela 5.2. Mesmo após a iteração 200 o erro no *caso 2* continua a cair mais que no *caso 1*. Da iteração 200 até a 1000 o erro médio no *caso 1* caiu de 6% para 4%, enquanto no *caso 2*, caiu de 4% para aproximadamente 2.5%.

[†]os termos *caso 1*, com a função de escalonamento das variáveis de entrada entre 0 e 1, e *caso 2*, em que o intervalo considerado foi -1 e 1, foram inseridos exclusivamente nesse capítulo para facilitar o encaminhamento do texto.

[‡] o erro aqui mencionado foi definido na Equação 5.1.

Tabela 5.2 – Comparação dos Tempos de Treinamento par os *Casos 1 e 2.*

modelo	número de iterações	tempo (horas)	erro médio (%)		erro máximo (%)	
			conjunto de treinamento	conjunto de teste	conjunto de treinamento	conjunto de teste
caso 1	6000	4	2.46	2.58	21.00	30.38
caso 2	6000	2	2.22	2.27	19.99	17.70
caso 1	14000	8	2.64	2.73	17.29	17.24
caso 2	14000	4	2.04	2.06	16.44	15.40

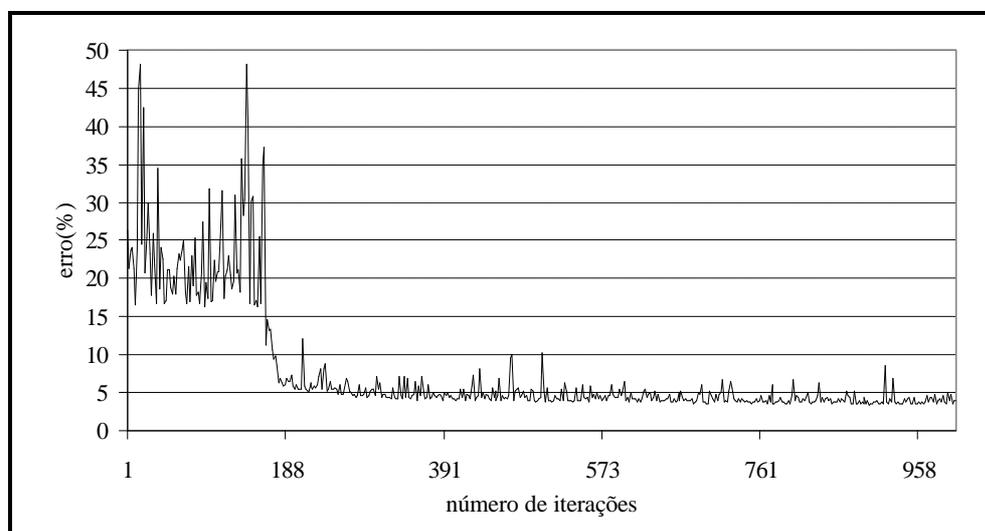


Figura 5.3 – Erro Médio no Conjunto de Treinamento para o *Caso 1.*

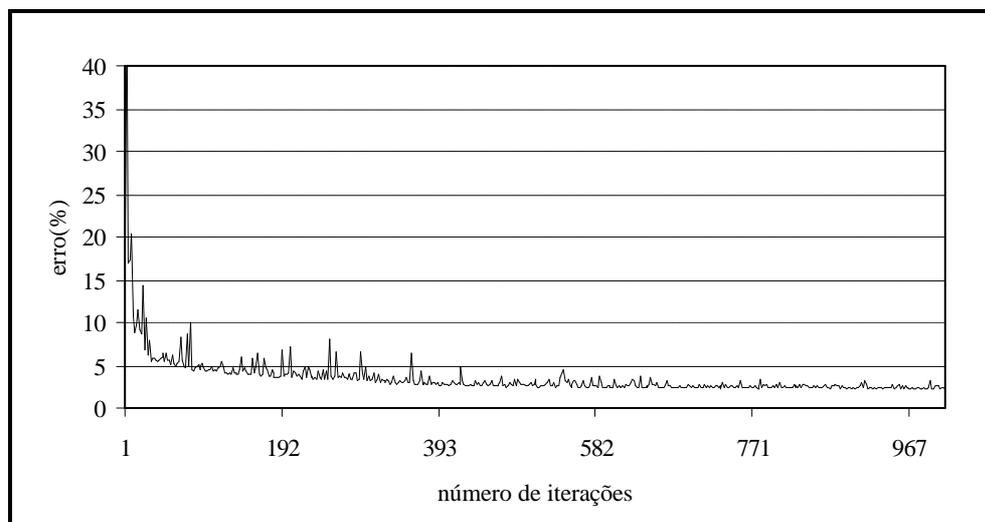


Figura 5.4 – Erro Médio no Conjunto de Treinamento para o *Caso 2.*

Pelo exposto, foi adotada a faixa de escalonamento do *caso 2* para as variáveis de entrada do *modelo RNA*. Relembrando, como a função de ativação é a *logística*, o escalonamento nas variáveis de saída foi entre 0.1 e 0.9.

5.4 Modificação na Função Resíduo.

No desenvolvimento do algoritmo de retro-propagação, apresentado no *Apêndice A*, Rumelhart³² utilizou o erro quadrático médio, definido na Equação 5.2, como função de mérito, ou função resíduo, a ser minimizada no processo de treinamento.

O erro quadrático médio foi definido por

$$\mathbf{e} = \frac{1}{2} \sum_{i=1}^p e_i^2 \quad (5.2)$$

sendo p o número de neurônios na camada de saída e

$$e_i = d_i - y_i \quad (5.3)$$

em que d_i e y_i são, respectivamente, os valores desejado e calculado pela rede.

Com essa função resíduo, no entanto, o erro e_i em cada neurônio da camada de saída, para cada par de treinamento, contribui para o erro total com o mesmo peso. Assim, para um conjunto de treinamento com eventuais pontos espúrios, a resposta da rede pode ficar comprometida.

Uma opção para tentar contornar esse problema é o uso de uma função que pondere o erro em cada ponto, penalizando mais os pontos cujos erros são maiores. Com o objetivo de analisar a influência de possíveis pontos espúrios no conjunto de treinamento foi definida a função

$$\mathbf{e} = \frac{1}{2} \sum_{i=1}^p \operatorname{tgh}(e_i^2) \quad (5.4)$$

sendo p o número de neurônios na camada de saída e e_i definido pela Equação 5.3.

Assim, o erro e_i será ponderado pela função tangente hiperbólica, cujo gráfico foi mostrado no capítulo 4, na Figura 4.4.

O desenvolvimento das modificações no algoritmo está mostrado no *Apêndice A*. Conforme destaca Cichocki⁵⁸ a utilização de uma função resíduo diferente daquela mostrada na Equação 5.2 pode ser implementada, basicamente, alterando-se a expressão de cálculo do gradiente local nos neurônios da camada de saída. Assim, a função resíduo definida pela Equação 5.4 foi implementada no programa *NEUROWELD* como opção à Equação 5.2.

Os resultados observados com a utilização da Equação 5.4, no entanto, não foram conclusivos sobre sua eficiência no tratamento de pontos espúrios. Foram elaborados dois exemplos simples, identificados nas Figuras 5.5 e 5.6, para avaliar o treinamento com aquela equação. De acordo com o mostrado na Figura 5.5 o ponto espúrio introduzido na função provocou uma perturbação local na função, mais acentuada no treinamento com a Equação 5.2, ainda que em outros pontos essa equação tenha fornecido resultados melhores que a Equação 5.4. Por outro lado, no exemplo mostrado na Figura 5.6[§], o ponto espúrio introduzido deslocou sobremaneira a curva fornecida pela rede treinada com a Equação 5.2, ao passo que com a Equação 5.4 a função simulada ficou mais bem representada.

[§] foram levantados pontos aleatórios da função $z = x^3 / y$, com x variando de 0.1 a 60 e y variando de 0.1 a 200. Devido às dificuldades de visualização do gráfico dessa função para os pares aleatórios gerados optou-se por ordenar os pontos a partir dos valores de x e construir o gráfico mostrado na Figura 5.6.

Nas Figuras 5.7 e 5.8 estão os gráficos de evolução dos erros médios nos conjuntos de treinamento do *modelo RNA* empregando-se, respectivamente, as funções definidas nas Equações 5.2 e 5.4. Observando as 1000 iterações iniciais conclui-se que não houve diferença significativa entre os dois casos.

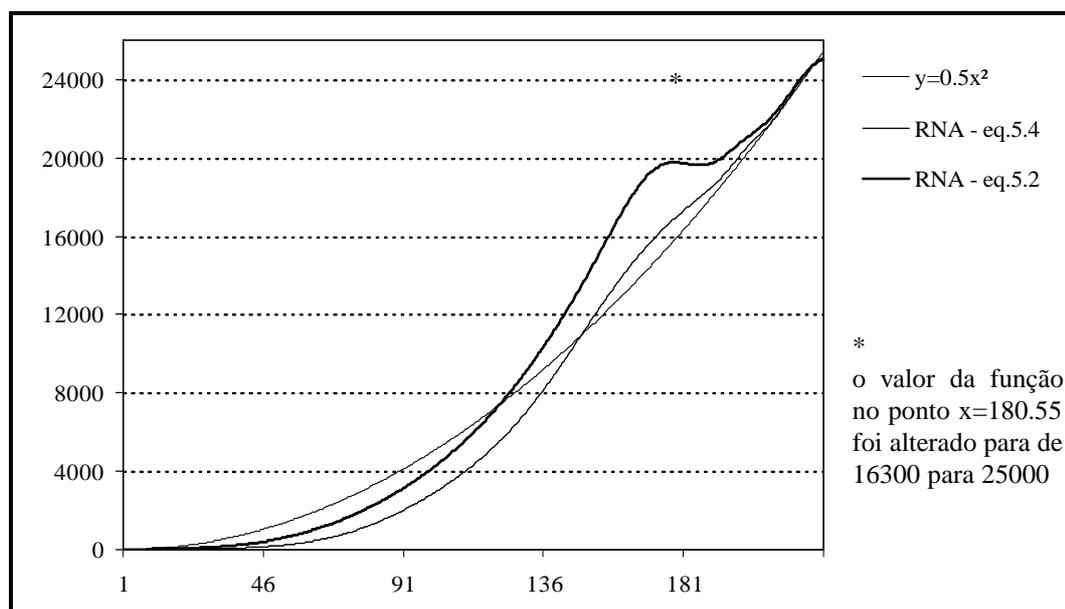


Figura 5.5 – Erro Médio no Conjunto de Treinamento para a função $y = 0.5x^2$.

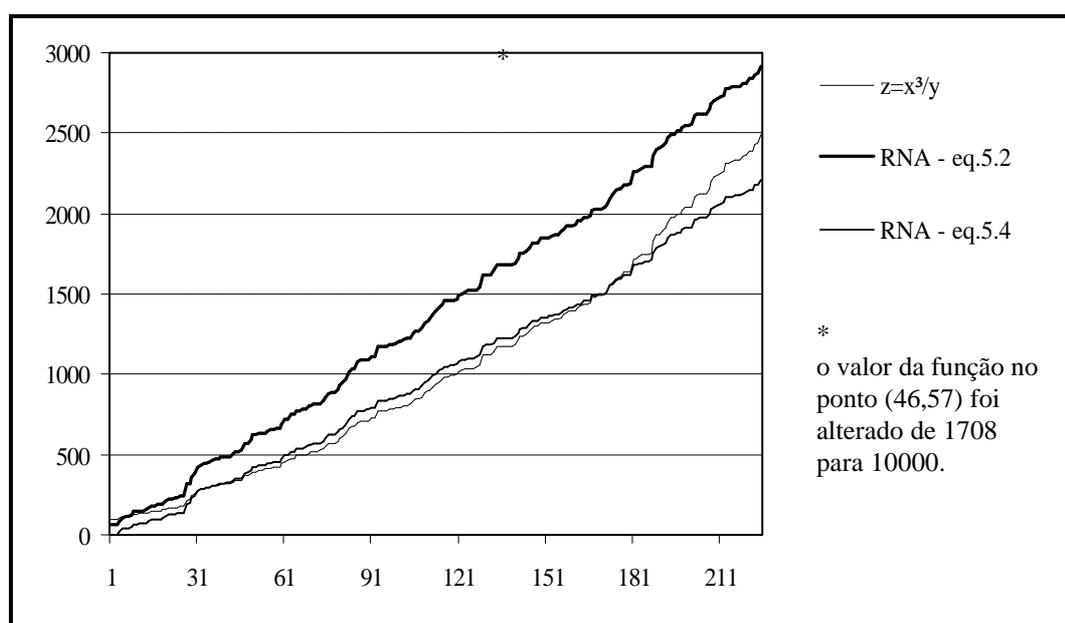


Figura 5.6 – Erro Médio no Conjunto de Treinamento para a função $z = x^3 / y$.

Dessa forma, é necessário que esse assunto seja estudado com outros exemplos formando um conjunto de análises suficientes para que uma conclusão mais fundada sobre a definição da função resíduo no processo de treinamento seja estabelecida. Assim, no desenvolvimento do *modelo RNA* foi considerada a Equação 5.2.

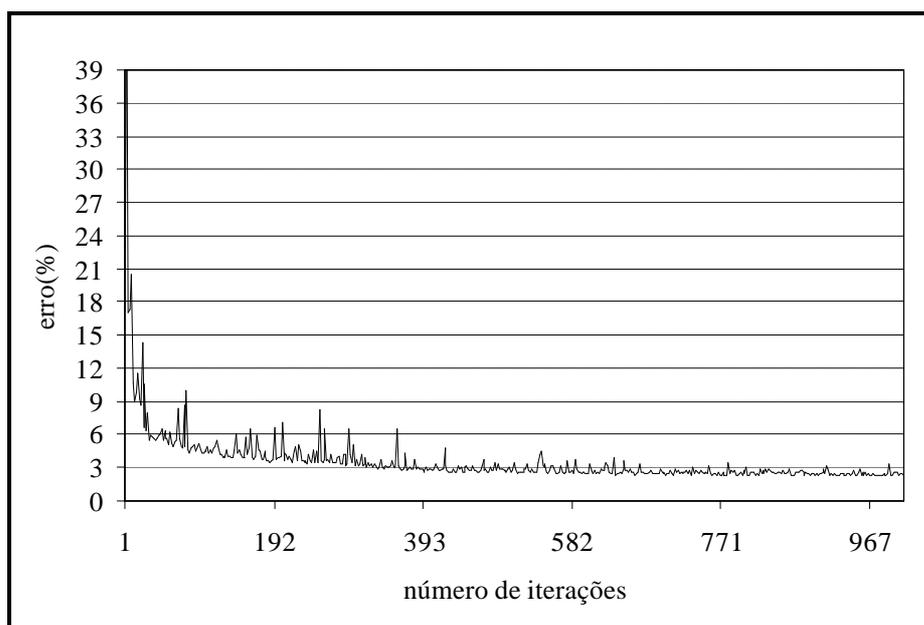


Figura 5.7 – Erro Médio no Conjunto de Treinamento para Equação 5.2.

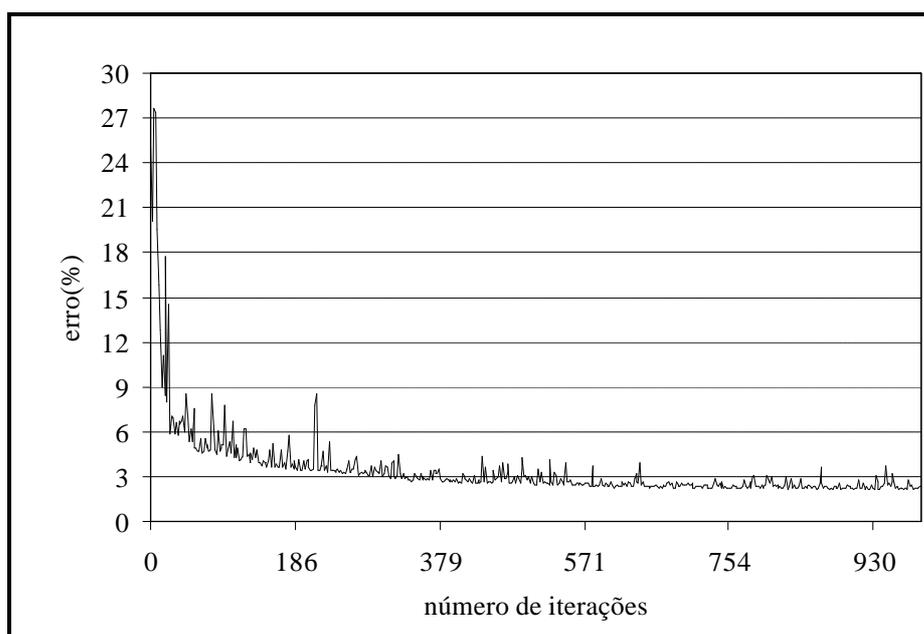


Figura 5.8 – Erro Médio no Conjunto de Treinamento para Equação 5.4.

5.5 Treinamento do *Modelo RNA*.

Cumprindo o objetivo maior desse trabalho foram definidas duas redes, detalhadas no *Apêndice A*, e cujas características principais de treinamento estão demarcadas na Tabela 5.3.

De acordo com o mostrado nesta tabela a configuração final para o caso FNP foi atingida em menos tempo, dado que para os dois casos o procedimento adotado foi o mesmo**.

Durante o treinamento foi verificado que, para o caso FNP, os erros médio e máximo tinham tendências de diminuir ao longo das iterações. Por isso, o treinamento foi parado com 29000 iterações, quando os referidos erros já eram suficientemente pequenos. No caso MNP, ao contrário, o processo para obter a configuração de rede foi mais trabalhoso. No treinamento, a partir da iteração 5000, aproximadamente, o erro médio nos conjuntos de teste e de treinamento ficou estável em torno de 2.4% e 3.1%, respectivamente. Os erros máximos, no entanto, ainda apresentavam oscilações entre 40% e 60%. Depois de 10000 iterações essa faixa caiu para 30% a 48%, e o erro médio no conjunto de teste estabilizou em torno de 2.6%. Com 13300 iterações, depois de 11 horas de processamento, o treinamento foi interrompido.

Tabela 5.3 – Características do Treinamento do *modelo RNA*.

caso de carga	número de pesos na rede	número de iterações	tempo (horas)	erro médio (%)		erro máximo (%)	
				conjunto de treinamento	conjunto de teste	conjunto de treinamento	conjunto de teste
FNP	95 (15x5)	29000	9	1.89	1.92	12.95	15.85
MNP	415 (25x15)	13300	11	2.38	2.57	32.40	34.10

** partiu-se de uma rede com uma camada oculta, com 10 neurônios e evoluiu-se aumentando o número de neurônios até o limite de 50. A partir daí foi adicionada uma segunda camada oculta e o processo foi repetido.

CAPÍTULO 6

RESULTADOS E DISCUSSÕES

6.1 Introdução.

Este capítulo será dedicado à apresentação dos resultados obtidos com as configurações finais de rede, definidas no *Apêndice A*, para os dois casos de carregamento analisados. Inicialmente as tensões calculadas com o *modelo RNA* serão confrontadas com aquelas utilizadas para treinar e testar a rede. Em seguida, o *modelo RNA* será comparado com as principais equações disponíveis e com resultados provenientes de ensaios experimentais.

Para complementar, no *Apêndice D* está apresentada uma tabela com os resultados obtidos para os valores máximos dos 252 casos analisados, para os dois casos de carregamento.

6.2 Comparação de Resultados Obtidos: RNA x MEF.

A comparação entre os resultados fornecidos pela RNA e aqueles utilizados no processo de treinamento, obtidos pelo MEF, está distribuída nas Figuras 6.1 a 6.24. Foram consideradas, nestas figuras, diferentes configurações de rede, englobando combinações dos parâmetros adimensionais apresentados na Tabela 3.1. O objetivo é fornecer um panorama de desempenho da função codificada pelo *modelo RNA*, em vários pontos de seu domínio. As Figuras 6.1 a 6.14 correspondem ao caso de carregamento FNP, enquanto o caso MNP está mostrado nas Figuras 6.15 a 6.26.

A existência de um modelo para representar a distribuição de tensões ao longo do cordão de solda, *de per si*, não seria suficiente para justificar essa pesquisa se não fossem os avanços que esse modelo representa sobre o procedimento tradicional. Para uma melhor compreensão do caráter inovador alcançado com o *modelo RNA* é necessário tecer alguns comentários sobre as bases do cálculo do FCT em juntas soldadas.

Historicamente os valores de FCT foram levantados através de ensaios experimentais e também por simulações numéricas. Até mesmo para manter certa compatibilidade com resultados anteriores os procedimentos para cálculo do FCT foram mantidos praticamente imutáveis ao longo das últimas quatro décadas. Embora já existam extensômetros elétricos com menos de 1 mm de comprimento e também exista a possibilidade de modelar a junta mais adequadamente através de simulação numérica, é certo que a maioria das equações existentes é baseada em valores de FCT obtidos por extrapolações, seja para evitar a influência da tensão de entalhe, no caso dos testes experimentais, ou pela utilização do elemento de placa, nas simulações numéricas. Por conta do exposto, nessa primeira etapa do cálculo do FCT já existe uma simplificação.

A segunda parte do problema está ligada à escolha de uma ferramenta eficiente para o cálculo do FCT em novas juntas. Conforme discutido no primeiro capítulo a saída encontrada foi montar equações parametrizadas e ajustá-las a partir de resultados conhecidos. Nesse ponto, também ocorre outra aproximação no cálculo do FCT, pois nem sempre as equações conseguem ajustar adequadamente o conjunto de dados, havendo casos em que o desvio-padrão chega a 40%⁵¹. Devido às incertezas suscitadas

pelas aproximações descritas o valor do FCT calculado para uma nova configuração precisa ser resguardado por um coeficiente de segurança.

Antes de avaliar os resultados do *modelo RNA* urge ressaltar que a utilização do conjunto de dados obtido por Massaroti²⁰ através simulação numérica, com um modelo de elementos do tipo “brick”, mais adequado para representar a junta soldada, elimina a necessidade de extrapolações no cálculo do FCT. Como a geometria do cordão de solda está representada o FCT decorre da observação do maior valor de tensão na junta, admitindo-se tensão unitária no braço secundário, longe da junta. Assim, o conjunto de dados levantado representa claro avanço sobre o aspecto de qualidade de resultado e sobre o procedimento anterior baseado em extrapolações.

Entretanto, embora o modelo utilizado por Massaroti seja mais representativo da junta soldada e também por isso o FCT obtido seja mais acurado, o segundo passo, que é conseguir simular o conjunto de dados obtidos por uma ferramenta expedita não pôde ser atingido através das equações tradicionais*.

O *modelo RNA*, ora proposto, introduz novo horizonte no cálculo do FCT. Ao contrário do que usualmente acontece com as tradicionais equações paramétricas, que permitem determinar somente os valores máximos de tensões, o *modelo RNA* consegue representar, com qualidade aceitável, a distribuição de tensões ao longo do comprimento da junta soldada. Isso vale tanto para configurações nas quais as distribuições de tensões são “bem comportadas”, representadas nas Figuras 6.2, 6.3, 6.15 e 6.19, por exemplo, como também para distribuições mais complexas, encontradas, principalmente, em

* Em seu trabalho Massaroti²⁰ conseguiu simular através de equações os pontos de máxima tensão (FCT) para o caso MNP.

configurações com valores de q abaixo de 70° . Essa característica, observada nos dois casos de carregamento e exemplificada nas Figuras 6.1, 6.4, 6.10 e 6.26, entre outras, está associada à complexidade do fenômeno analisado e também à dificuldade de representação da geometria da solda na região de *heel*[†], para baixos valores de q .

As vantagens do *modelo RNA* são imediatas. Conforme exemplificado nas Figuras 6.31 a 6.34, de posse da distribuição de tensões para os dois casos de carregamento analisados pode-se empregar valores mais realistas no projeto da junta sob a ação simultânea de dois carregamentos, ao invés de uma distribuição padrão que nem sempre premia a eficiência. Em adição, o projetista pode trabalhar com a geometria do cordão de solda para calcular um FCT menor, conforme será discutido no próximo item. Do ponto de vista de análise, no conhecimento do autor, o *modelo RNA* é pioneiro na representação da distribuição de tensões em juntas soldadas.

Ainda com relação às Figuras 6.1 a 6.26 é importante observar que os pontos que as compõem não estão divididos por conjunto de treinamento e conjunto de teste. Isto porque esses conjuntos foram gerados aleatoriamente e, assim, nenhum dos 252 conjuntos de pontos ficou por inteiro no conjunto de treinamento ou no de teste[‡].

Para avaliar os resultados dentro de cada conjunto, de teste e de treinamento, foram construídos os gráficos das Figuras 6.27 a 6.30. Os gráficos mostrados nas Figuras 6.27 e 6.28 são análogos àqueles construídos no item 5.2, e representam o caso de carregamento FNP. Nota-se, no entanto, uma melhoria na representação em relação aos resultados apresentados naquele item. Aqui, a maior diferença absoluta obtida no

[†] As posições *heel* e *toe* foram definidas na Figura 2.3.

[‡] cada figura é formada por 41 pontos que correspondem à distribuição de tensões ao longo do cordão de solda para uma determinada configuração. Para o treinamento da rede esses pontos foram separados aleatoriamente entre os dois conjuntos, de teste e de treinamento.

conjunto de teste foi 14.4%. Ainda, nos pontos em que a diferença absoluta foi maior que 10% o valor de FCT, invariavelmente, foi menor que 1.7.

Nas Figuras 6.29 e 6.30, respectivamente para os conjuntos de treinamento e de teste, estão os histogramas levantados no caso de carregamento MNP. Neste caso, a maior diferença absoluta obtida no conjunto de teste foi 34.1%. No entanto, no conjunto de treinamento e no de teste existem pontos nos quais o valor da tensão é menor que 1. Conforme ilustrado na Tabela 6.1, na maioria dos 180 pontos em que a diferença absoluta supera 10% o valor de tensão é inferior a 1.

Considera-se, assim, que nos dois casos de carregamento os valores fornecidos pelo *modelo RNA* estão de acordo com aqueles utilizados nos conjuntos de treinamento e de teste, ou seja, foram identificadas duas configurações de redes neurais, uma para cada caso de carregamento, que simulam, com precisão aceitável do ponto de vista de engenharia, a distribuição de tensões em juntas tubulares soldadas do tipo Y.

Tabela 6.1 – Diferenças Absolutas Maiores que 10% para o Caso MNP.

número de pontos	tensão		diferença absoluta máxima (%)	diferença relativa correspondente (%)
	MEF	RNA		
165	< 1	< 1	34.1	2.2
14	< 2	< 2	16.4	4.2
1	2.3	2.5	8.7	5.0

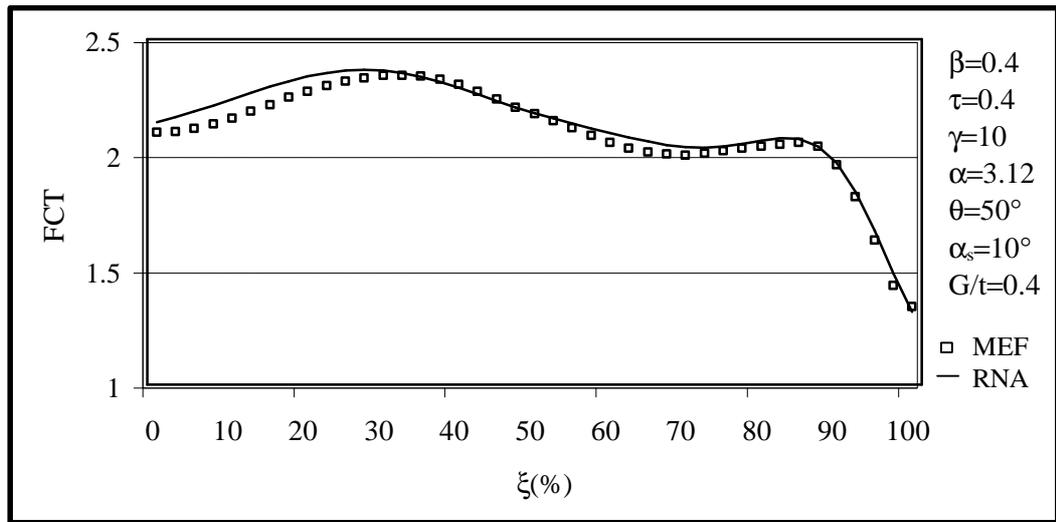


Figura 6.1 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

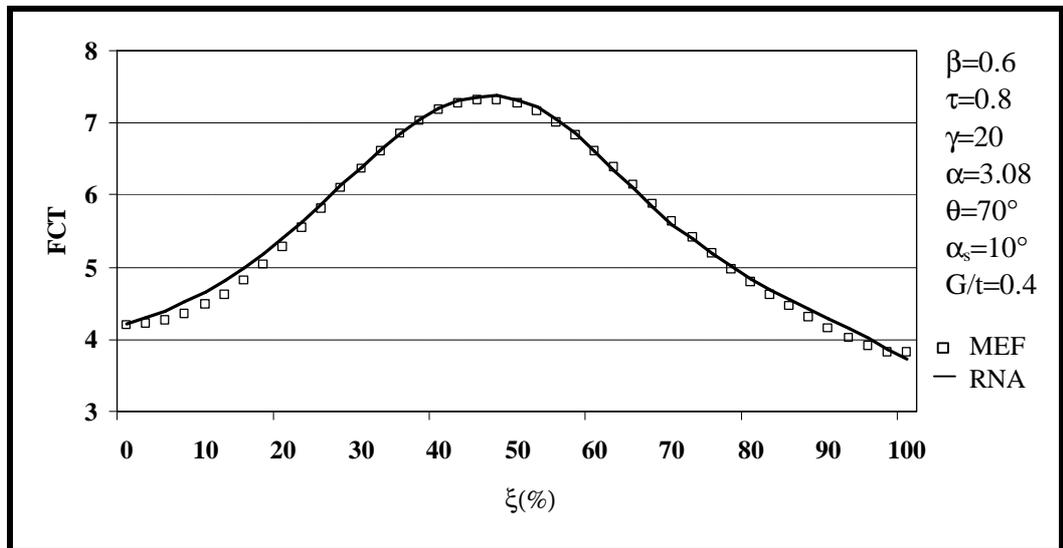


Figura 6.2 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

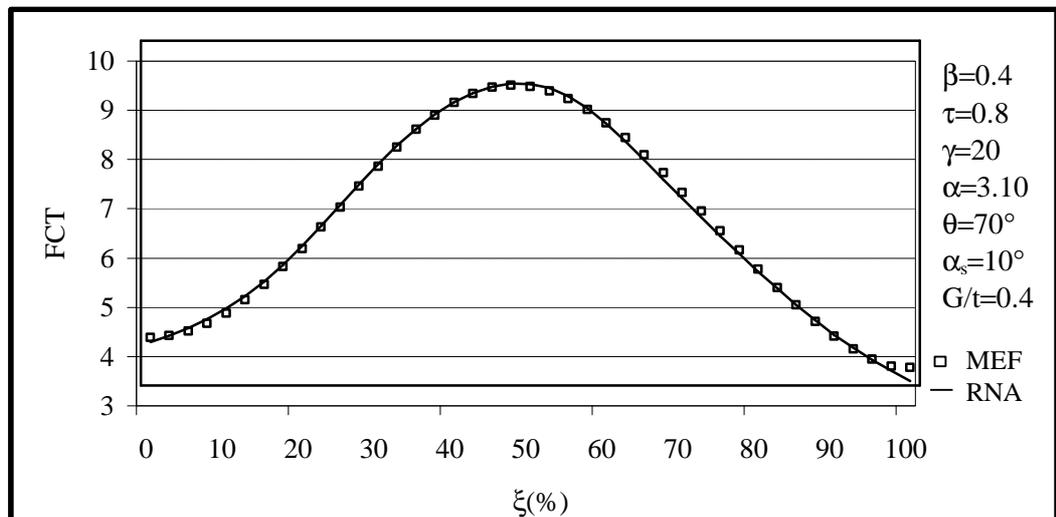


Figura 6.3 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

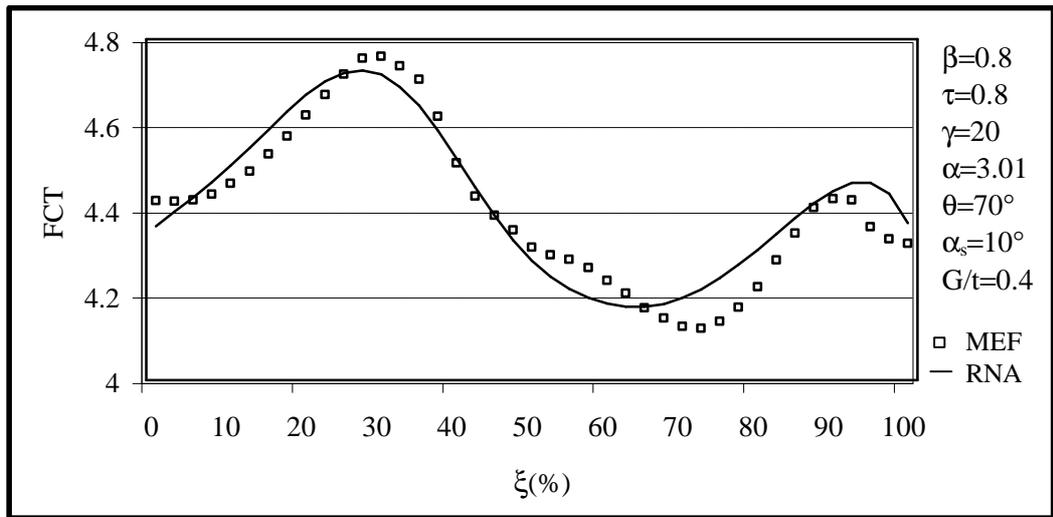


Figura 6.4 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

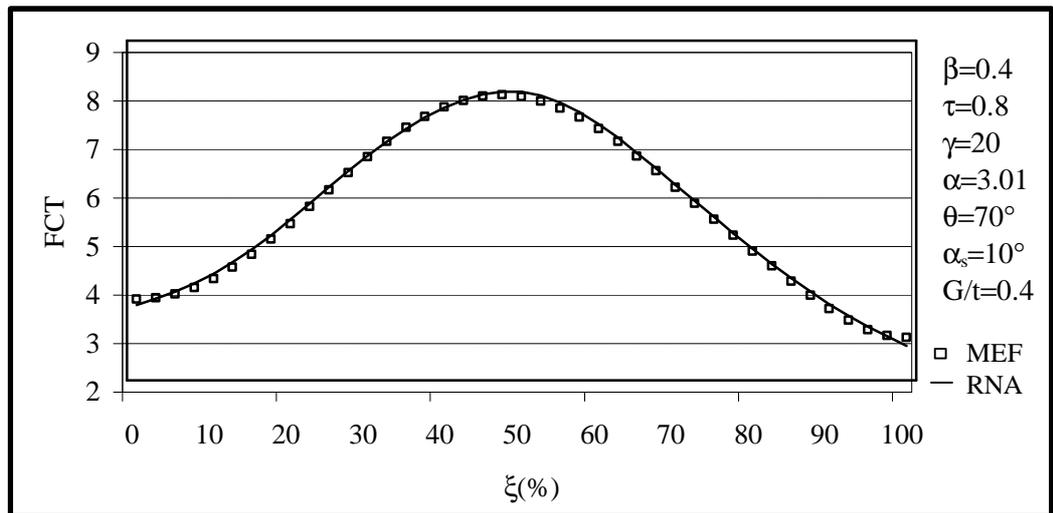


Figura 6.5 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

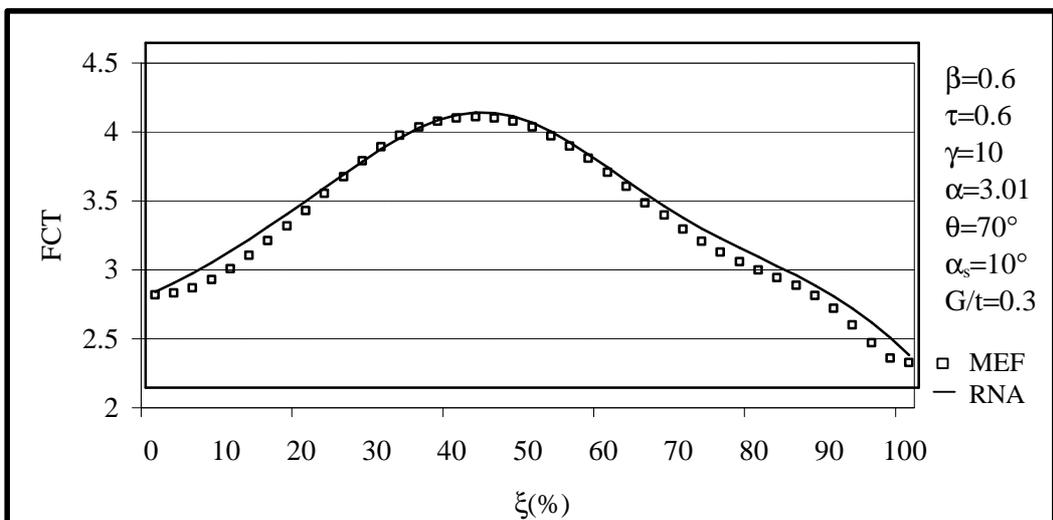


Figura 6.6 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

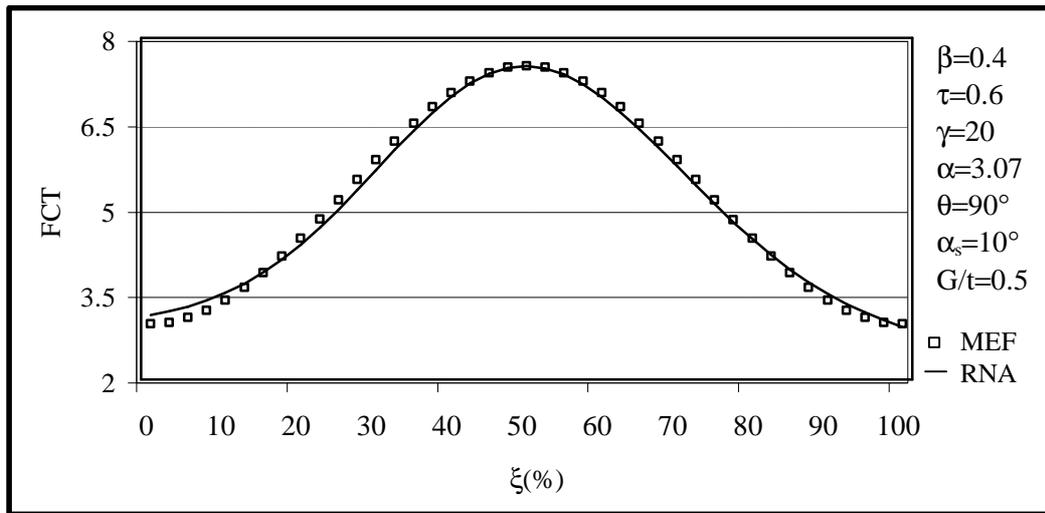


Figura 6.7 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

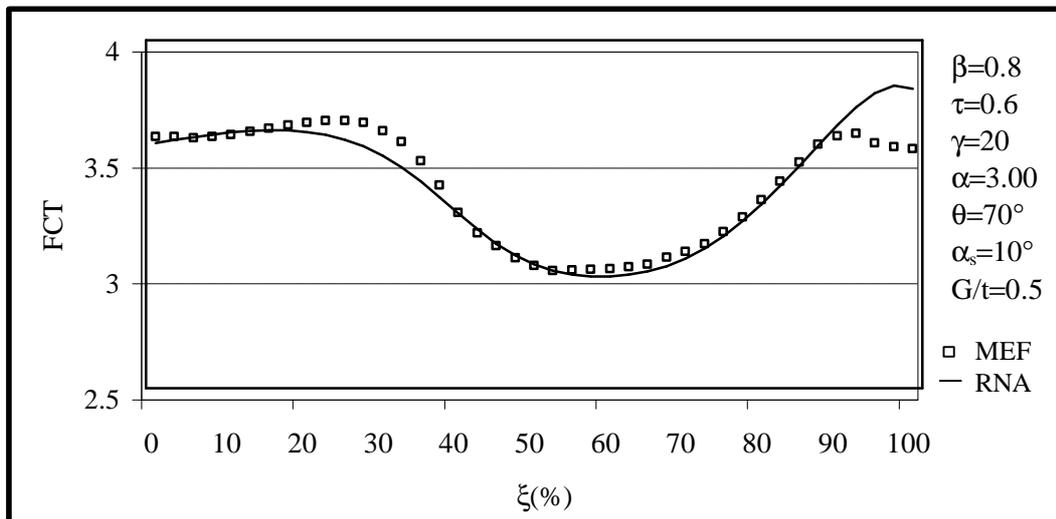


Figura 6.8 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

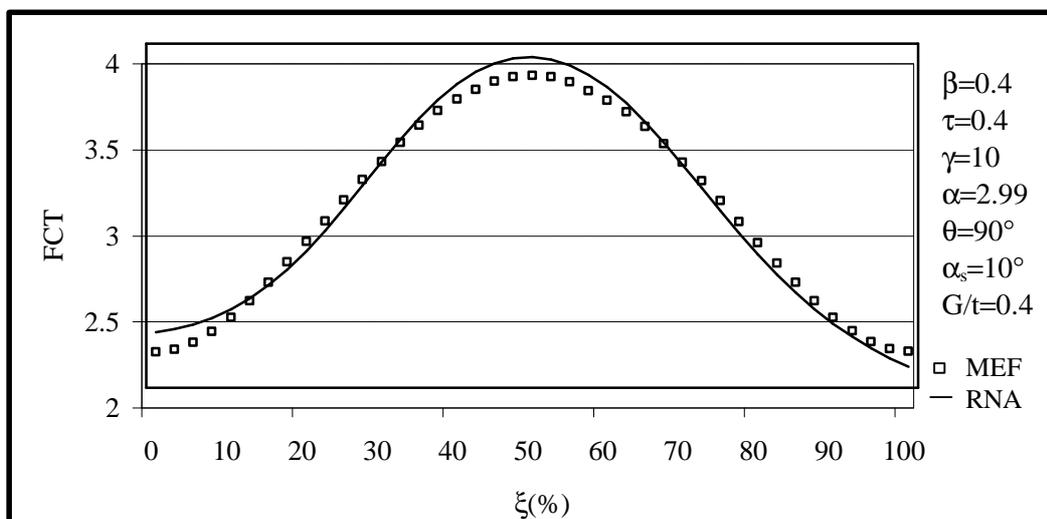


Figura 6.9 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

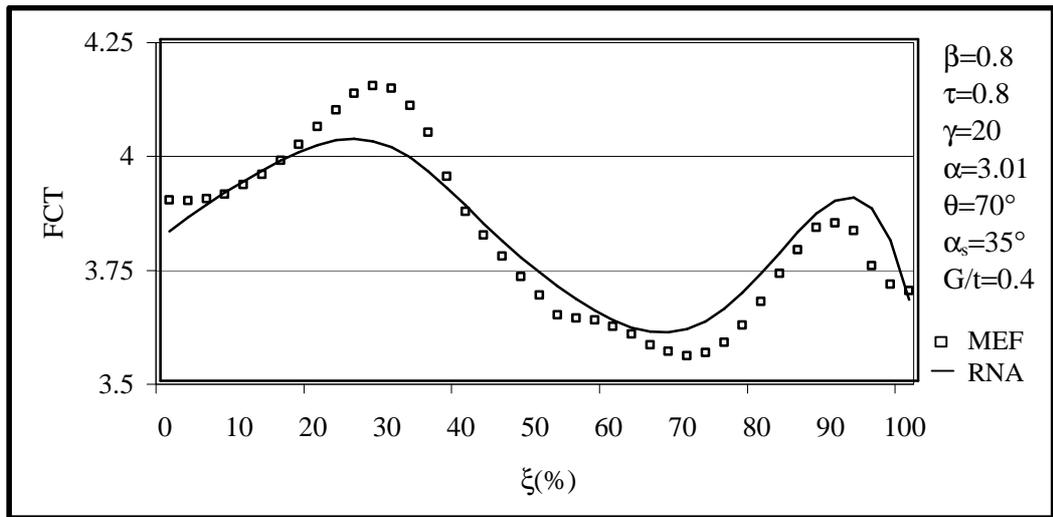


Figura 6.10 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

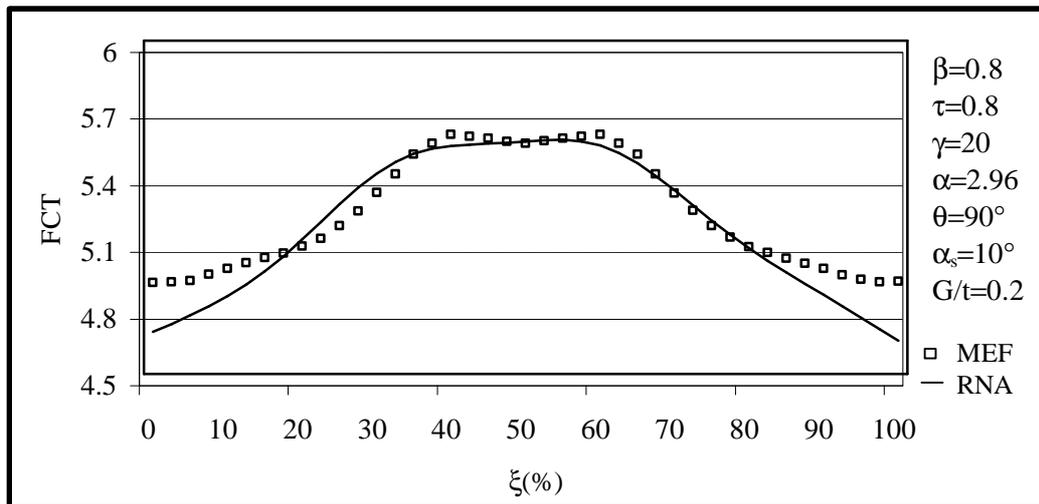


Figura 6.11 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

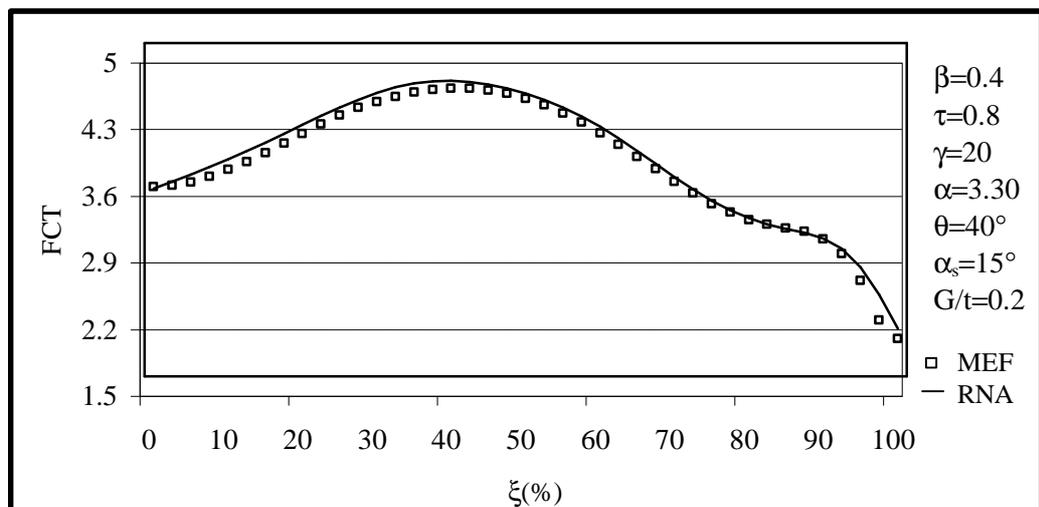


Figura 6.12 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

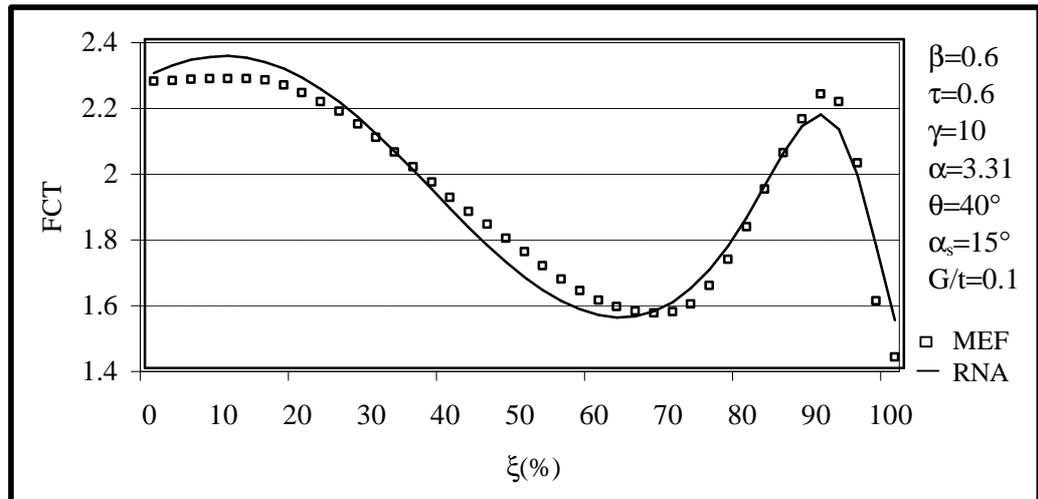


Figura 6.13 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

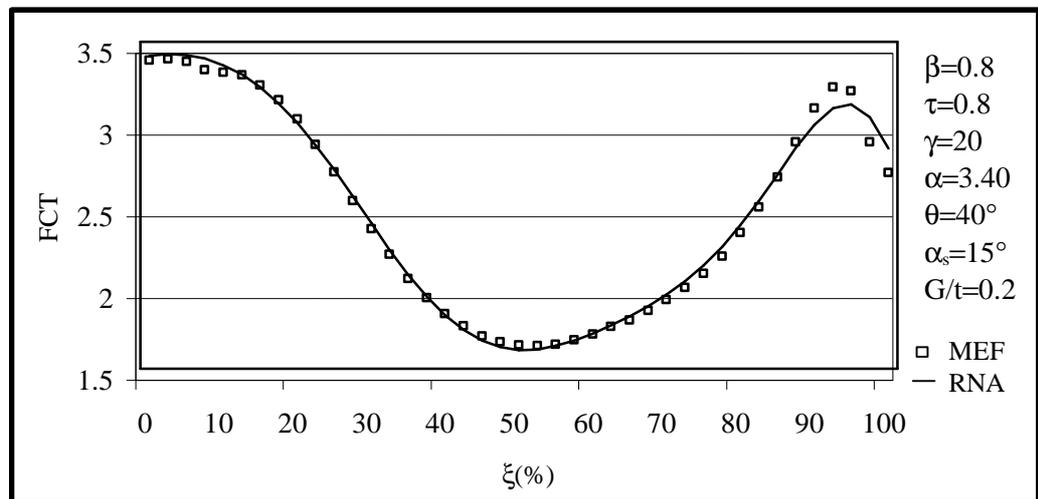


Figura 6.14 – Distribuição das TEVM ao Longo do Cordão de Solda – FNP.

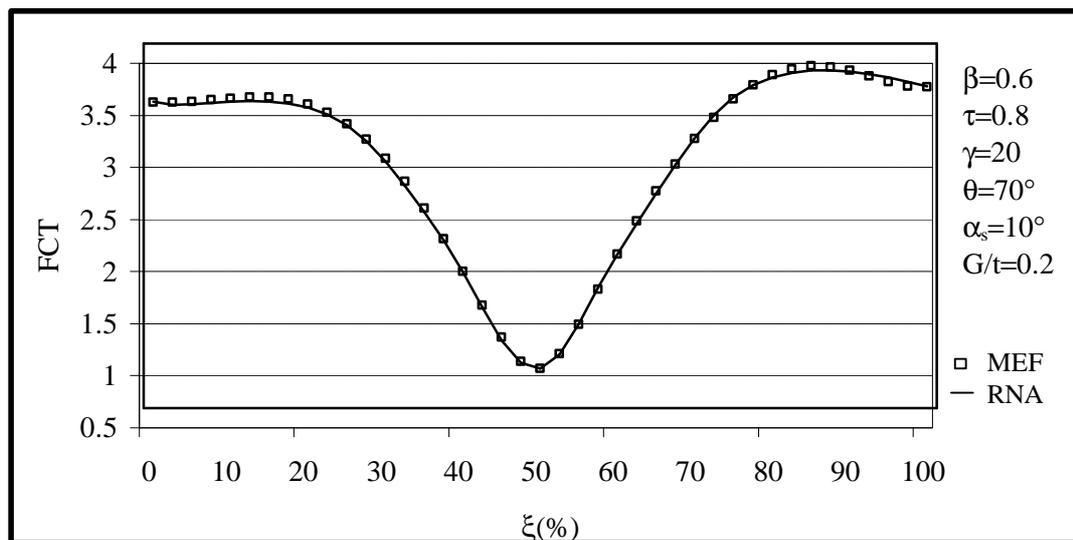


Figura 6.15 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

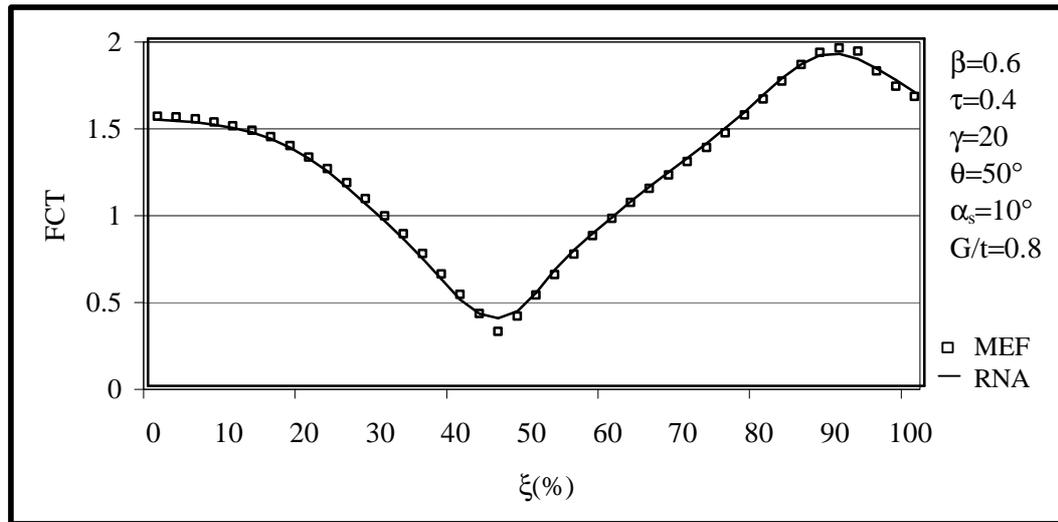


Figura 6.16 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

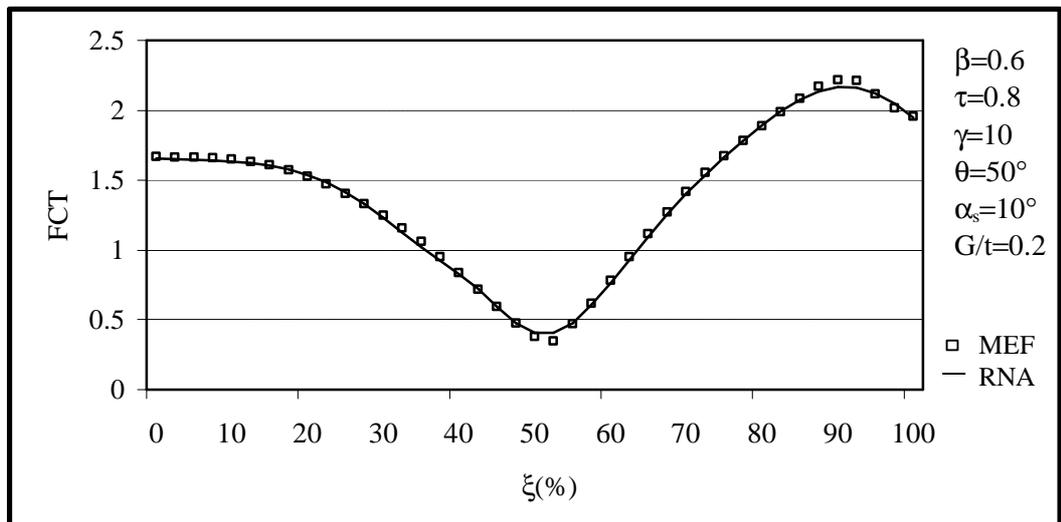


Figura 6.17 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

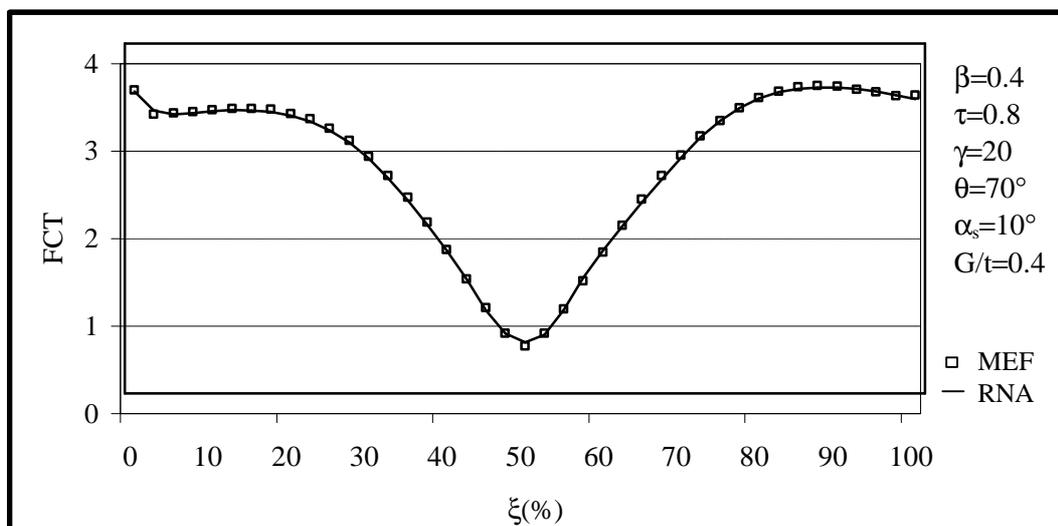


Figura 6.18 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

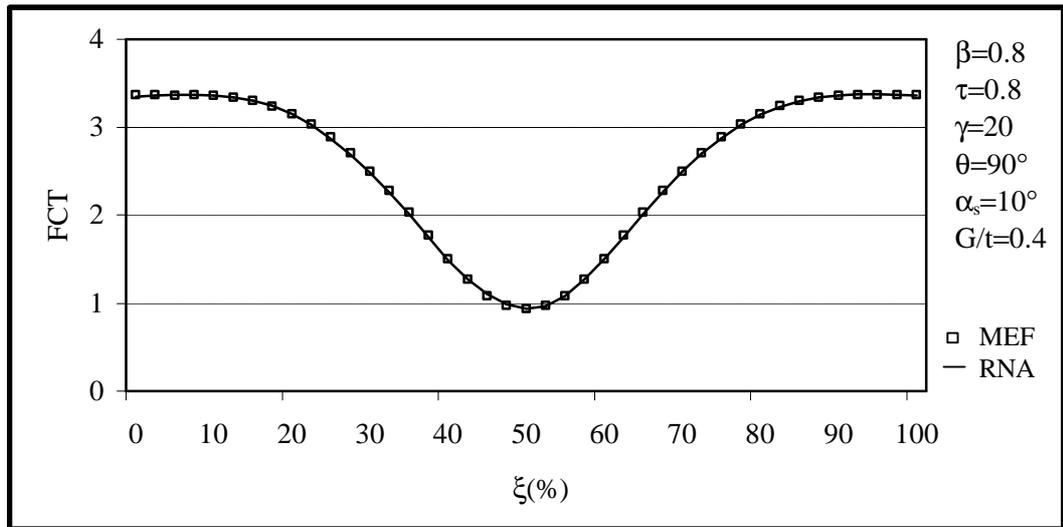


Figura 6.19 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

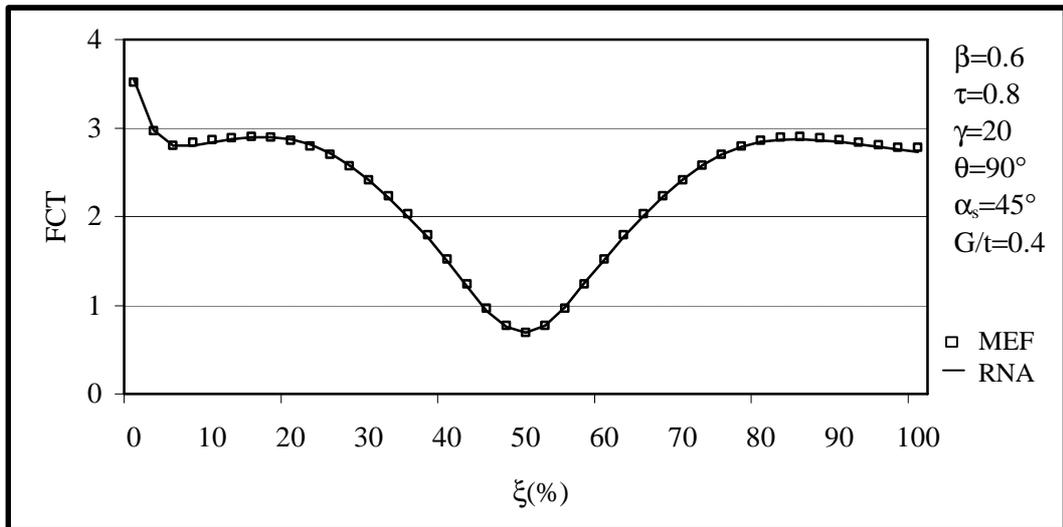


Figura 6.20 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

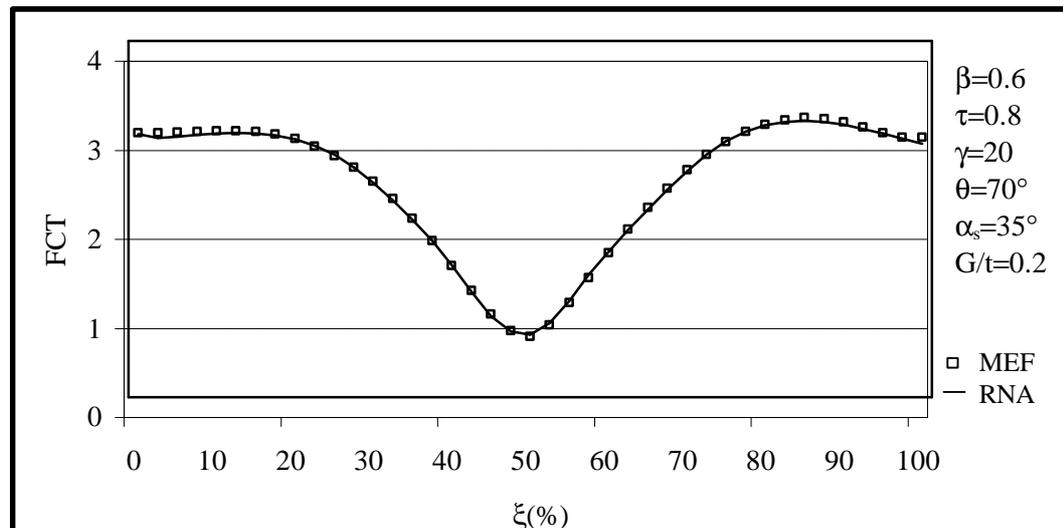


Figura 6.21 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

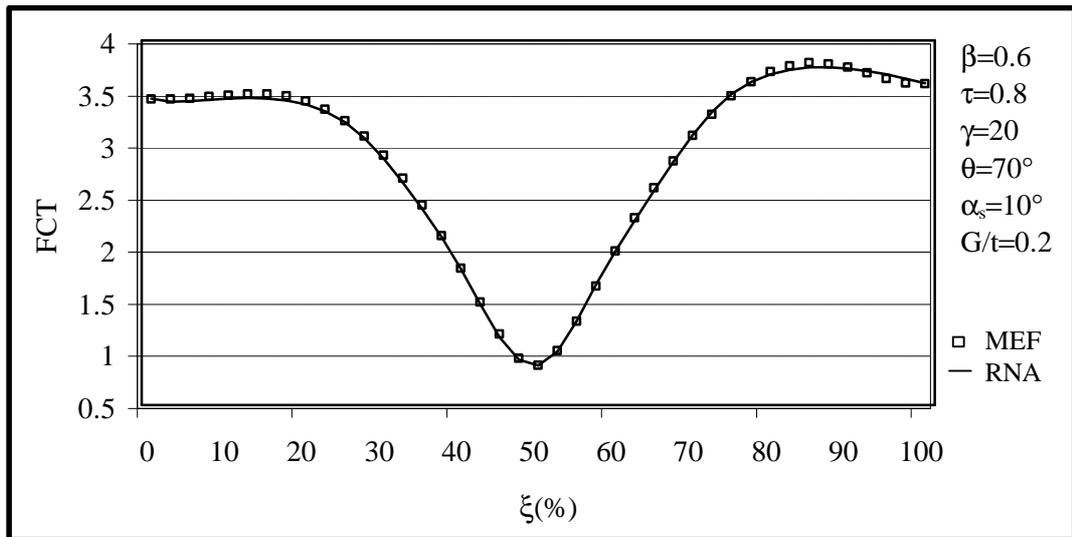


Figura 6.22 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

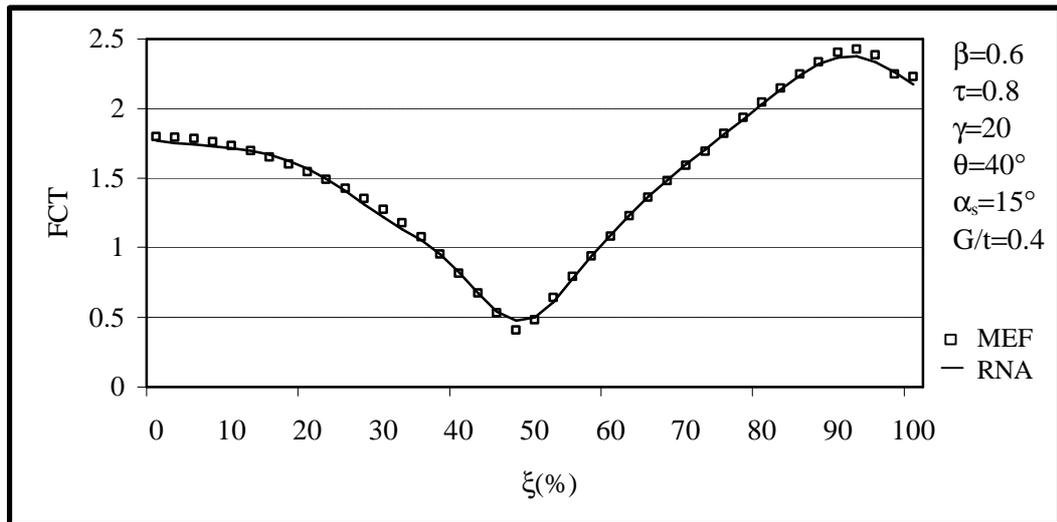


Figura 6.23 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

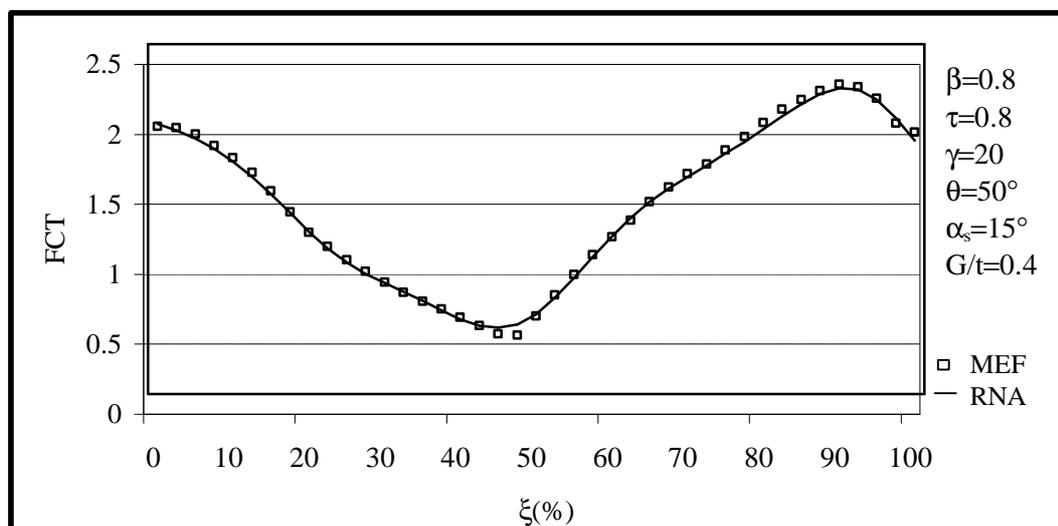


Figura 6.24 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

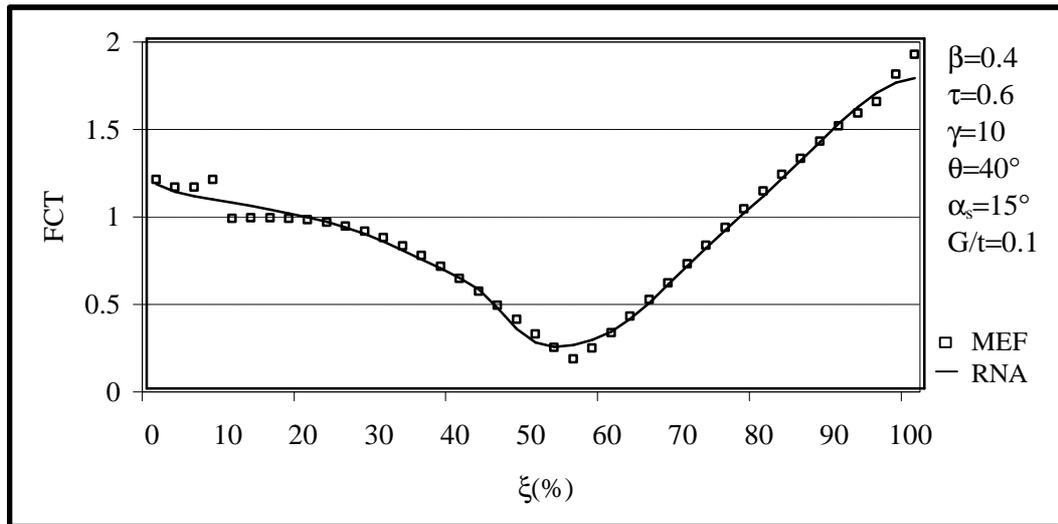


Figura 6.25 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

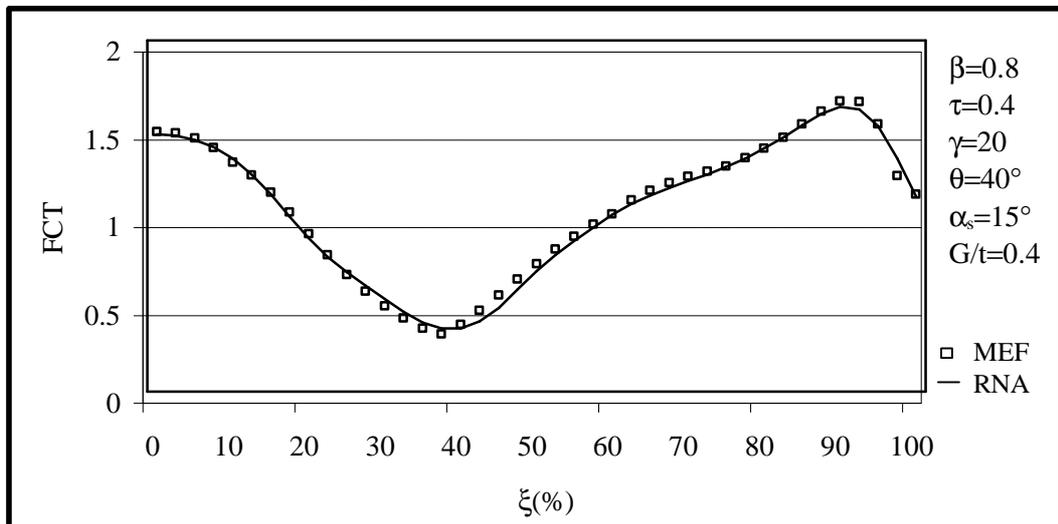


Figura 6.26 – Distribuição das TEVM ao Longo do Cordão de Solda – MNP.

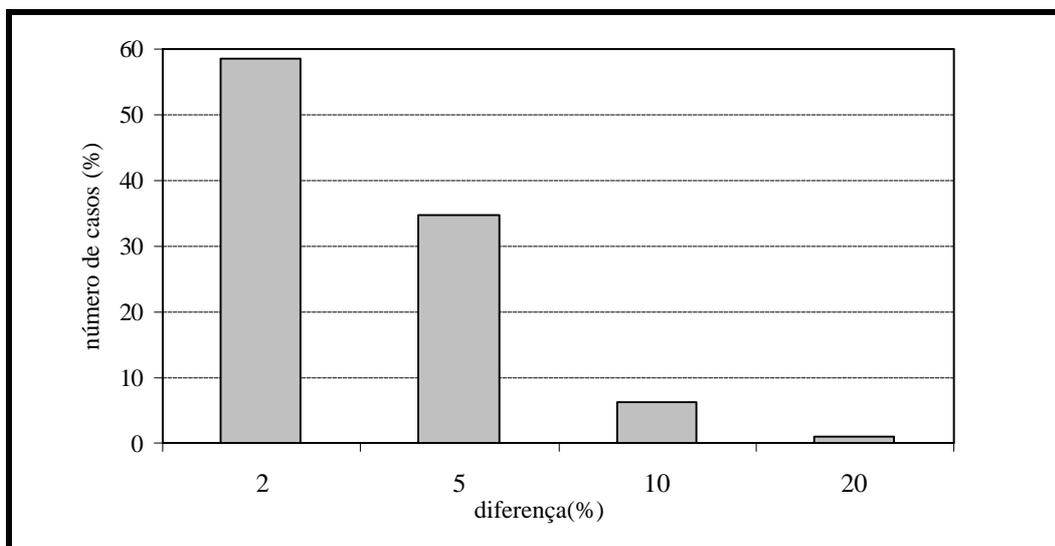


Figura 6.27 – Distribuição do Erro Médio no Conjunto de Treinamento – FNP.

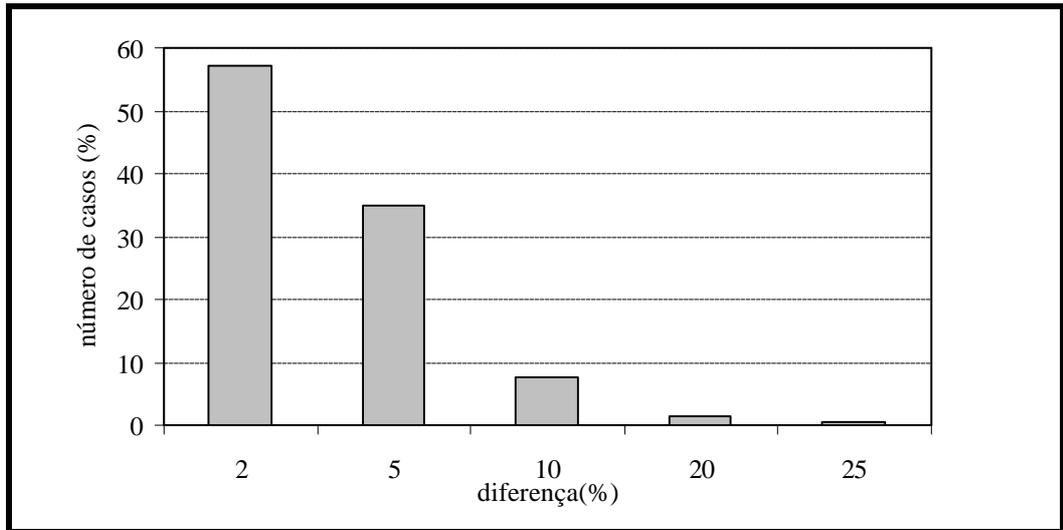


Figura 6.28 – Distribuição do Erro Médio no Conjunto de Teste – FNP.

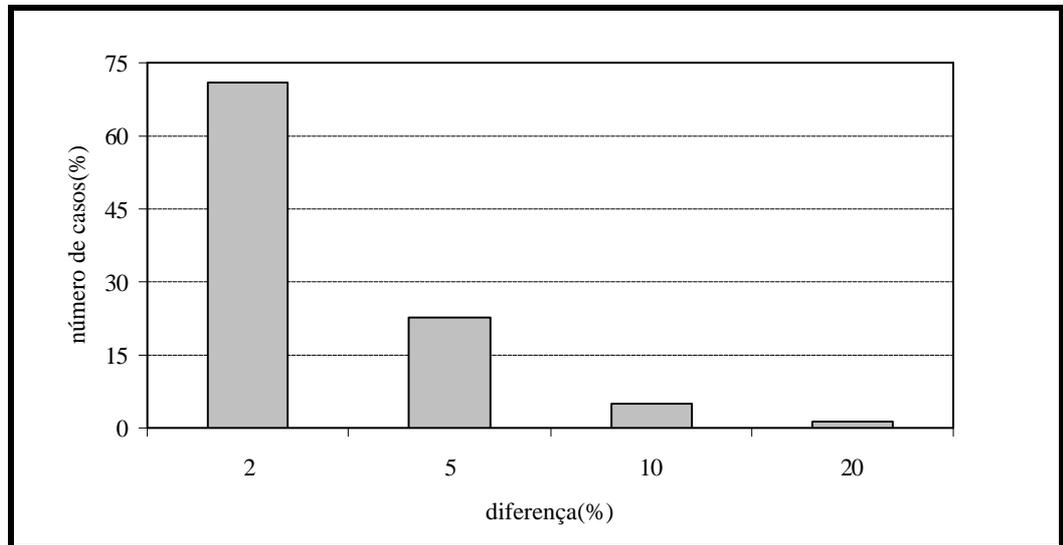


Figura 6.29 – Distribuição do Erro Médio no Conjunto de Treinamento – MNP.

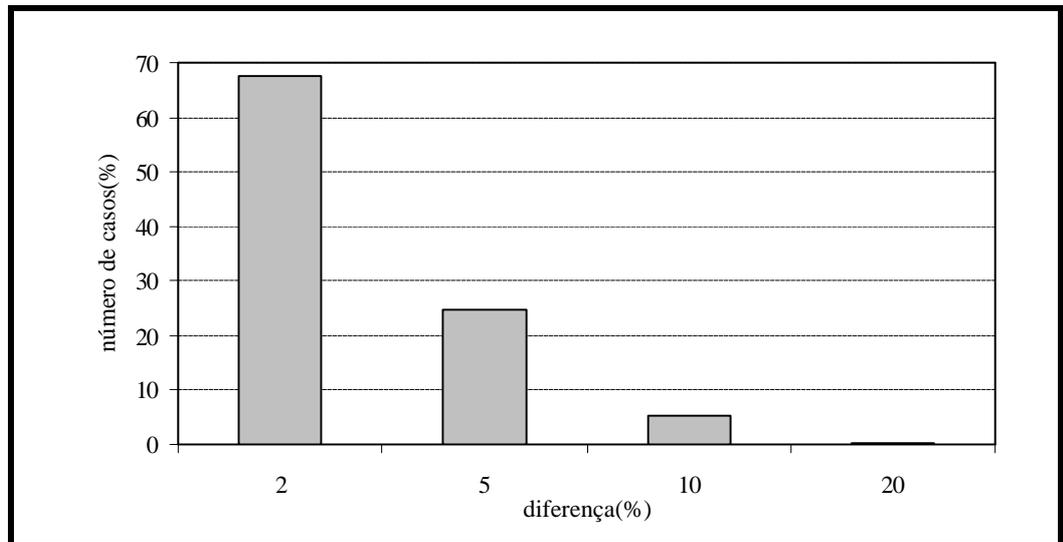


Figura 6.30 – Distribuição do Erro Médio no Conjunto de Teste – MNP.

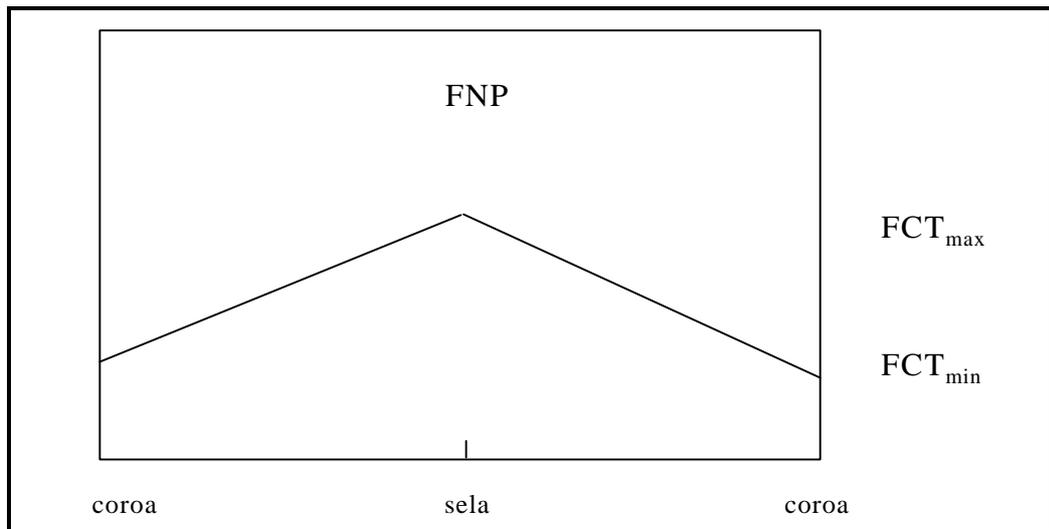


Figura 6.31 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda Recomendada pela UEG¹⁹ - FNP.

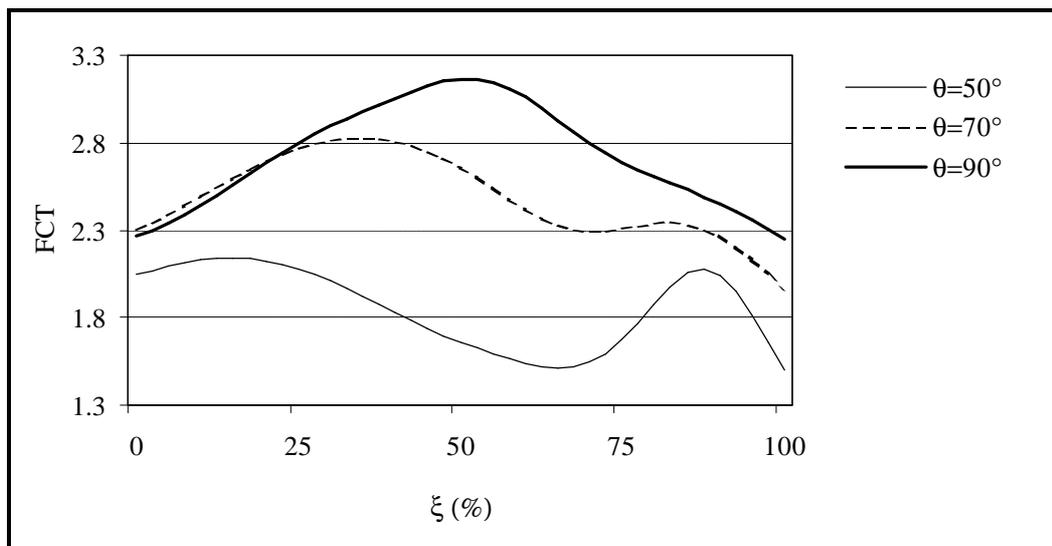


Figura 6.32 – Distribuições de Tensões ao Longo do Comprimento do Cordão de Solda para o modelo RNA - FNP.

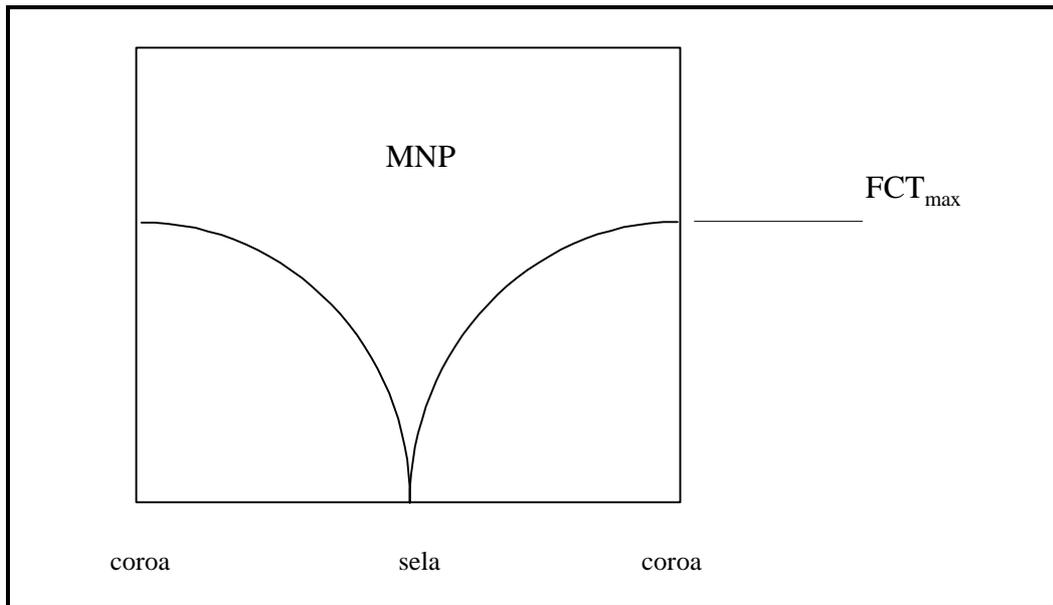


Figura 6.33 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda Recomendada pela UEG¹⁹ - MNP.

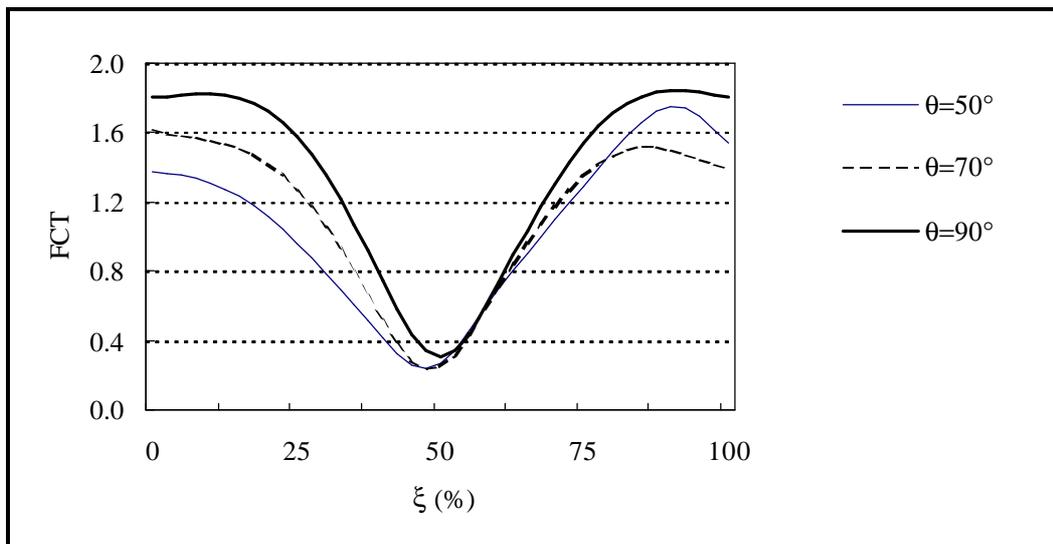


Figura 6.34 – Distribuição de Tensões ao Longo do Comprimento do Cordão de Solda para o Modelo RNA - MNP.

6.3 Comparação de Resultados: RNA x Equações Paramétricas.

Nas figuras 6.35 a 6.42 estão apresentados resultados comparativos dos valores obtidos com as RNA e aqueles fornecidos pelas principais equações disponíveis na literatura. Foram escolhidas as equações da UEG¹⁹ e do Lloyds Register(LR)⁵¹, publicadas, respectivamente, em 1985 e em 1997. Esses dois conjuntos de equações inclui revisões das equações existentes até as respectivas datas de publicação e também novos conjuntos de dados.

As equações da UEG foram derivadas de ensaios com modelos de acrílico e simulação numérica através do MEF, representando os tubos elementos de casca, sem considerar a geometria do cordão de solda. No caso das equações do LR foram utilizados modelos de aço e modelos de acrílico. Nos modelos de aço foi considerada a geometria do cordão de solda.

A variação do FCT em função dos parâmetros representativos da geometria do cordão de solda, mostrada nas Figuras 6.35 a 6.42, é um diferencial importante obtido pelo *modelo RNA* que permite ao projetista avaliar a geometria mais adequada para o cordão de solda. Devido ao rígido controle de qualidade das juntas soldadas, existente em face dos custos de uma plataforma, é possível garantir que o processo de soldagem seja compatível com o desenhado pelo projetista. Essa variação não é considerada nas equações paramétricas, as quais, em geral, não consideram nem mesmo a existência do cordão de solda. Os parâmetros da geometria do cordão de solda, incorporados no conjunto de dados de Massaroti²⁰ e reproduzidos pelo *modelo RNA*, produziram variações de até 35% no valor do FCT.

Os valores obtidos com o *modelo RNA* são, de modo geral, menores que aqueles fornecidos pelas equações. De fato, as equações foram obtidas através de regressões aplicadas em resultados obtidos pelo MEF utilizando-se o elemento finito de casca. Conforme mostrado nas Figuras 3.7 e 3.8 são necessárias extrapolações de tensões na região da junta para definir o valor do FCT. Como, em adição, o modelo de casca não contempla a geometria do cordão de solda, os resultados fornecidos pelas equações são, via de regra, maiores que aqueles observados nos testes experimentais⁵¹.

No *Apêndice D* foram incluídos os valores de FCT para os 252 modelos analisados, e também os respectivos valores fornecidos pelas equações do LR e da UEG. Para o caso FNP a diferença média entre os valores do *modelo RNA* e as equações do LR, é de 23.8%. Comparando-se os resultados da UEG com os do LR a diferença média é de 35.8%. Essas diferenças foram obtidas tendo-se como base os resultados do LR comum nas duas comparações. Para o carregamento MNP as diferenças foram, respectivamente, 11.6% e 29%. Os resultados corroboram com o exposto no parágrafo anterior, pois os modelos de aço utilizados para levantar as equações do LR incluem o cordão de solda. Assim, é razoável que os valores do LR estejam mais próximos daqueles obtidos com o *modelo RNA* que os da UEG.

Nas figuras 6.43 a 6.51 foi avaliada a capacidade do *modelo RNA* — e também das equações mencionadas — de fornecer resultados fora de suas respectivas faixas de validade. As faixas de validade dos parâmetros do *modelo RNA* foram definidas na Tabela 3.1. Para as equações da UEG e do LR essas faixas estão definidas no *Apêndice C*.

Das Figuras 6.43 e 6.49 observa-se a variação aproximadamente quadrática do FCT com o parâmetro b , mais acentuada para o caso FNP do que para o caso MNP. As curvaturas observadas para os dois casos de carregamento vão ao encontro dos gráficos registrados por Wardenier¹¹, reproduzidos na Figura 6.52. Os intervalos de validade dos parâmetros analisados nas Figuras 6.43 a 6.49 são usualmente empregados para as equações paramétricas.

Nesse sentido, os parâmetros, à exceção de α , ou seja, L/D , apresentaram comportamentos similares para o *modelo RNA* e as equações, compatíveis também com os resultados da DNV. Embora seja recomendado o uso das equações e do *modelo RNA* dentro das faixas de parâmetros estabelecidas os valores observados indicam curvas de tendência semelhantes entre o *modelo RNA* e as equações. Dessa forma, o treinamento a partir de um conjunto de dados que englobe um intervalo maior dos parâmetros avaliados poderá ser feito a partir das configurações finais de rede obtidas para os dois casos de carregamento, com a expectativa de convergência rápida para erros médios semelhantes aos já obtidos, explorados nas Figuras 6.27 a 6.30.

A variação do FCT com o parâmetro α , ilustrada na Figuras 6.45, indica diferenças significativas para valores fora da faixa com que a rede foi treinada. Nesse caso, o ideal seria a complementação do conjunto de treinamento com dados que abrangessem um intervalo maior de α . A sensibilidade do FCT em relação ao parâmetro α está relacionada com a faixa estreita utilizada para treinar a rede no caso FNP. Porcentualmente, a variação de α no conjunto de treinamento é de pouco mais de 10%, ao passo que, para todas os outros parâmetros, os valores mínimos diferem dos máximos em mais de 100%. Assim, um estudo mais aprofundado sobre esse assunto poderá

esclarecer a variação do FCT com o parâmetro α . Para tanto, é necessário um conjunto de treinamento que contemple um intervalo maior de variação do referido parâmetro.

Observa-se, no entanto, a despeito do parágrafo anterior, que o desempenho qualitativo da rede fora dos limites dos parâmetros utilizados no treinamento é muito bom. Isso traz à tona mais uma vantagem da utilização do modelo aqui concebido, ou seja, a simulação da função que governa o fenômeno de distribuição de tensões na junta. As equações representadas nas Figuras 6.43 a 6.51 foram obtidas através de regressões sobre conjuntos de dados com os parâmetros variando nas faixas indicadas nas abscissas dos respectivos gráficos. Por outro lado, o *modelo RNA* foi treinado, via de regra, com intervalos menores de variação dos parâmetros adimensionais e ainda assim conseguiu representar adequadamente a função em pontos fora dos intervalos utilizados no treinamento. Os parâmetros \mathbf{b} e \mathbf{t} , por exemplo, foram incluídos no treinamento variando de 0.4 a 0.8. Nas equações avaliadas os mesmos parâmetros foram considerados entre 0.3 e 1.

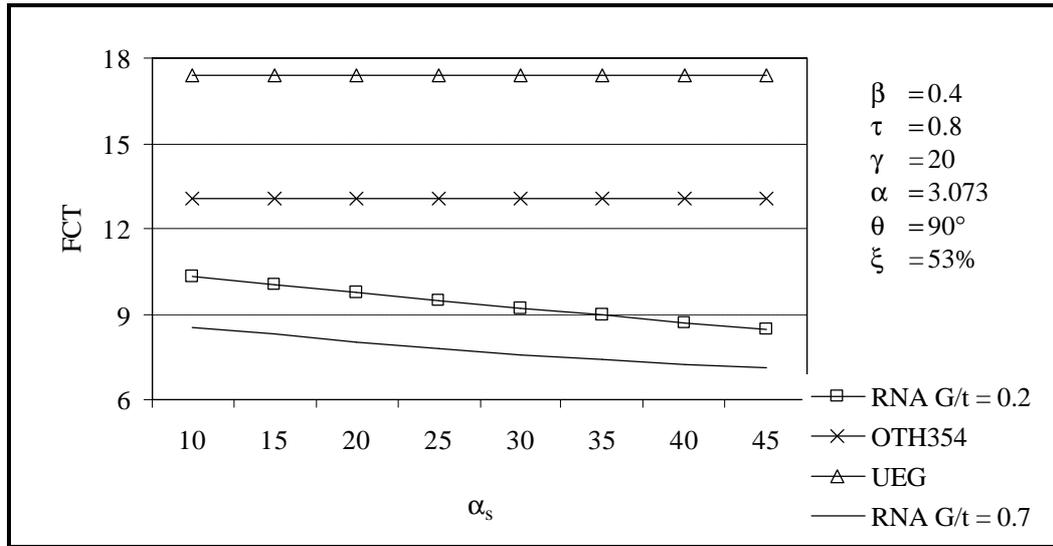


Figura 6.35 – Comparação de Resultados: RNA x Equações Paramétricas - FNP

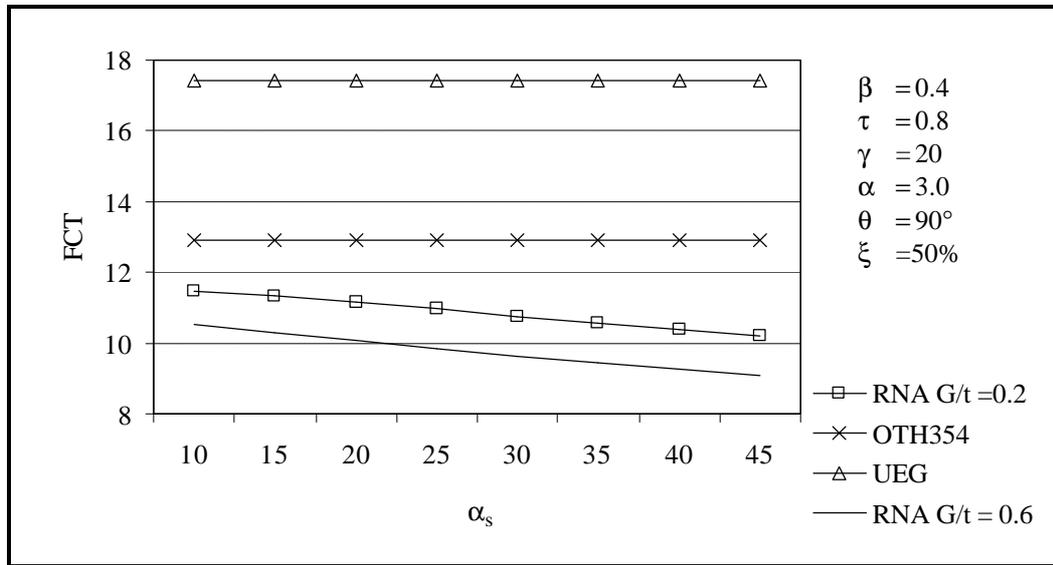


Figura 6.36 – Comparação de Resultados: RNA x Equações Paramétricas - FNP

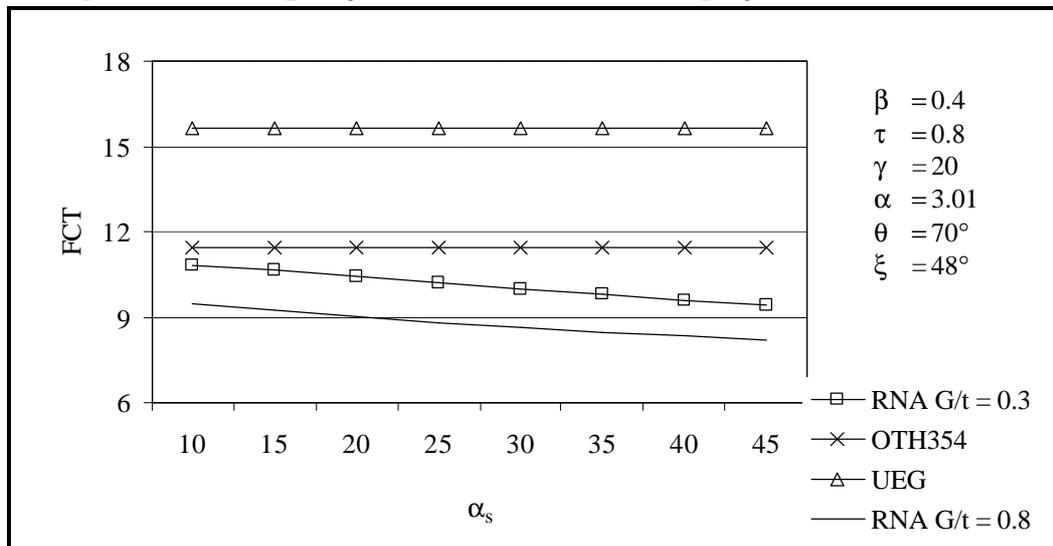


Figura 6.37 – Comparação de Resultados: RNA x Equações Paramétricas - FNP

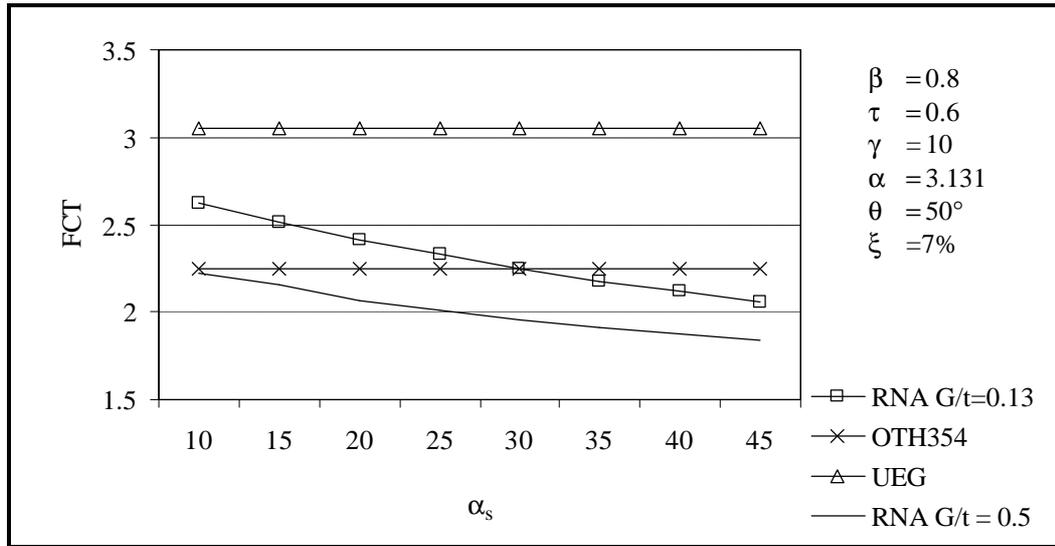


Figura 6.38 – Comparação de Resultados: RNA x Equações Paramétricas - FNP

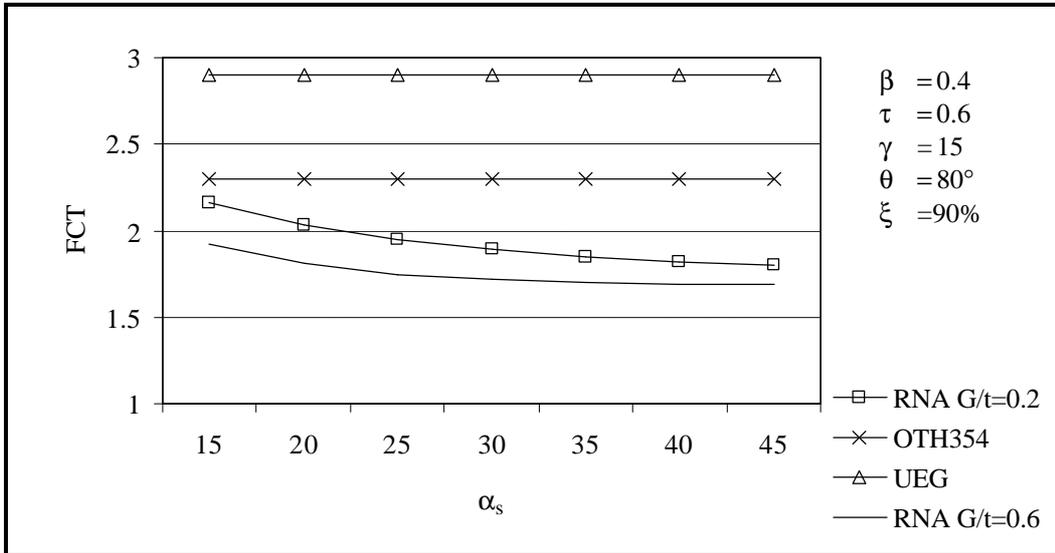


Figura 6.39 – Comparação de Resultados: RNA x Equações Paramétricas - MNP

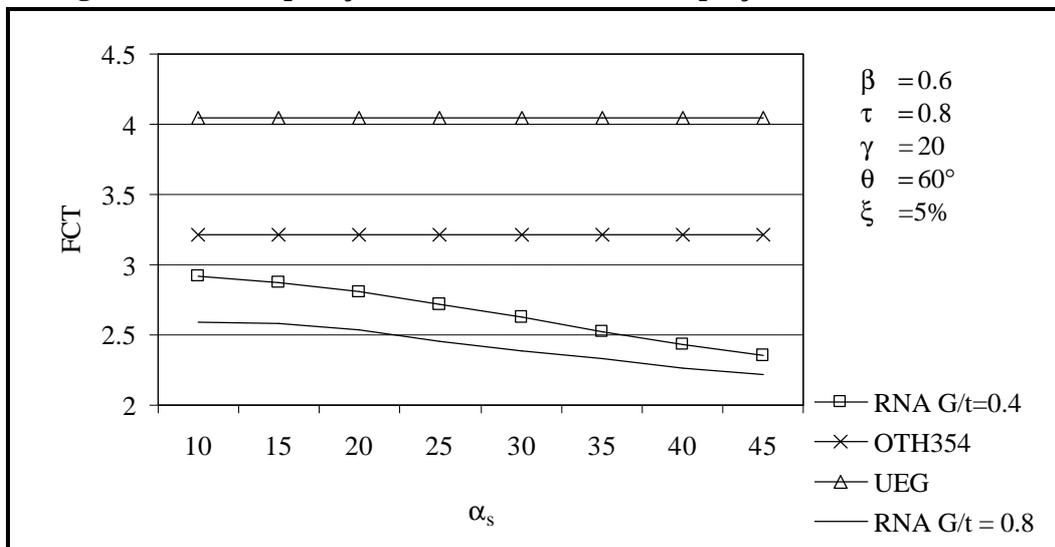


Figura 6.40 – Comparação de Resultados: RNA x Equações Paramétricas - MNP

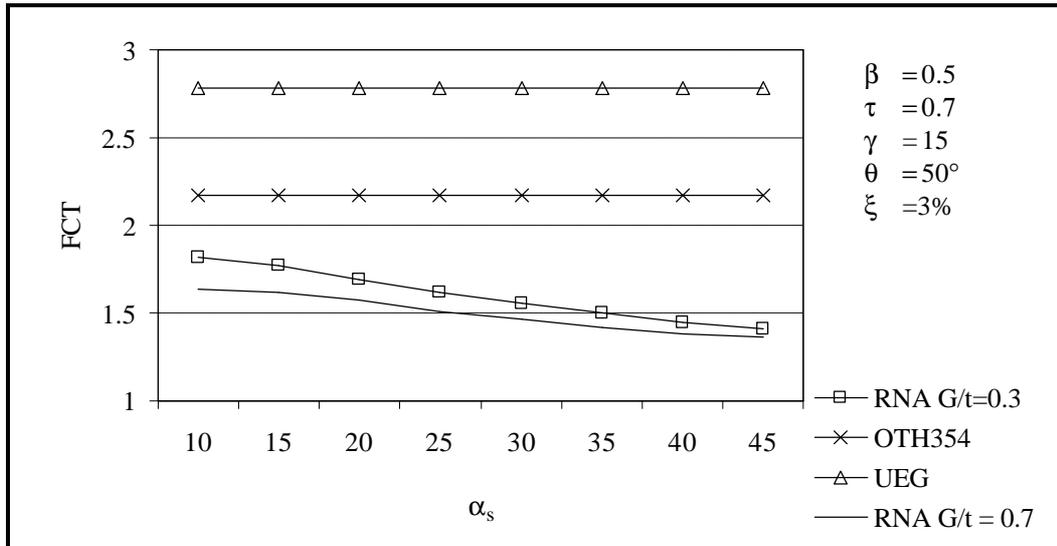


Figura 6.41 – Comparação de Resultados: RNA x Equações Paramétricas - MNP

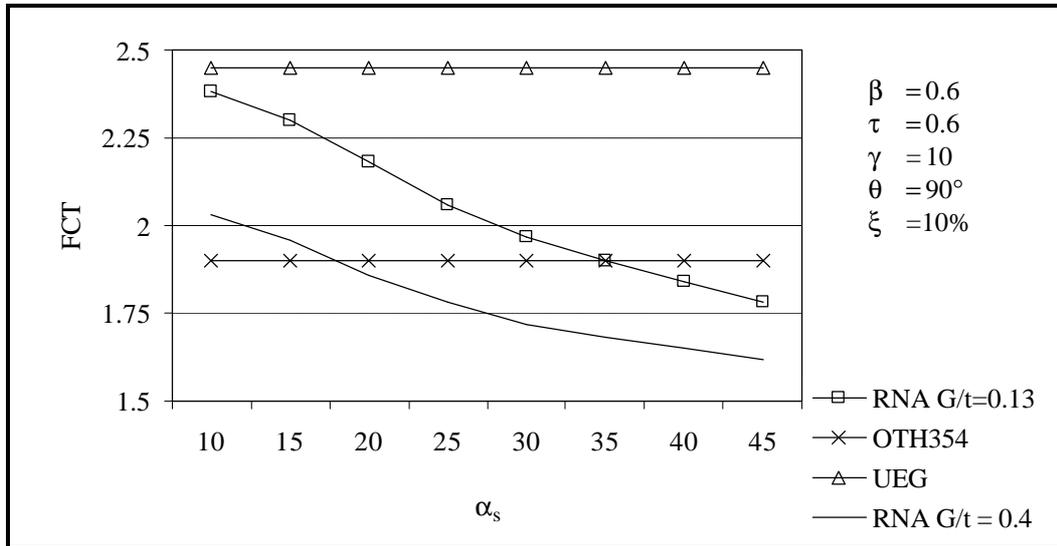


Figura 6.42 – Comparação de Resultados: RNA x Equações Paramétricas - MNP

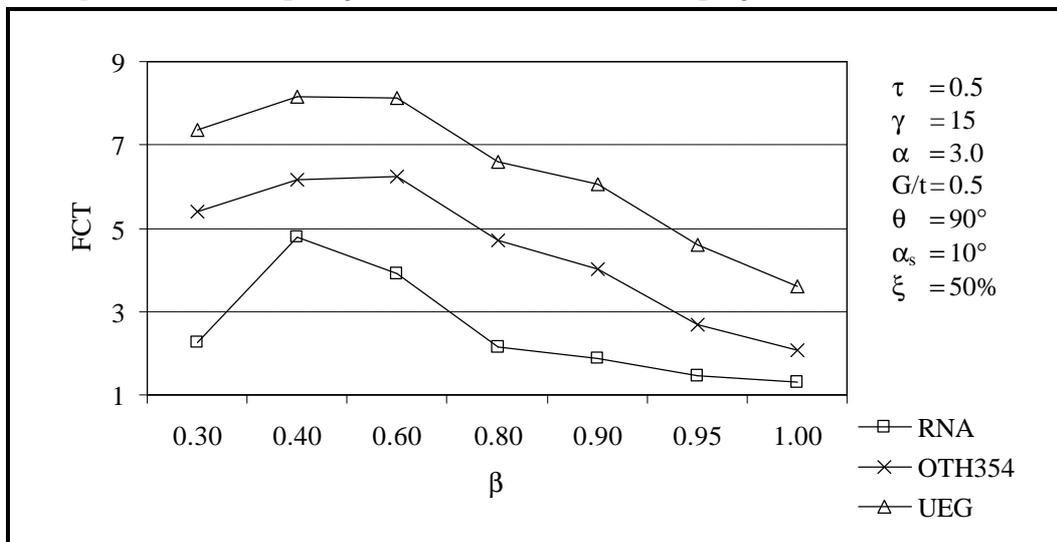


Figura 6.43 – Variação do FCT com o parâmetro b- FNP.

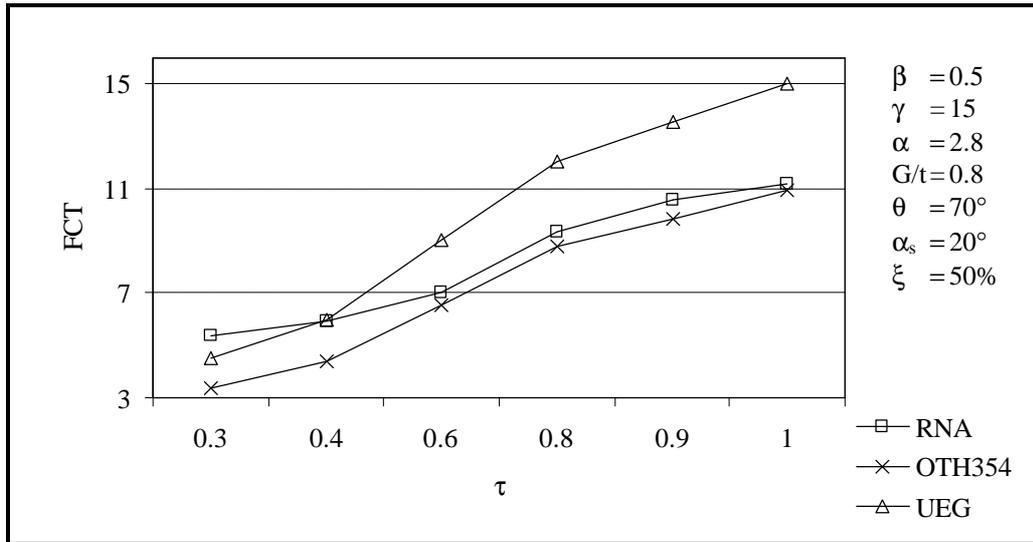


Figura 6.44 – Variação do FCT com o parâmetro τ – FNP.

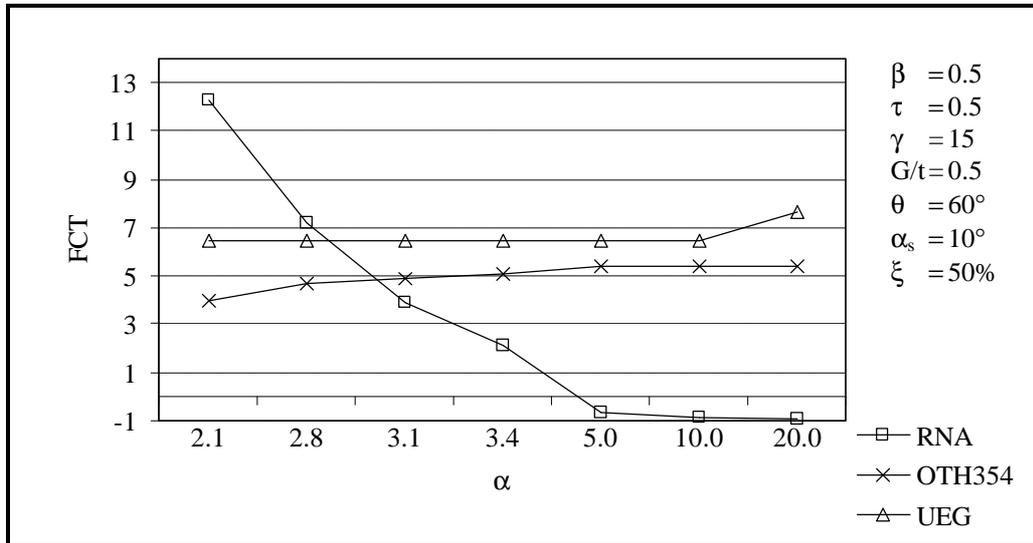


Figura 6.45 – Variação do FCT com o parâmetro α – FNP.

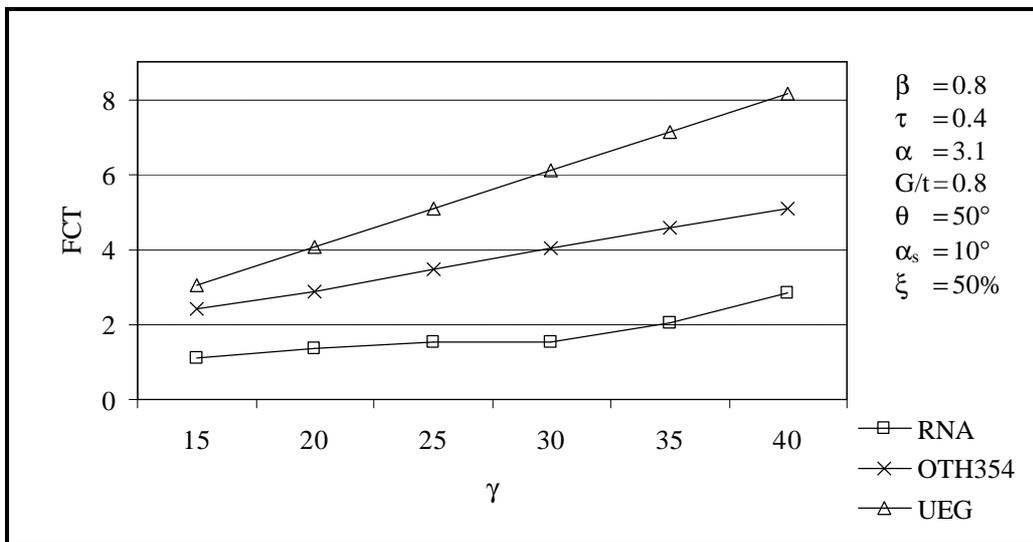


Figura 6.46 – Variação do FCT com o parâmetro γ – FNP.

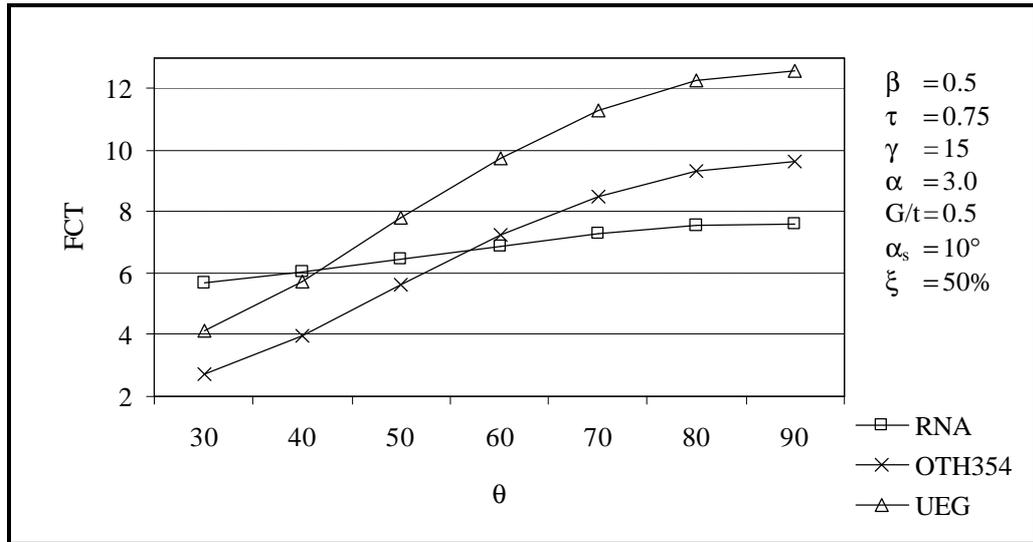


Figura 6.47 – Variação do FCT com o parâmetro q– FNP.

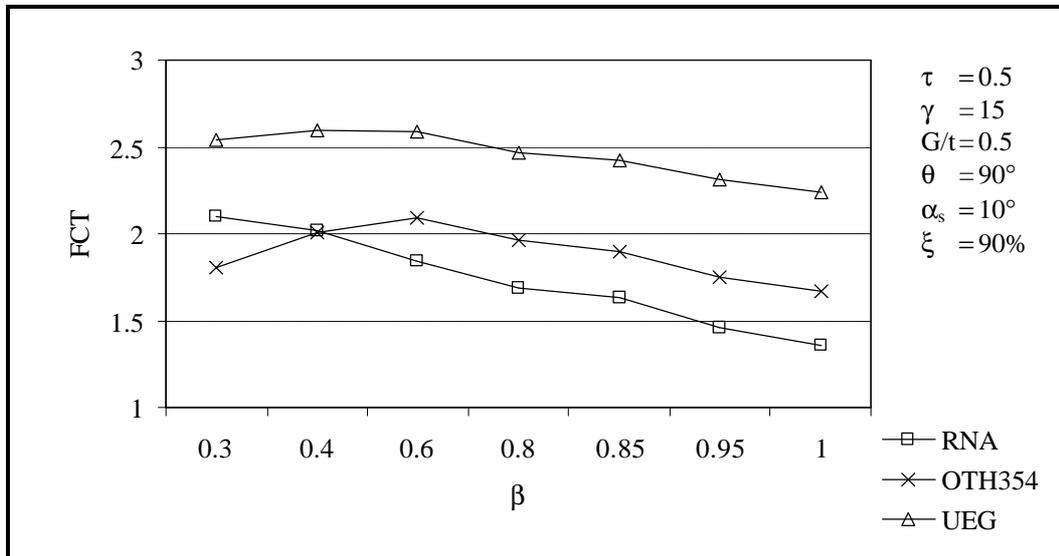


Figura 6.48 – Variação do FCT com o parâmetro b– MNP.

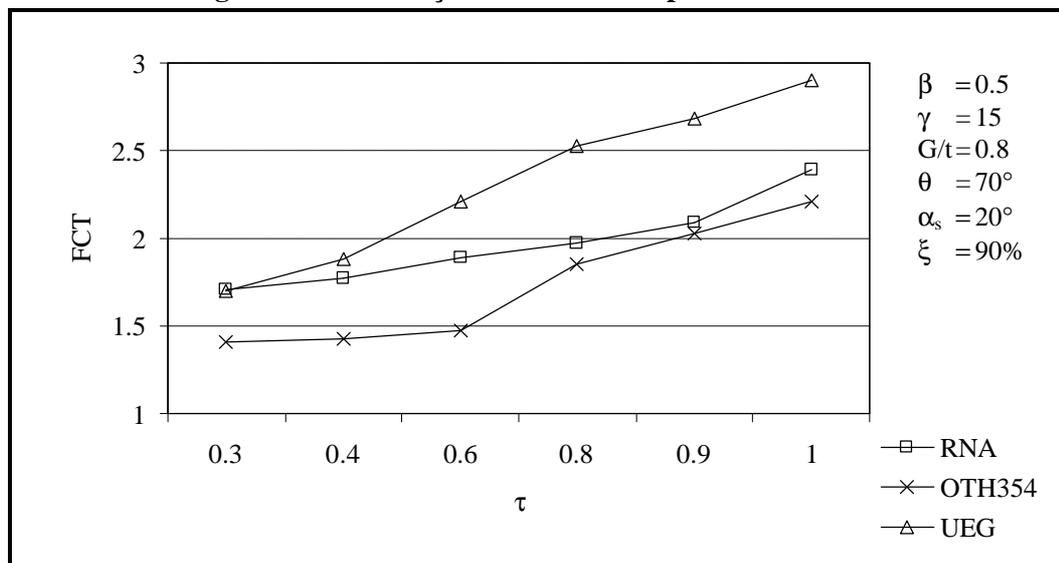


Figura 6.49 – Variação do FCT com o parâmetro t– MNP.

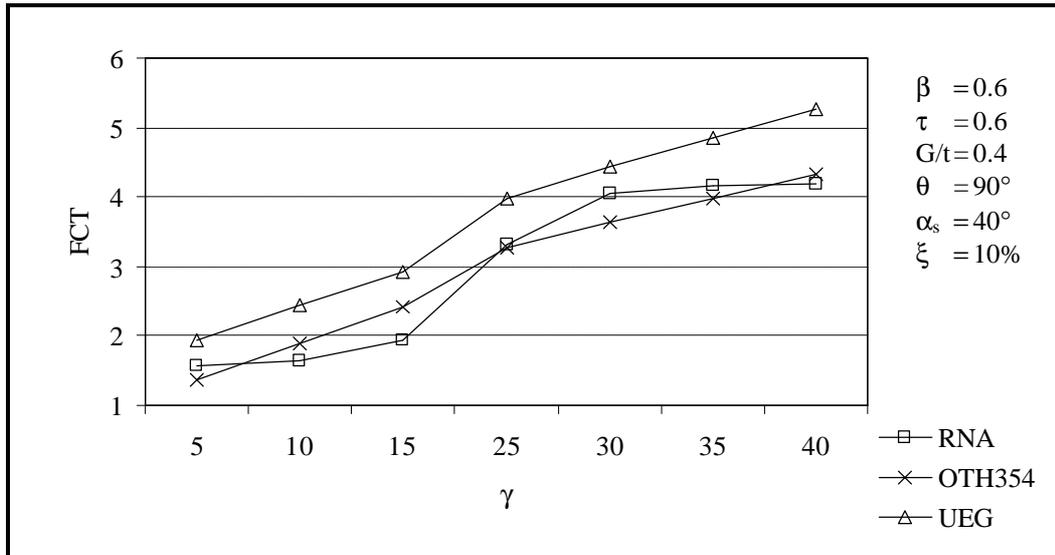


Figura 6.50 – Variação do FCT com o parâmetro γ – MNP.

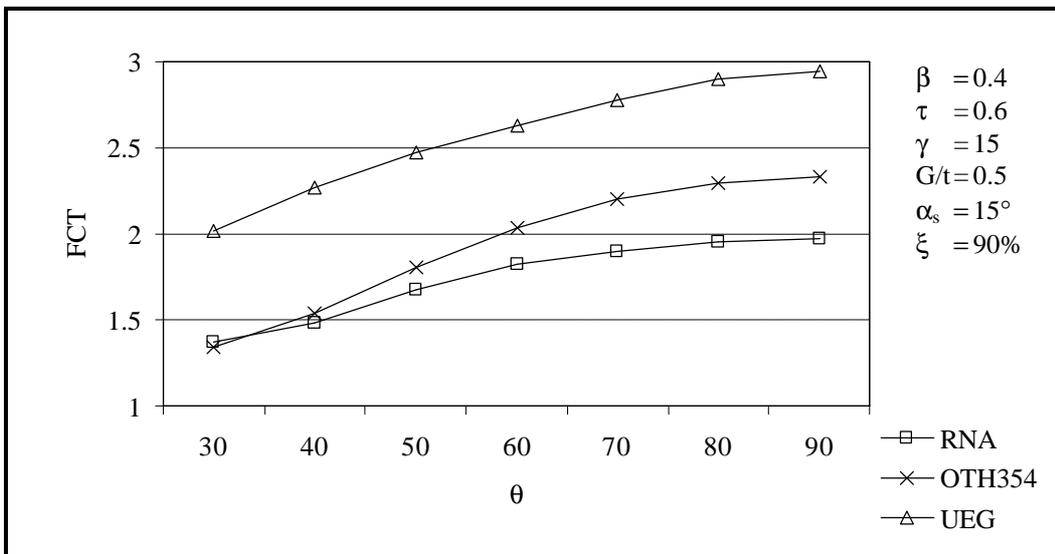


Figura 6.51 – Variação do FCT com o parâmetro θ – MNP.

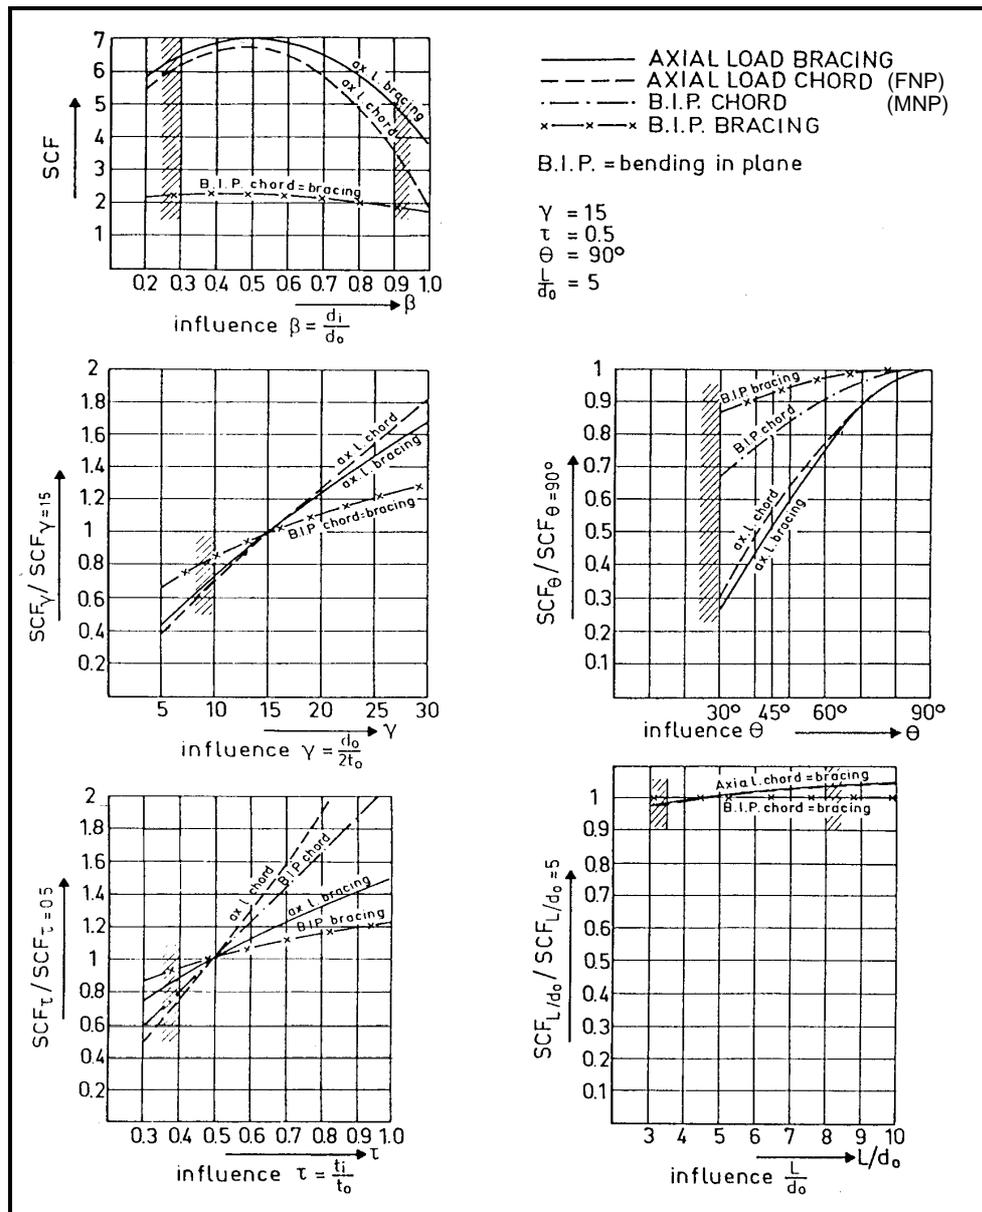


Figura 6.52 – Variação do FCT com os Parâmetros da Junta¹¹.

6.4 Comparação de Resultados: RNA x Ensaios em Bancos de Prova.

A principal dificuldade para comparar resultados provenientes de ensaios em bancos de prova, ou simplesmente ensaios, é encontrar, na literatura, valores de FCT obtidos por esse meio. Em geral, os resultados de ensaios experimentais não são publicados e, sim, as equações paramétricas originadas a partir deles. Foram utilizados resultados levantados em programas patrocinados pelo Departamento de Energia Britânico^{51,65,66}.

Nas Figuras 6.53 a 6.60 foram comparados os resultados do modelo RNA com os resultados de ensaios. Como os resultados dos ensaios são conhecidos em apenas três pontos admitiu-se uma curva passando por esses pontos, conforme mostrado naquelas figuras.

Em alguns casos, como por exemplo nas Figuras 6.53 e 6.55, foram utilizados parâmetros fora da faixa de valores definida na Tabela 3.1. Acredita-se, no entanto, de acordo com o discutido no item anterior, que as extrapolações dos parâmetros τ e γ , sejam aceitáveis nos casos em que foram aplicadas.

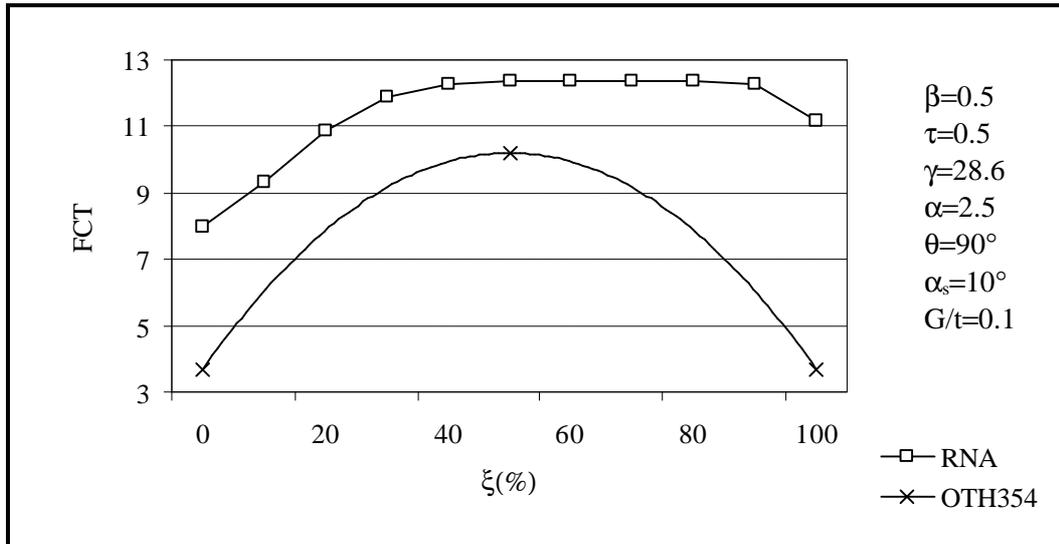


Figura 6.53 – Comparação dos Resultados da RNA com Ensaio Experimentais – FNP.

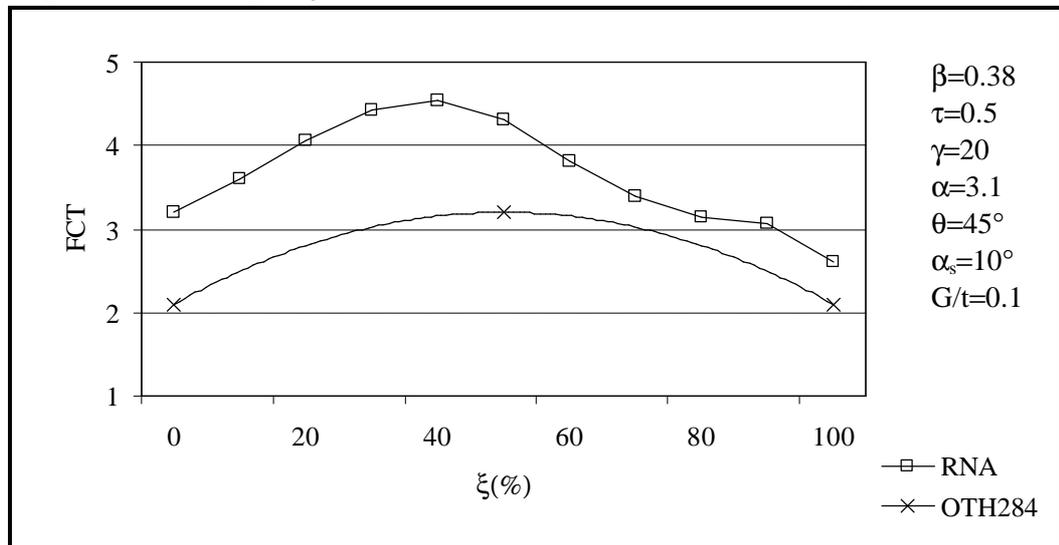


Figura 6.54 – Comparação dos Resultados da RNA com Ensaio Experimentais – FNP.

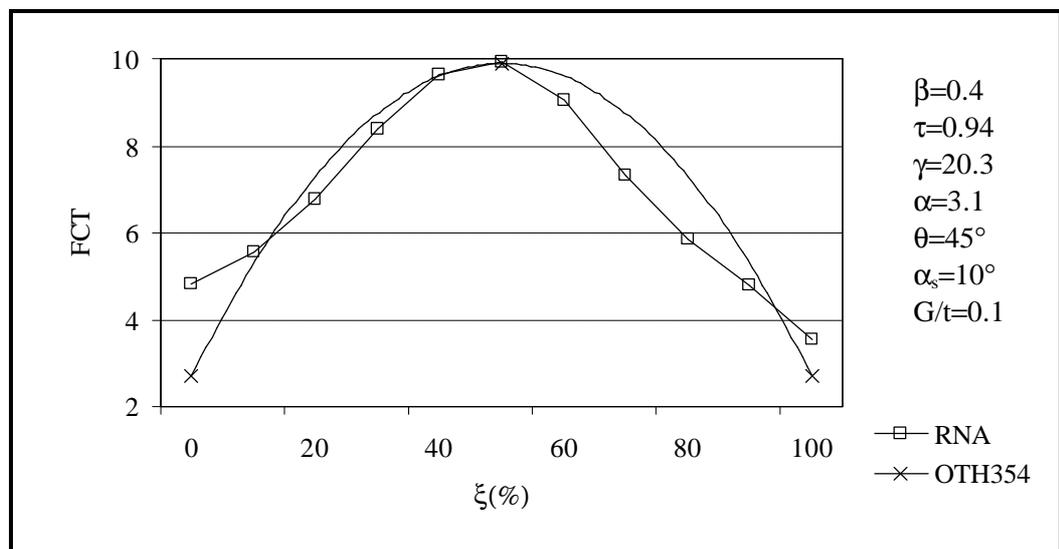


Figura 6.55 – Comparação dos Resultados da RNA com Ensaio Experimentais – FNP.

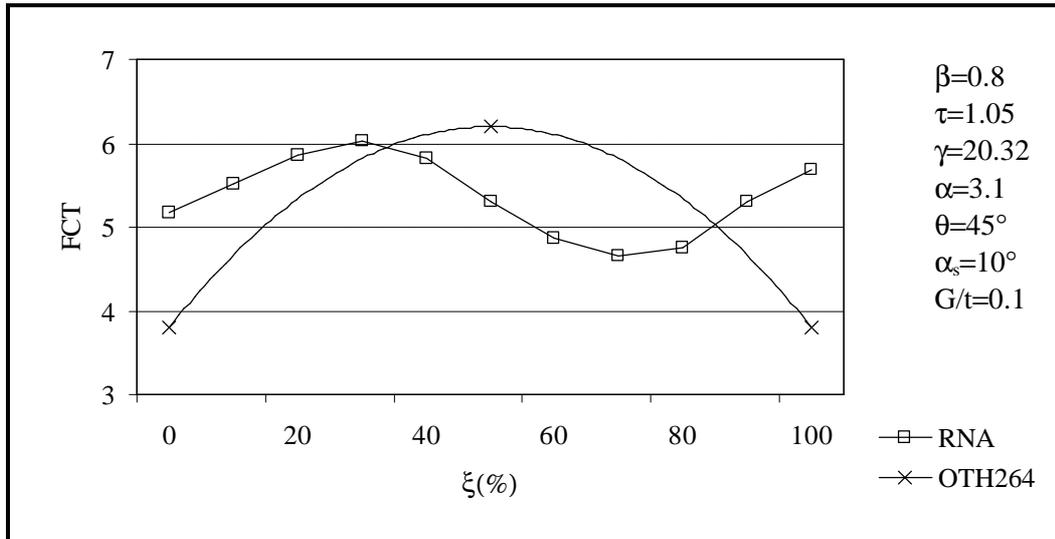


Figura 6.56 – Comparação dos Resultados da RNA com Ensaio Experimentais – FNP.

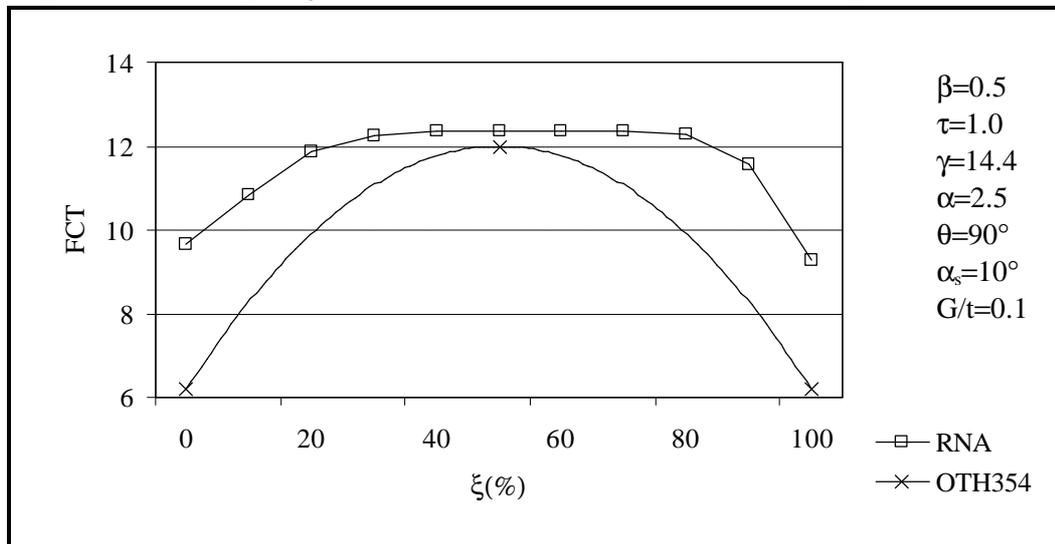


Figura 6.57 – Comparação dos Resultados da RNA com Ensaio Experimentais – FNP.

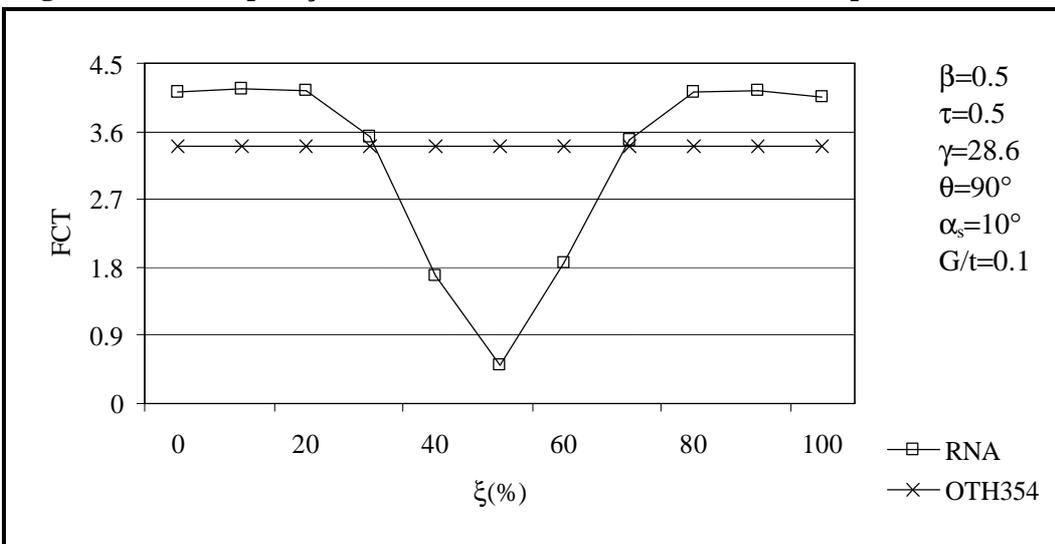


Figura 6.58 – Comparação dos Resultados da RNA com Ensaio Experimentais – MNP.

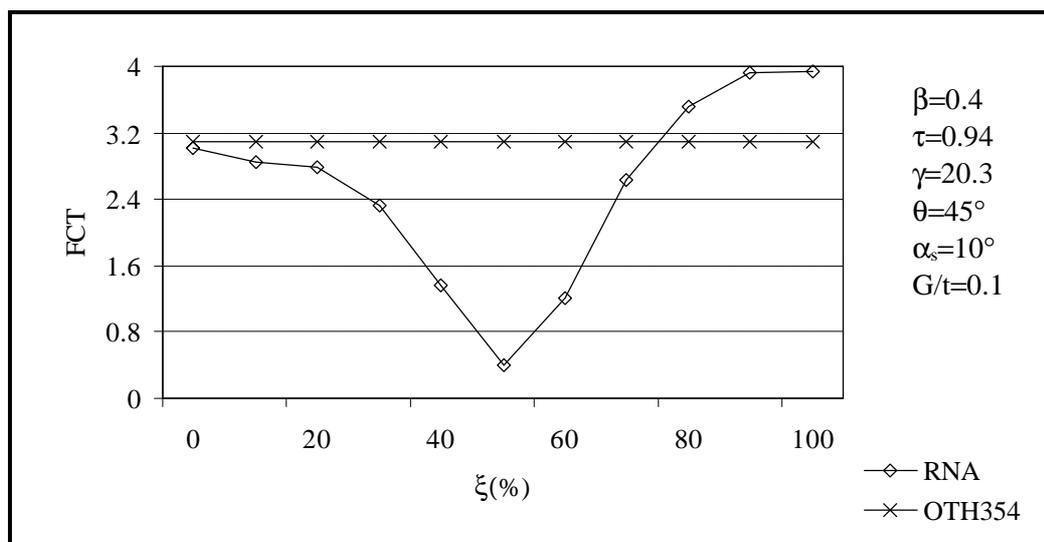


Figura 6.59 – Comparação dos Resultados da RNA com Ensaios Experimentais – MNP.

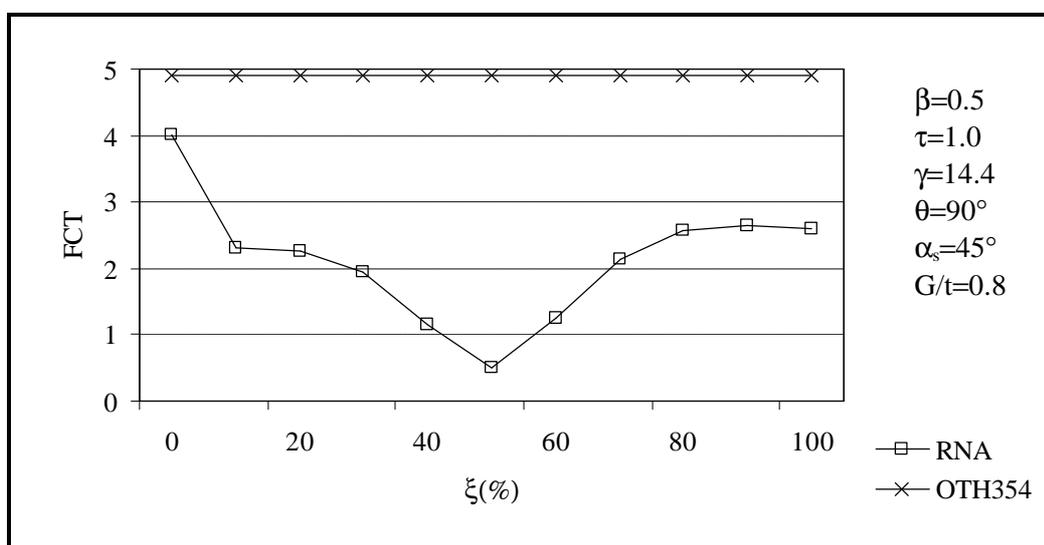


Figura 6.60 – Comparação dos Resultados da RNA com Ensaios Experimentais – MNP.

De um modo geral, o projeto da estrutura tubular é guiado pela espessura necessária para que a junta resista aos carregamentos a ela impostos. Adicionalmente, pode-se perceber que os valores de FCT calculados pelas formulações tradicionais indicam valores superiores àqueles calculados pelo modelo utilizado para a elaboração da RNA, o que, sem dúvida, penaliza o peso da estrutura. Um valor de FCT mais realista, considerando um modo de cálculo de tensões mais preciso como o utilizado nesse trabalho pode, sem equívoco, reduzir esse efeito e gerar estruturas mais leves, melhorando suas condições de fabricação, operação e manutenção.

CAPÍTULO 7

CONCLUSÕES E PERSPECTIVAS

Os objetivos de estabelecer um modelo de cálculo do fator de concentração de tensões em juntas soldadas e, ainda, que pudesse representar a distribuição de tensões ao longo do cordão de solda foram alcançados, conforme explanado no decorrer desse trabalho e realçado no capítulo anterior.

Com efeito, as incertezas suscitadas no processo de definição das equações paramétricas provocam a inclusão de fatores de segurança que o procedimento discutido nesse trabalho não exige ou pelo menos, minimiza. Entenda-se, pois, a importância não só da modelagem com RNA, mas também do levantamento do conjunto de dados nas bases do trabalho de Massaroti²⁰, incluindo a geometria do cordão de solda. Sabe-se que os dois modelos, equações paramétricas e RNA, não contemplam as tensões de entalhe, provocadas pelo processo de soldagem e, portanto, ainda existirão incertezas para avaliar o valor real das tensões na junta. A existência dessas tensões é considerada no levantamento das *curvas S-N*, usualmente utilizadas na definição de critérios de projeto para as juntas.

O *modelo RNA* emerge, então, como uma nova e poderosa ferramenta para avaliação das concentrações de tensões em juntas soldadas, com a qual é possível representar de modo mais realista a distribuição de tensões nessas juntas. Com isso, é possível determinar as características geométricas das juntas para carregamentos combinados, por exemplo FNP e MNP, sem a necessidade de empregar os valores

máximos de cada caso. Um enfoque menos conservador no cálculo do FCT pode trazer, como consequência, uma estrutura mais leve e mais econômica, em face do elevado número de juntas soldadas na estrutura de uma plataforma.

Deve-se entender, no entanto, que o emprego de RNA não é uma panacéia e como toda ferramenta de cálculo apresenta vantagens e desvantagens, conforme mostrado nos capítulos 5 e 6. Ainda assim, o emprego de redes neurais artificiais no cálculo da distribuição de tensões em juntas soldadas é uma opção viável e de fácil utilização. Com algumas linhas de código, em uma linguagem de programação de computador, pode-se implementar as configurações de pesos, estabelecidas no *Apêndice A*, que representam o “conhecimento” da rede no cálculo da distribuição de tensões em juntas soldadas. A bem da verdade, diga-se que os primeiros ensaios feitos com RNA nessa pesquisa foram somente para o cálculo do FCT. Uma vez percebido o potencial da ferramenta foram incluídos os pontos ao longo do cordão de solda.

Nesse contexto, a utilização de redes neurais artificiais no cálculo de FCT pode ser estendida para outras geometrias de juntas (X, K, K-T, etc.), desde que existam conjuntos de dados representativos dessas geometrias. Em adição, sugere-se que nestes dados estejam computados também os parâmetros representativos da geometria do cordão de solda, uma vez que a ferramenta RNA consegue simular inclusive essa geometria.

Outro emprego potencial de RNA é no cálculo dos limites de resistência das juntas soldadas. Esses limites são calculados de modo semelhante ao feito atualmente para o FCT, isto é, levantamento de dados através de ensaios em bancos de prova e

desenvolvimento de equações baseadas em regressões que ajustam curvas sobre os dados colhidos^{67,68}.

Como sugestão para futuros trabalhos está a inclusão de um novo parâmetro para representar o valor da tensão na seção do cordão de solda, o que forneceria subsídios para uma melhor compreensão da distribuição de tensões na região do cordão de solda, uma vez que praticamente não existem referências na literatura sobre esse assunto. Assim, novas investigações no âmbito das RNA com o objetivo de acelerar o processo de treinamento talvez sejam necessárias, dado que o conjunto de treinamento pode chegar a ordem de 100000 pontos. Nesse caso, é recomendada a utilização do algoritmo de apresentação aleatória dos pares de treinamento discutido no *Apêndice A*.

Finalizando, sugere-se que os problemas enfrentados durante essa pesquisa, esclarecidos no capítulo 5, e as soluções adotadas sejam avaliadas em novos desenvolvimentos evitando-se, assim, que caminhos inglórios sejam trilhados novamente.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Marshall, *Design of Welded Tubular Connections*, Elsevier, Amsterdam, 1992.
2. Visser, W., *On the Structural Design of Tubular Joints*, Proceedings of 6th Offshore Technology Conference, Houston, 1974.
3. Kallaby, J., Price, J.B., *Evaluation of Fatigue Considerations in the Design of Framed Offshore Structures*, Proceedings of 8th Offshore Technology Conference, Houston, 1976.
4. Gibstein, M. B., Moe, E.T., *Numerical and Experimental Stress Analysis of Tubular Joints with Inclined Braces*. Proceedings of International Conference Steel in Marine Structures, Paris, October, 1981.
5. Rhee, H.C., Salama, M.M., *On the Evaluation of Stress Intensity Factor for Tubular Joint Fatigue Study*, Proceedings of 17th Offshore Technology Conference, Houston, 1985.
6. Duncan, W., Dharmavasan, S., *Fatigue Fracture Mechanics Analysis of T and Y Joints*, Proceedings of 14th Offshore Technology Conference, Houston, 1985.
7. Huang, X., Du, Z., Hancock, J.W., *A Finite Element Evaluation of the Stress Intensity Factors of Surface Cracks in a Tubular Joint*, Proceedings of 20th Offshore Technology Conference, Houston, 1985.
8. AWS- American Welding Society – *Structural Welding Code: Steel*, 10^a ed., Miami, 1986.
9. American Petroleum Institute, *Recommended Practice for Planning, Designing and Constructing Fixed Offshore Platforms: APIR2A.*, 1984.
10. Gibstein, M. B., Moe, E.T., *Fatigue Strength of Welded Tubular Joints Tested at Det Norske Veritas Laboratories*, Proceedings. of International Conference Steel in Marine Structures, Paris, October, 1981.
11. Wardenier, J., *Hollow Section Joints*, Delft University Press, Delft, 1982.
12. Graff, W.J., *Introduction to Offshore Structures*, Gulf Publishing Company, 1981.
13. Branco, C.M., Fernandes, A.A., Castro, P.M.S.T., *Fadiga de Estruturas Soldadas*, Fundação Calouste Gulbenkian, Lisboa, 1986.
14. Humes, A.F. et al. *Noções de Cálculo Numérico*, McGrawHill, São Paulo, 1984.
15. Allen, D.M., Cady, F.B., *Analyzing Experimental Data by Regression*, Wadsworth, Belmont, 1982.
16. Efthymiou, M., Durkin, S. *Stress Concentration in T/Y and Gap/Overlap K-Joints*. Proceedings of 4th International Conference on Behavior of Offshore Structures, Delft, 1985.
17. Kuang, J.G., Potvin, A.B., Leick, R.D., *Stress Concentration in Tubular Joints*, Proceedings of 7th Offshore Technology Conference, Houston, 1975.

18. Wordsworth, A. C., *Aspects of the Stress Concentration Factors at Tubular Joints*, Steel in Marine Structures, Amsterdam, 1987.
19. UEG, *Design of Tubular Joints for Offshore Structures*, London, 1985.
20. Massaroti, V.M., *Concentração de Tensões em Juntas Tubulares Tipo Y: Análise da Influência da Geometria do Cordão de Solda*, Tese de Doutorado, EPUSP, 1997.
21. Mukherjee, A., Deshpande, M., *Modeling Initial Design Process Using Artificial Neural Networks*, Journal of Computing in Civil Engineering, Vol.9,n.3, 1995.
22. Barai, S.V., Pandey, P.C., *Vibration Signature Analysis using Artificial Neural Networks*, Journal of Computing in Civil Engineering, Vol.9,n.4, 1995.
23. Wu, X., Ghaboussi, J., Garrett, J.H., Rajasekaran, S., *Use of Neural Networks in Detection of Structural Damage*, Computer & Structures, vol.42, 1992.
24. Szewczyk, Z.P., Hajela, P., *Damage Detection in Structures Based on Feature-Sensitive Neural Networks*, Journal of Computing in Civil Engineering, Vol.8, n.2, p.163-178, 1994.
25. Berke, L., Patnaik, S.N., Murthy, P.L.N., *Optimal Design of Aerospace Structural Components Using Neural Networks*, Computer & Structures, 48, 1993.
26. Sadek, E. A., *Optimization of Structures Having General Cross-Sectional Relationships Using an Optimality Criterion Method*, Computer & Structures, Vol.43, n.5, 1992.
27. Kang, J., Song, Ji-Ho, *Neural Network Applications in Determining the Fatigue Crack Opening Load*, International Journal of Fatigue, n.1, vol.20, 1998.
28. Almar, A., *Fatigue Handbook – Offshore Steel Structures*, TAPIR, Oslo, 1985.
29. Welstead, S.T., *Neural Network and Fuzzy Logic Applications in C/C++*, Wiley, New York, 1994.
30. Wasserman, P.D., *Neural Computing: Theory and Practice*, Wiley & Sons, New York, 1992.
31. Wasserman, P.D., *Advanced Methods in Neural Computing*, Van Nostrand Reinhold, New York, 1993.
32. Rumelhart, D.E., McClelland, J.L., *Parallel Distributed Processing: Explorations in the Micro-Structures of Cognition*, Vol.1, MIT Press, Cambridge, 1986.
33. Fremann, J.A., Skapura, D.M. *Neural Networks – Algorithms, Applications, and Programming Techniques*, Addison-Wesley, New York, 1991.
34. Rumelhart, D.E., McClelland, J.L., *Parallel Distributed Processing: Explorations in the Micro-Structures of Cognition*, Vol.2, MIT Press, Cambridge, 1986.
35. MacLennan, *Characteristics of Connectionist Knowledge Representation*, Technical Report CS-91-147, Univ. of Tennessee, 1991.
36. Holliday, G.H., Graff, W.J., *Three-Dimensional Photoelastic Analysis of Welded T-Connections*, Proceedings of 3th Offshore Technology Conference, Houston, 1971.

37. Bijlaard,P.P , *Stresses From Local Loadings in Cylindrical Pressure Vessels*, Transactions of the ASME, v.08, 1955.
38. Bijlaard,P.P , *Stresses From Radial Loads in Cylindrical Pressure Vessels*, The Welding Journal, vol.33, 1954.
39. Bouwkamp, J.G., *Concepts of Tubular-Joint Design*, Journal of the Structural Division, ASCE, April, 1964.
40. Carter,R.M., Marshall,P.W., Thomas,P.D., *Materials Problems in Offshore Platforms*, Proceedings of 1th Offshore Technology Conference, Houston, 1969.
41. Toprac,A.A., Johnston,L.P., Noel,J., *Welded Tubular Connections: an investigation of stress in T joints*, Welding Research Supplement, n.1, vol. 31, 1966.
42. Leick, R.D., Potvin, A.B., *Automated Mesh Generation for Tubular Joint Stress Analysis*, Computer & Structures, vol.7, p.73-91, 1977.
43. Scordelis,A.C., Bouwkamp, J.G., *Analytical Study of Tubular T-joints*, Journal of the Structural Division, ASCE, January,1970.
44. Reber,J.B., *Ultimate Strength Design of Tubular Joints*, Journal of the Structural Division, ASCE, June,1973.
45. Kwan,C., Graff,W.J., *Analysis of Tubular T-Connections by the Finite Element Method: Comparison with Experiments*, Proceedings of 4th Offshore Technology Conference, Houston, 1972.
46. Liaw, C.Y., Litton,R.W., Reimer,R.B., *Improved Finite Elements for Analysis of Welded Tubular Joints*, Proceedings of 8th Offshore Technology Conference, Houston, 1976.
47. Gibstein, M. B., Moe, E.T., *Fatigue of Tubular Joints*, DNV, Oslo, 1984.
48. Dijkstra, O.D., *Fatigue Strength of Tubular T- and X-joints*, Proceedings of 12th Offshore Technology Conference, Houston, 1980.
49. Lieurade, H.P., *Fatigue Life Prediction of Tubular Nodes*, Proceedings of 12th Offshore Technology Conference, Houston, 1980.
50. Callan, M.D., *BP Magnus Platform Internally Stiffened Bracing Node Studies*, Proceedings of 13th Offshore Technology Conference, Houston, 1981.
51. Lloyd's Register of Shipping, *OTH354- Stress Concentration Factors for Simple Tubular Joints*, Offshore Technology Report – HSE, London, 1997.
52. ALGOR, *Finite Element Analysis System*, Algor Interactive System Inc, 1997.
53. McCulloch W.S., Pitts, W., *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, vol. 5, 1943.
54. Haykin, S., *Neural Networks – A Comprehensive Foundation*, Prentice Hall, New Jersey, 1994.
55. Hebb, D.O., *The Organization of Behavior: A Neuropsychological Theory*, Wiley&Sons, New York, 1949.
56. Roseblatt, F., *Principles of Neuro-Dynamics*, Spartan Books, Washington, 1962.

57. Widrow, B., *Generalization and Information Storage in Networks of ADALINE "neurons"*, In *Self-Organization Systems*, p.435-461, Sparta, Washington, 1962.
58. Cichocki, A., Unbehauen, R., *Neural Networks for Optimization and Signal Processing*, Wiley, New York, 1995.
59. Minsky, M. Pappert, S., *Perceptrons*, MIT Press, Cambridge, 1969.
60. Parker, D.J., *Learning-logic: Casting the Cortex of the Human Brain in Silicon*, Technical Report - TR 47. Center for Computational Research in Economics and Management Science, MIT, Cambridge. 1985.
61. LeCun, Y., *Une Procédure D'apprentissage pour Réseau a Seuil Assymetrique*, *Cognitiva* 85, 500-604, 1985.
62. Werbos, P.J., *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences.*, Ph.D. Thesis, Harvard University, Cambridge, 1974.
63. Rylo, Márcio, *Notas de Aula do Curso PEE817 – Introdução à Inteligência Artificial*, EPUSP, junho, 1996.
64. Schiffmann, W., Joost, M., Werner, R., *Optimization of the Backpropagation Algorithm for Training Multilayer Perceptrons*, University of Koblenz, Koblenz, 1994.
65. UK Department of Energy, *OTH87-264-Elastic Stress Concentration Factor (SCF) Tests on Tubular Steel Joints*, HMSO Books, London, 1988.
66. UK Department of Energy, *OTH88-284- Stress Concentration Factor Data from Large Scale Tubular Joints*, HMSO Books, London, 1988.
67. Kurobane, Y. et al., *A New Ultimate Capacity Formula for Unstiffened CHS T, TT and K-Joints Under Axial Brace Loads*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
68. Makino, Y., Wilmshurst, S .R., Kurobane, Y., *Additional Tests of CHS Planar KK-Joints Under Anti-Symmetrical Axial Loads*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
69. Kóvacs, Z.L., *Redes Neurais Artificiais – Fundamentos e Aplicações*, Editora Acadêmica, São Paulo, 1996.

BIBLIOGRAFIA RECOMENDADA

- 1 Abel A., Yu, X., *Multiaxial Fatigue in Offshore Tubular Joints*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
- 2 Baldi, P.F., Hornik, K., *Learning in Linear Neural Networks: A Survey*, IEEE Transactions on Neural Networks, vol.6, n.3, 1995.
- 3 Becker, J.M., *Fatigue Failure of Welded Tubular Joints*, Proceedings of 2th Offshore Technology Conference, Houston, 1970.
- 4 Bennett, R.W., *Design for Welding Offshore Structures*, Proceedings of 2th Offshore Technology Conference, Houston, 1970.
- 5 Bignonnet, A., et al, *The Influence of Cathodic Protection and Post Weld Improvement on the Fatigue Resistance of Steel Welded Joints*, Steel in Marine Structures, Amsterdam, 1987.
- 6 Billington, C.J., Lalani, M., Tebbett, I.E., *Background to New Formulas for the Ultimate Limit State of Tubular Joints*, Proceedings of 14th Offshore Technology Conference, Houston, 1982.
- 7 Brink, S.H. van den, Ter Avest, F.J., *Assessment of the Fracture Toughness Properties of Material in Welded Tubular Joints*, Steel in Marine Structures, Amsterdam, 1987.
- 8 Campo, J.J., et al., *Improved Analytical Techniques Utilized in the Design of the Deepwater Namorado Platform*, Proceedings of 11th Offshore Technology Conference, Houston, 1979.
- 9 Cardoso, A.A., Augusto, O.B., *Cálculo de Concentração de Tensões em Juntas Tubulares utilizando Redes Neurais Artificiais*, XV Congresso Panamericano de Engenharia Naval, Transporte Marítimo e Engenharia Portuária, Montevideo, 1997.
- 10 Chen, H.M., et al., *Neural Networks for Structure Control*, Journal of Computing in Civil Engineering, Vol.9, n.2, 1995.
- 11 Chiew, S.P., Soh, C.K., Fung, T.C., *Large Scale Testing of a Multiplanar Tubular DX-Joint*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
- 12 Davidson, J.W., Goulter, I.C., *Evolution Program for Design of Rectilinear Branched Networks*, Journal of Computing in Civil Engineering, Vol.9, n.2, 1995.
- 13 Elkordy, M.F., Chang, K.C., Lee, G.C., *Neural Networks Trained by Analytically Simulated Damage States*, Journal of Computing in Civil Engineering, Vol.7, 1993.
- 14 Elman, J.L., *Incremental Learning, or the Importance of Starting Small*, Center for Research in Language Technical Report 9101, San Diego, 1991.
- 15 Engesvik, K., Lassen, T., *The Effect of Weld Geometry on Fatigue Life*, Proceedings of 14th Offshore Technology Conference, Houston, 1982.

- 16 Ergezinger, S., Thomsen, E., *An Accelerated Learning Algorithm for Multilayer Perceptrons: Optimization Layer by Layer*, IEEE Transactions on Neural Networks, Vol.6, n.1, 1995.
- 17 Fessler, Henry, Edwards, C.D., *Comparison of Stress Distributions in a Simple Tubular Joint Using 3-D Finite Element, Photoelastic and Strain Gauge Techniques*, Proceedings of 15th Offshore Technology Conference, Houston, 1983.
- 18 Flood, I., Kartam, N., *Neural Networks in Civil Engineering. I: Principles and Understanding*, Journal of Computing in Civil Engineering, Vol.8, n.2, 1994.
- 19 Flood, I., Kartam, N., *Neural Networks in Civil Engineering. I: Systems and Application*, Journal of Computing in Civil Engineering, Vol.8, n.2, 1994.
- 20 Freire, J.L.F., *Análise de Tensões em Junções Tubulares do Tipo T Via Fotoelasticidade Tridimensional*, VII Congresso Brasileiro de Engenharia Mecânica, Uberlândia, 1983.
- 21 Geyer, J.F., Stahl, B., *Simplified Fatigue Design Procedure for Offshore Structures*, Proceedings of 18th Offshore Technology Conference, Houston, 1986.
- 22 Godfrey, G.B., *Joints in Tubular Structures*, The Structural Engineer, London, April, 1959.
- 23 Gulati, K.C., Wang, W.J., Kan, D.K.Y., *An Analytical Study of Stress Concentration Effects in Multibrace Joints Under Combined Loading*, Proceedings of 14th Offshore Technology Conference, Houston, 1982.
- 24 Hajela, P., Berke, L., *Neurobiological Computation Models in Structural Analysis and Design*, Computers & Structures, Vol.41, n.4, 1991.
- 25 Hanna, S.Y., et al., *Fatigue Design Considerations for Deepwater Fixed Platforms*, Proceedings of 16th Offshore Technology Conference, Houston, 1984.
- 26 Huther, M., Bury, D., Zehri, M., *Selection of a S-N Curve for Design – Difficulties and State of Art*, Steel in Marine Structures, Amsterdam, 1987.
- 27 Iwasaki, T., Kawahara, M., Asano, K., *Fatigue Crack Growth Behavior in Welded Tubular Joints in T, TY, and K*, Proceedings of 11th Offshore Technology Conference, Houston, 1979.
- 28 Jenkins, W.M., *Towards Structural Optimization via the Genetic Algorithm*, Computers & Structures. Vol.40, n.5, 1991.
- 29 Jordan, M.I., *Why the Logistic Function? A Tutorial Discussion on Probabilities and Neural Networks*, Computational Cognitive Science, Technical Report 9503, 1995.
- 30 Kurobane, Y., et al., *Database of Test and Numerical Analysis Results for Unstiffened Tubular Joints*, Kumamoto University, Kumamoto, 1995.
- 31 Kussmaul, T., Schönfeldt, H., *Design Aspects and Steel Requirements for Offshore Structures*, Steel in Marine Structures, Amsterdam, 1987.
- 32 Lalani, M., Tebbett, I.E., Choo, B.S., *Improved Fatigue Life Estimation of Tubular Joints*, Proceedings of 18th Offshore Technology Conference, Houston, 1986.

- 33 Lieurade, H.P., Lecoq, H., *Potential Use of High Strength Structural Steel in Offshore Construction*, Steel in Marine Structures, Amsterdam, 1987.
- 34 Lillo, W.E., et al., *On Solving Constrained Optimization Problems with Neural Networks: A Penalty Method Approach*, IEEE Transactions on Neural Networks, vol.4, n.6, 1993.
- 35 Lippmann, R.P., *An Introduction to Computing with Neural Nets*, IEEE ASSP Magazine, April, 1987.
- 36 Ma., S.Y., Tebbett, I.E., *Estimations of Stress Concentration Factor for Fatigue Design of Welded Tubular Connections*, Proceedings of 20th Offshore Technology Conference, Houston, 1988.
- 37 Makino, Y., et al, *Behavior of Tubular T- and K-Joints Under Combined Loads*, Proceedings of 18th Offshore Technology Conference, Houston, 1986.
- 38 Martin,T., McGregor, J., *An Investigation into the Stress Distribution and Fatigue Strength of a Welded Tubular T-Joint*, Proceedings of 9th Offshore Technology Conference, Houston, 1977.
- 39 Milani,N.K., Grundy,P., *Behavior of innovative Tubular KT-Joints Under Variable Repeated Loading*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
- 40 Moan, T., *Current Trends in the Safety of Offshore Structures*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
- 41 Mukherjee, A., Deshpande, J.M., *Application of Artificial Neural Networks in Structural Design Expert Systems*, Computers & Structures, Vol.54, n.3, 1995.
- 42 Mukhopadhyay, A., Itoh, Y., Bouwkamp, J.G., *Fatigue Behavior of Tubular Joints in Offshore Structures*, Proceedings of 7th Offshore Technology Conference, Houston, 1975.
- 43 Naylor, D., Jones, S., Myers, D., *Backpropagation in Linear Arrays – A Performance Analysis and Optimization*, IEEE Transactions on Neural Networks, vol.6, n.3, 1995.
- 44 Noordhoer,C., Da Re, M.L., *The Results of the European Fatigue Tests on Welded Tubular Joints Compared with SCF Formulas and Design Lines*, Steel in Marine Structures, Amsterdam, 1987.
- 45 Poyet, P., Jardinier, R., *Use of Cast Steel Node Joints for Off-Shore Structures*, Steel in Marine Structures, Amsterdam, 1987.
- 46 Protzel, P.W., Palumbo, D.L., Arras, M.K., *Performance and Fault-Tolerance of Neural Networks for Optimization*, IEEE Transactions on Neural Networks, Vol.4, n.4, 1993.
- 47 Puthli,R., Mang, F., Karcher,D., *The Static Strength of Stiffened and Unstiffened L-Joints Made of Circular Hollow Sections*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.

- 48 Ramasamy, J.V., Rajasekaran, S., *Artificial Neural Network and Genetic Algorithm for the Design Optimization of Industrial Roofs – A Comparison*, Computers & Structures. Vol.58, n.4, 1996.
- 49 Reddy, R.R., Gupta, A., Singh, R.P., *Heuristic, Symbolic Logic and Knowledge-Based Approach to the Design and Construction of Buildings*, Computers & Structures, Vol. 43, n.6, 1992.
- 50 Riedmiller, M., *RPROP – Description and Implementation Details*, Technical Report of University of Karlsruhe, 1994.
- 51 Riedmiller, M., *Advanced Supervised Learning in Multi-Layer Perceptrons – From Backpropagation to Adaptive Learning Algorithms*, International Journal of Computer Standards and Interfaces, Special Issue on Neural Networks(5), 1994.
- 52 Ripoli, Romulo Rastopirquim, *Estudo de Concentração de Tensões em Estruturas Oceânicas: Juntas Tubulares Tipo Y e T*. São Paulo, 1992. 136p. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo.
- 53 Rogers, J.L., *Simulating Structural Analysis with Neural Network*, Journal of Computing in Civil Engineering, Vol.8, n.2, 1994.
- 54 Simpson, R.J., et al., *Towards a more Rational Approach for the Design of Tubular Joints in Steel Offshore Structures*, Design of Tubular Structures, London, 1983.
- 55 Stern, I.L., Alia, B.L., *Fabrication and Serviceability of Offshore Structures*, Proceedings of 13th Offshore Technology Conference, Houston, 1981.
- 56 Tank, D.W., Hopfield J.J., *Simple “Neural” Optimization Networks: An A/D Converter, Signal Decision Circuit, and a Linear Programming Circuit*, IEEE Transactions on Circuits and Systems, Vol.Cas-33, n.5, 1986.
- 57 Thebault, J., Olagnon, M., *Fatigue Analysis of a Tubular Joint Broken under Waves and Currents Loadings*, Proceedings of 12th Offshore Technology Conference, Houston, 1980.
- 58 Tolloczko, J.A., Lalani, M., *The Implication of New Data on the Fatigue Life Assessment of Tubular Joints*, Proceedings of 20th Offshore Technology Conference, Houston, 1988.
- 59 Vaessen, H.G., Back, J., *Fatigue Behavior of Welded Steel Joints in Air and Seawater*, Proceedings of 11th Offshore Technology Conference, Houston, 1979.
- 60 van der Vegte, G.J., *The Axial Strength of Uniplanar X-Joints Reinforced by T-Shaped Ring-Stiffeners*, Proceedings of 17th International Offshore and Polar Engineering Conference, Honolulu, USA, 1997.
- 61 Warren, S.S., *Neural Networks and Statistical Models*, Proceedings of 19th Annual SAS Users Group International Conference, April, 1994.
- 62 Warren, S.S., *Stopped Training and Other Remedies for Over-fitting*, Proceedings of 27th Symposium on the Interface, 1995.
- 63 Williams, T.P., Gucunski, N., *Neural Networks for Back-calculation of Moduli From SASW Test*, Journal of Computing in Civil Engineering, Vol.9, n.1, 1995.

- 64 Wordsworth, A.C., *Aspects of the Stress Concentration Factors at Tubular Joints, Steel in Marine Structures*, Amsterdam, 1987.
- 65 Wylde, J., *Fatigue Tests on Welded Tubular T-Joints With Equal Brace and Chord Diameters*, Proceedings of 15th Offshore Technology Conference, Houston, 1983.
- 66 Wylde, J.G., *Fatigue Tests on Tubular K and KT Joints under Axial Brace Loading*, Proceedings of 12th Offshore Technology Conference, Houston, 1980.
- 67 Yamasaki, T., Takizama, S., Komatsu, M., *Static and Fatigue Tests on Large-Size Tubular T-Joints*, Proceedings of 11th Offshore Technology Conference, Houston, 1979.
- 68 Yeh, I-Cheng, *Construction-Site Layout Using Annealed Neural Network*, Journal of Computing in Civil Engineering, Vol.9, 1995.

APÊNDICE A

CONFIGURAÇÃO DO *MODELO RNA*

A.1 Definição dos Pesos Sinápticos.

Nesse apêndice estão as configurações finais obtidas depois do treinamento para os dois casos de carregamento, FNP e MNP. Colocadas na forma de tabelas, estas configurações representam o conhecimento embutido nas redes das distribuições de tensões em juntas soldadas do tipo Y, para aqueles carregamentos.

Para calcular novas configurações de junta Y, para o caso FNP, deve-se construir uma RNA com quatro camadas, a primeira com 8 neurônios, a segunda com 15, a terceira com 5 e a última com 1 neurônio, conforme ilustrado na Figura A.1. Os neurônios são totalmente interligados, camada a camada, e os pesos utilizados, bem como os limiares, estão definidos na Tabela A1. Para facilitar o entendimento, foram identificados alguns pesos na rede, os quais estão destacados na Tabela A.1.

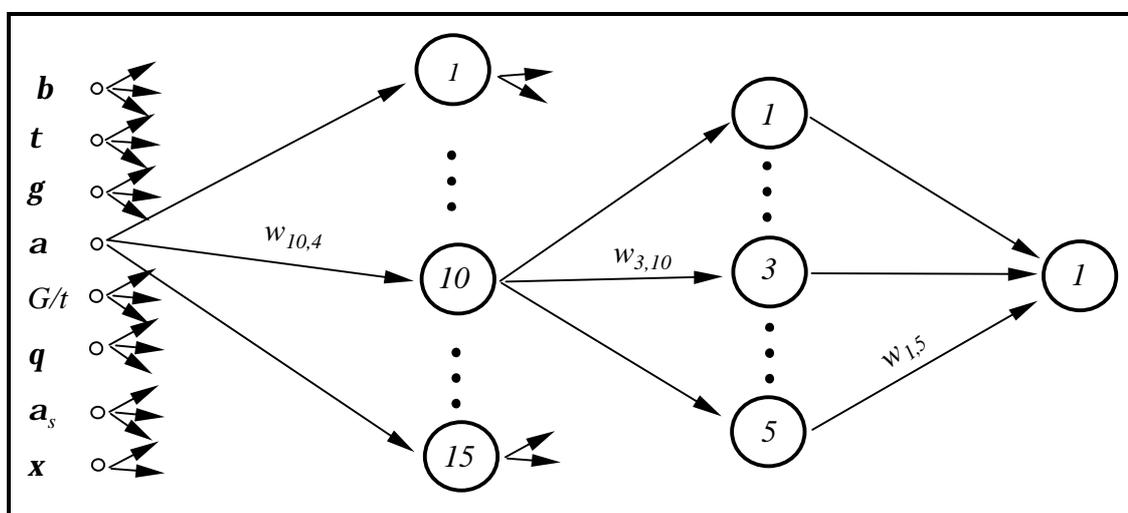


Figura A.1 – Rede Neural para o Caso FNP.

Observações para a Tabela A.1:

- 1 na coluna zero estão os limiares \mathbf{q} dos neurônios. O peso w_{ij} corresponde à ligação do neurônio i da camada k com o neurônio j da camada $k-1$.
- 2 as faixas válidas dos parâmetros de entrada estão mostradas na Tabela 3.1. Foram utilizados os valores 0.98 e 11.05 para reescalonar a TEVM entre 0.1 e 0.9.
- 3 para utilizar apropriadamente esta tabela, os valores limites mostrados na Tabela 3.1 devem ser escalonados para os limites -1 e 1 . As variáveis de entrada devem ser escalonadas nesta faixa, enquanto a saída da função sigmóide deve ser escalonada entre 0.1 e 0.9. A ordem dos parâmetros de entrada na primeira camada é fundamental e deve ser igual à apresentada na Figura A.1, ou seja: \mathbf{b} , \mathbf{t} , \mathbf{g} , \mathbf{a} , G/t , \mathbf{q} , \mathbf{a}_s e \mathbf{x} .

Caso MNP.

Para o caso MNP, o cálculo de novas configurações de junta Y pode ser feito construindo-se uma RNA com quatro camadas: a primeira com 7 neurônios, a qual servirá de entrada para os parâmetros, a segunda com 25, a terceira com 15 e a última com 1 neurônio, conforme ilustrado na Figura A.2. Os neurônios são totalmente interligados, camada a camada, e os pesos utilizados, bem como os limiares, estão definidos nas Tabelas A2 e A3. Analogamente, foram destacados alguns pesos na Figura A.2, os quais estão destacados nas Tabelas A2 e A3.

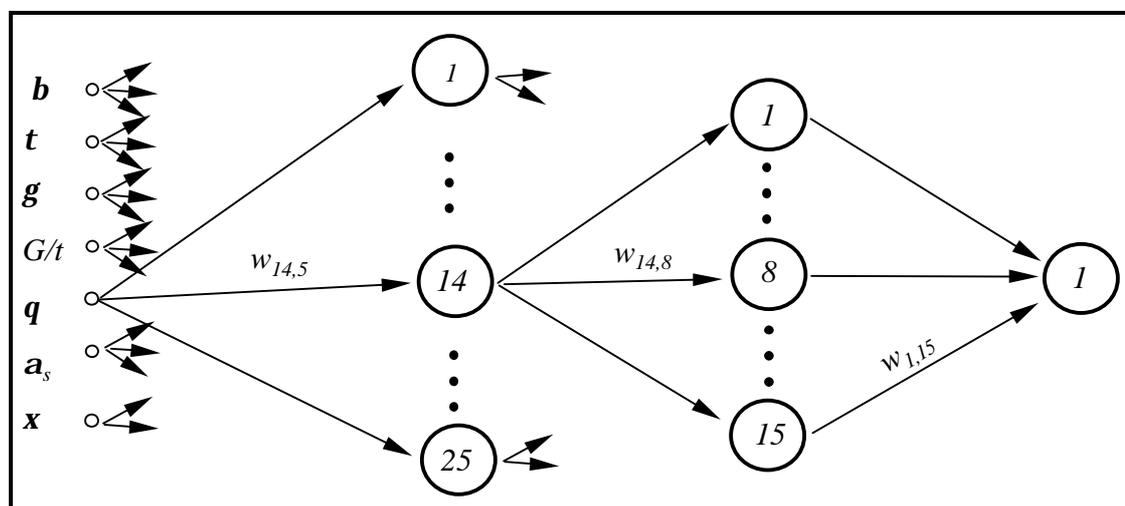


Figura A.2 – Rede Neural para o Caso MNP.

Tabela A.2 – Pesos dos Neurônios para a Rede Neural do Caso MNP – 1/2.

	0	1	2	3	4	5	6	7
pesos que ligam os neurônios da segunda camada aos neurônios da primeira camada								
1	6,25367094	-1,80918309	1,62678314	2,07796577	-0,84107732	0,78798402	-0,74949668	-1,67094619
2	4,70959210	0,52312112	-0,47503897	-0,38186141	0,18138180	0,22478726	-4,76273527	-0,67314886
3	3,96663879	-0,10851503	0,02232992	-0,09250530	-2,39867923	0,53494598	-0,94206402	-0,01143556
4	4,36238691	-0,28205584	0,05076061	3,08322769	-1,24309539	0,83444602	-1,01462084	-0,84825509
5	1,69885495	-1,14326122	0,12879625	-0,49937429	-0,14458834	-0,59031943	0,31733004	3,02072069
6	2,84179871	2,75550435	0,24717129	0,37161832	-0,16067315	-0,14649364	-0,35361111	-2,32562002
7	2,41854461	-1,42664132	0,88978467	1,51196194	0,09529293	0,35804593	-1,05303921	-0,57907583
8	5,86095320	-1,89906285	0,38797832	-1,17127648	0,78122540	-2,36244517	0,54427427	1,54635984
9	4,07432654	-1,90670854	0,24001329	2,26241521	-0,28294724	1,45847409	-0,13122075	-2,26892475
10	3,89779402	-0,05711361	1,74211953	-0,42848267	-0,51238007	0,01775006	-0,69135201	-1,27474190
11	3,57616441	-0,54974141	1,16771131	2,16625479	-0,10639876	-0,12361285	-0,64763241	-0,76389947
12	4,43523416	0,39934610	2,81165470	3,41629743	-0,31212299	0,40745333	0,48222992	2,54555635
13	1,02871776	-0,31521925	0,89155212	-1,01989849	-0,14377252	0,02678064	0,19845616	-1,29766961
14	3,01529879	-0,23023667	0,05369265	2,49779035	-0,20693608	-0,37063569	0,42698159	-1,27391776
15	3,56416098	-1,06837590	-0,27326875	-0,33490423	0,16167265	1,59725758	-0,15507176	2,27984746
16	4,34177913	0,18040040	0,18085783	0,05390535	0,00272268	1,25344989	-0,02766925	6,21019098
17	1,62530270	0,83238489	-0,04505440	-0,00420495	0,11903701	-0,07227546	0,02508561	-8,35909967
18	4,79183426	-0,51190449	0,57093891	-0,74141302	-0,38256666	-1,17202487	0,19833717	-3,87858810
19	2,04901435	-0,19544230	-0,31722304	0,16556647	-0,02548740	-1,03209576	0,04404632	9,75002060
20	2,56082746	-0,55426103	1,59254737	0,09829384	-0,05158520	1,17291468	-0,33586342	-1,81875862
21	1,67067719	0,04840326	-0,10146360	-0,00158969	0,06135419	-3,77703197	0,12890653	-0,26699927
22	3,95400439	0,55408657	-0,09263843	-0,00859956	0,08347519	0,80404487	0,08031614	-5,95236021
23	14,93292201	-0,44328814	0,03081741	-0,12888843	0,59103869	0,28210715	0,84522798	-13,04469853
24	3,10035320	-1,01444061	0,26767833	-0,29288085	-0,06718961	-0,19569389	0,05997871	-12,65444273
25	0,46431699	-1,29320169	0,12824535	-0,34240194	-0,00679424	-0,66711121	0,12583076	-2,76713190

Observações para a Tabela A.2:

1 na coluna zero estão os limiares q dos neurônios. O peso w_{ij} corresponde à ligação do neurônio i da camada k com o neurônio j da camada $k-1$.

2 as faixas válidas dos parâmetros de entrada estão mostradas na Tabela 3.1.

Neste caso de carregamento não foi incluída o parâmetro α . Foi utilizado o intervalo de 0.16 a 4.10 para reescalonar as TEVM entre 0.1 e 0.9.

- 3 para utilizar apropriadamente esta tabela, os valores limites mostrados na Tabela 3.1 devem ser escalonados para os limites -1 e 1 . As variáveis de entrada devem ser escalonadas nesta faixa, enquanto a saída da função sigmóide deve ser escalonada entre 0.1 e 0.9 . A ordem dos parâmetros na entrada da primeira camada deve ser a seguinte: **\mathbf{b} , \mathbf{t} , \mathbf{g} , G/t , \mathbf{q} , \mathbf{a}_s e \mathbf{x}** .

Tabela A.3 – Pesos dos Neurônios que Compõem a Rede Neural para o Caso MNP – 2/2.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
pesos que ligam os neurônios da terceira camada aos neurônios da segunda camada.																
0	-6.96116152	1.03441445	0.66892272	6.3378636	0.08877669	0.05170243	0.18828714	2.01438784	0.98365664	1.65497508	0.36607017	0.52001782	0.27485743	1.12143781	5.86291982	
1	-1.53127458	-2.23192942	-0.03548148	-0.24065841	-1.19208539	0.89618107	-2.41601539	-1.58566116	-0.79614179	-0.23009279	0.04585912	-2.02380983	0.74710477	1.54100688	1.35854974	
2	0.3324408	0.19131256	-0.80111763	-0.12401051	0.88135397	-0.28924447	-1.08709677	0.67442716	-3.71859714	0.10823962	0.66133638	-0.35229693	-1.07886263	-1.17330299	0.25566094	
3	-1.08822104	0.20043769	-0.57113733	0.77344169	-1.92176391	0.35399406	-0.70393888	0.44090262	0.11878147	0.73622278	-0.2721093	-0.83501433	1.24584735	-0.63980725	-0.14083815	
4	-0.17178981	-0.01089972	-0.68653807	-0.86373703	-0.98037743	0.20764518	-0.37138103	-0.93688425	-1.13968789	0.48908903	0.00616969	0.27564351	-0.16057185	-0.61648943	0.21501724	
5	0.4309429	-1.42517169	-1.02139768	0.64464101	-0.24639249	0.41994668	0.84359105	2.49539682	-0.37585609	-2.54790188	-1.05173952	-0.19282031	-2.5661442	0.37324904	1.94464721	
6	1.87335754	-0.24250649	-0.42104278	0.55416115	0.30915976	-0.36239101	-0.60441833	-0.85852564	-0.97926299	1.5345915	-1.04899298	-0.30981022	1.11893604	0.71914212	-2.99291318	
7	2.47194883	-0.54862619	-0.27526357	-1.92543394	-1.47490008	0.44727017	-0.32973407	-0.48730151	0.18202578	-0.56552199	-0.01910613	1.53329359	0.90117067	-0.61217004	-0.24083697	
8	-4.07791895	-1.06616925	-0.37265605	-2.36112336	-0.28148543	-2.5096959	1.2029492	-1.85960699	2.6495803	-0.72841661	-0.89208927	-0.82812037	0.20796525	-0.37313548	1.22180958	
9	0.72595389	-0.34826595	0.06321995	2.59546996	1.56257052	-0.91202333	-1.26855387	0.26423891	-1.1434845	-2.95038105	1.28130629	-0.28421738	-0.80540084	0.49426179	-2.84145448	
10	-1.78956427	1.12179155	0.64804651	0.09551224	-1.02262748	-0.82008339	-0.39769012	-1.38439161	-0.40640269	-1.43565384	0.9760308	1.86516288	-0.58917883	0.64640209	-0.15500729	
11	-3.43552459	-1.95702457	0.27249401	1.23741647	0.69953446	-1.44928624	-0.06900654	-0.55332732	0.4479248	-0.20300254	0.13326216	-0.56213524	0.38256191	0.11802663	0.77891893	
12	-0.65920647	0.11959993	-0.43200225	-0.28801299	-0.3185116	-0.1091032	0.31710008	-1.15290731	-0.64944802	-0.01437459	0.84710081	1.18508606	-2.39811358	-1.67493984	-0.06403259	
13	1.71116826	-2.84005448	-0.93651545	-1.0477194	1.67052569	-1.82133856	-1.10343173	-6.15018758	-0.42580311	0.960508	-0.08359215	-1.95935216	-2.23033431	1.50835945	-0.87860596	
14	0.70019157	-3.01683337	0.60277255	-0.20383429	0.13440113	0.79000062	-1.31659218	-0.77774905	-0.53522412	-1.33212207	-0.19681872	0.42012132	1.58869376	-2.93793651	1.56163972	
15	1.51661973	0.65863015	-0.65491855	-3.08333466	1.7070516	-1.15459305	-1.28514215	-3.4907292	-1.18360879	-1.00639022	-0.9156626	-1.09534878	-1.87857307	2.63867421	-4.11032984	
16	-0.8577937	-0.73866736	-1.00725977	5.83356905	-1.13305777	-9.89462688	-0.73989529	2.25768586	2.61436978	2.34864475	-3.19648632	-0.99148325	-3.56560352	-2.24394271	4.31563766	
17	-2.48690379	1.35361911	-1.32148021	0.44132952	-1.35170713	-1.33141062	0.58224904	-1.39201924	1.35818858	0.84545314	-4.87731863	-1.1692506	-5.83640787	-1.8205056	1.56657641	
18	0.08382445	-0.75719911	0.04492076	0.48279868	-1.88967192	-3.15704091	-3.06337148	-2.27709292	-0.84409708	-1.21108052	-0.54082652	0.40506484	0.24725096	0.65647452	1.74262328	
19	-4.58930795	0.46214986	-2.60078095	-2.71881449	-0.16470881	-9.13212872	-0.73369965	-2.05996715	0.34238724	-2.67493526	-1.06740296	-5.15202902	-2.84107509	-1.31511392	-2.51844441	
20	-1.15317845	0.21727332	-0.57318094	0.80585424	-0.31518512	1.34479085	-0.68652316	-0.61067749	-1.15406221	0.4818855	-1.79233162	-0.15027299	-1.39843807	0.05711076	0.7036864	
21	0.68749358	-0.57221192	1.18234377	4.09334752	0.37939026	0.28539793	-0.73098116	-0.90539996	0.6296117	1.49607051	1.34370703	1.33478422	0.61599821	-0.38504406	1.0330949	
22	-0.46709758	-3.01738606	-1.12361101	-0.01528203	0.61840237	-1.87196786	0.77992055	1.68218682	-1.0709769	-2.27443041	-1.22306774	-2.1374286	-1.5064361	-0.68152445	1.73222882	
23	-6.94311199	0.11609324	0.01948716	-3.01286189	1.66584989	0.52472269	2.38830449	-0.09509171	-0.10283909	2.2033543	-0.62812309	0.69302524	0.16141063	-1.78953808	-0.98324613	
24	-2.76213352	0.780052	-1.43676293	0.08976056	-1.28966859	-2.02256351	0.99995442	1.05192064	-0.93664755	-1.18990955	-10.1242526	2.20049756	-3.13861944	-0.58042529	-3.88325423	
25	2.11714541	-1.80155625	0.4621141	-0.04257886	2.17371739	1.00278099	-2.00503576	0.84355384	-1.90055922	0.75543854	1.88133061	-1.85820024	-0.45946604	2.20717473	6.56152672	
pesos que ligam os neurônios da camada de saída aos neurônios da terceira camada.																
1	-5,57693271	-4,37360313	-3,45388076	2,0482128	-2,65541860	-1,15461989	-4,03498639	-1,62290590	-3,18862246	-0,96715248	-1,49156523	-1,83249831	-1,33806271	-2,94234106	-0,98779096	-1,16866247

Observações para a Tabela A.3:

- 1 Para facilitar o armazenamento dos pesos no formato de matriz foi necessário inverter as colunas com as linhas dos pesos entre a segunda e a terceira camada. Assim, na linha zero estão os limiares \mathbf{q} dos neurônios e o peso w_{ji} corresponde à ligação do neurônio i da camada k com o neurônio j da camada $k-1$.
- 2 para os pesos que ligam a camada de saída à terceira camada, na primeira coluna está o limiar do neurônio, ao passo que um peso qualquer w_{lj} corresponde à ligação do neurônio l da camada k com o neurônio j da camada $k-1$.

A.2 Formatação do Arquivo de Entrada do Programa NEUROWELD.

O arquivo de entrada do programa NEUROWELD é padrão ASCII e tem o formato definido abaixo:

```

NCAM FRES GERA
NNERi
ALPHA
ETA
ERRO1
ERRO2
NITER1
NITER2
MIN1 MAX1.
MIN2 MAX2.
NTRE NTES
VMAX
VMIN
PTREi
PTESi

```

em que:

NCAM número de camadas na rede (inteiro).
 FRES definição da função resíduo. FR=1 para a função definida na Equação 5.2 e FR=2 para a função definida na Equação 5.4. (inteiro)
 GERA GERA=1 para gerar aleatoriamente os pesos e GERA=2 para ler arquivo com os pesos. (inteiro)
 NNERi número de neurônios em cada camada, começando na camada de entrada e progredindo até a camada de saída. Deve haver NCAM linhas, cada uma definindo o número de neurônios para a correspondente camada. (inteiro)
 ALPHA parâmetro para acelerar a convergência. (real)
 ETA taxa de aprendizagem. (real)
 ERRO1 erro máximo para a convergência de um único para de treinamento.(real)
 ERRO2 erro máximo para a convergência do conjunto de treinamento.(real)
 NITER1 número máximo de iterações para o conjunto de treinamento. (inteiro)
 NITER2 número máximo de iterações para um par de treinamento. (inteiro)
 MIN1 valor mínimo para escalonamento das variáveis de entrada. (real)
 MAX1 valor máximo para escalonamento das variáveis de entrada. (real)

- MIN2 valor mínimo para escalonamento das variáveis de saída. (real)
- MAX2 valor máximo para escalonamento das variáveis de saída. (real)
- NTRE número de pares de treinamento. (inteiro)
- NTES número de pares de teste. (inteiro)
- VMAX vetor com os valores máximos de cada variável. Deve haver consistência entre a ordem que as variáveis aparecem neste vetor e nos vetores de treinamento e de teste. (real)
- VMIN vetor com os valores mínimos de cada variável. Deve haver consistência entre a ordem que as variáveis aparecem neste vetor e nos vetores de treinamento e de teste. (real).
- PTRE_i deve haver NTRE pares de treinamento, um em cada linha, obedecendo a seqüência vetor de entrada, vetor de saída. (real)
- PTES_i deve haver NTES pares de teste, um em cada linha, obedecendo a seqüência vetor de entrada, vetor de saída. (real)

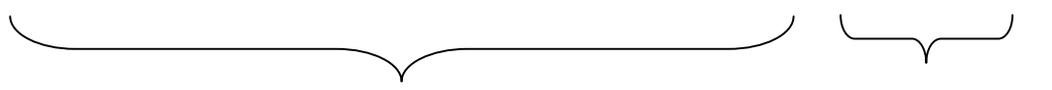
A.2.1 Exemplo de Arquivo de Entrada do Programa NEUROWELD.

Este arquivo foi utilizado para treinar o *modelo RNA* no caso FNP, a menos dos números de pares de treinamento e de teste, modificados.

```

4 1 1
8
15
5
1
0.85
0.85
0.00004
0.000025
90000
20
0.0 1.0
0.1 0.9
5 2
0.800 0.800 20.000 3.400 0.800 90.000 45.000 100.000 11.019
0.400 0.400 10.000 2.900 0.100 40.000 10.000 0.000 0.193
0.400 0.400 10.000 3.019 0.200 70.000 10.0 77.500 2.814
0.400 0.800 10.000 3.137 0.200 50.000 25.0 80.000 2.665
0.400 0.400 10.000 3.019 0.400 70.000 10.0 92.500 2.016
0.400 0.600 10.000 3.030 0.133 70.000 10.0 35.000 4.881
0.800 0.800 20.000 3.203 0.400 50.000 10.0 7.500 3.778
0.800 0.800 10.000 2.955 0.200 70.000 10.0 17.500 3.674
0.400 0.600 10.000 3.227 0.267 40.000 15.0 5.000 2.172

```



VETORES DE ENTRADA
VETORES DE SAÍDA

APÊNDICE B

ALGORITMOS DE TREINAMENTO DE RNA

B.1. ALGORITMO DE TREINAMENTO DO PERCEPTRON

O algoritmo de treinamento do *perceptron* é útil para separar classes *linearmente separáveis*. Considere o perceptron mostrado na Figura B.1. Definindo o vetor de entrada do perceptron por

$$X = [-1, x_1, x_2, \dots, x_p]^T \quad (\text{B.1})$$

e o vetor de pesos por

$$W = [q, w_1, w_2, \dots, w_p]^T \quad (\text{B.2})$$

Em notação vetorial, a combinação linear pode ser escrita como

$$u = W^T X \quad (\text{B.3})$$

O objetivo do perceptron é encontrar um conjunto de pesos W que satisfaça à equação

$$W^T X = 0 \quad (\text{B.4})$$

A equação B.4 define um hiperplano plotado no espaço p -dimensional que representa uma superfície de separação entre duas classes diferentes, C_1 e C_2 .

Suponha que exista um subconjunto de vetores de treinamento — $X_1(1), X_1(2), \dots$ — que pertença à classe C_1 e outro subconjunto $\mathcal{X} X_2(1), X_2(2), \dots$ — que pertença à classe C_2 . A união dos dois subconjuntos formam o conjunto de treinamento.

O processo de treinamento do perceptron com os conjuntos X_1 e X_2 consiste em

encontrar um vetor de pesos W que separe as classes C_1 e C_2 . Segundo o *Teorema de Aprendizagem do Perceptron*, desenvolvido por Rosenblatt⁵⁶, o vetor W é obtido em um número finito de passos pelo algoritmo mostrado na Tabela B.1.

Tabela B.1 – Algoritmo de Aprendizagem do Perceptron

1. Inicializa-se o vetor de pesos com $W=\{0\}$.
2. Apresenta-se um novo vetor de treinamento X_i à rede e calcula-se o produto.

$$u_i = W^T X_i \quad (\text{B.5})$$

3. Verifica-se se o vetor X_i está corretamente classificado. Nesse caso não há modificação no vetor W , ou seja

$$W(n+1) = W(n) \quad \text{se } W^T X(n) \geq 0 \quad \text{e } X(n) \in C_1 \quad (\text{B.6})$$

e

$$W(n+1) = W(n) \quad \text{se } W^T X(n) < 0 \quad \text{e } X(n) \in C_2 \quad (\text{B.7})$$

em que n corresponde à n -ésima iteração.

4. Caso contrário, o vetor de pesos é atualizado com a seguinte regra

$$W(n+1) = W(n) - \mathbf{h}X(n) \quad \text{se } W^T X(n) \geq 0 \quad \text{e } X(n) \in C_2 \quad (\text{B.8})$$

e

$$W(n+1) = W(n) + \mathbf{h}X(n) \quad \text{se } W^T X(n) < 0 \quad \text{e } X(n) \in C_1 \quad (\text{B.9})$$

em que \mathbf{h} é a taxa de aprendizado.

5. Volta-se ao passo 2 até que todos os vetores X estejam corretamente classificados.

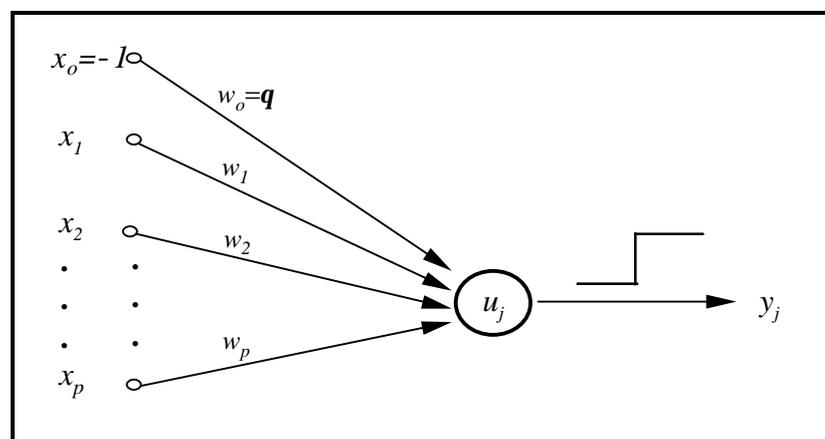


Figura B.1 – Modelo do Perceptron

B.2. REGRA DELTA

A regra delta foi elaborada para treinar o *ADALINE*, ilustrado na Figura B.2, cuja saída y é a combinação linear calculada por

$$y = u = W^T X \quad (\text{B.10})$$

em que

$$X = [x_1, x_2, \dots, x_p]^T \quad (\text{B.11})$$

e

$$W = [w_1, w_2, \dots, w_p]^T$$

O objetivo do treinamento do *ADALINE* é encontrar um conjunto de pesos W para minimizar a função definida por

$$E(W) = \frac{1}{2} \sum_{l=1}^L (d_l - y_l)^2 = \frac{1}{2} \sum_{l=1}^L (d_l - W^T X_l)^2 \quad (\text{B.12})$$

em que L é o número total de pares (X_l, d_l) de treinamento.

A função definida em B.12 é convexa e possui um ponto mínimo W^* . A condição necessária para que W^* seja um ponto de mínimo é que o gradiente da função E seja nulo naquele ponto⁶⁹, ou seja,

$$\begin{aligned} \nabla(E(W)) &= \frac{1}{2} \frac{\partial}{\partial W} \sum_{l=1}^L (d_l - y_l)^2 \Big|_{W=W^*} = 0 \\ &= - \sum_{l=1}^L X_l (d_l - W^T X_l) = 0 \end{aligned} \quad (\text{B.13})$$

Desenvolvendo:

$$\left[\sum_{l=1}^L X_l X_l^T \right] W^* = \sum_{l=1}^L X_l d_l \quad (\text{B.14})$$

O conjunto de pesos W^* é encontrado resolvendo-se a equação B.14, o que pode ser feito invertendo-se a matriz dada por

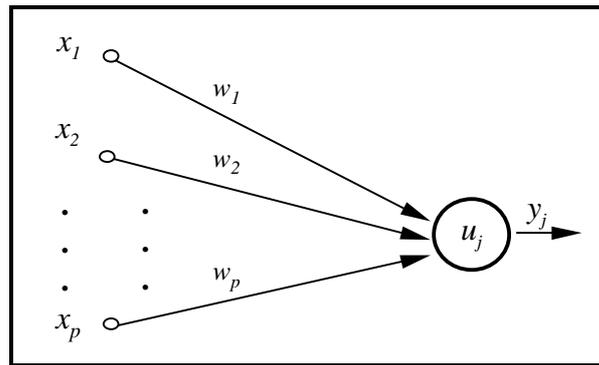


Figura B-2 – Modelo de Neurônio ADALINE

$$M = \sum_{l=1}^L X_l X_l^T \quad (\text{B.15})$$

Assim procedendo, obtendo-se

$$W^* = M^{-1} \sum_{l=1}^L X_l d_l \quad (\text{B.16})$$

A inversão da matriz M , no entanto, exige que o conjunto de treinamento contenha, pelo menos, p vetores de entrada X_l sejam linearmente independentes⁶⁹. Além disso, o conjunto de dados pode ser mal condicionado e dificultar, ou até mesmo impossibilitar, a inversão de matriz, feita normalmente por métodos numéricos.

Outra solução para encontrar o vetor de pesos W^* é a *regra delta* proposta por Widrow⁵⁷. Esta regra é um processo iterativo, no qual, partindo-se de um ponto $W(0)$ pode-se caminhar em direção ao ponto de mínimo, bastando para isto evoluir no sentido oposto ao do gradiente naquele ponto⁶⁹, isto é,

$$W(n+1) = W(n) + \Delta W(n) \quad (\text{B.17})$$

e

$$DW(n) = -h \nabla E(W(n)) \quad (\text{B.17a})$$

em que a taxa de aprendizado h determina o tamanho do passo no sentido oposto ao gradiente.

Sendo

$$\nabla E(W) = -\sum_{l=1}^L X_l (d_l - W^T X_l) \quad (\text{B.18})$$

e substituindo as Equações B.18 e B.10 na Equação B.17 obtém-se

$$W(n+1) = W(n) + \mathbf{h} \sum_{l=1}^L X_l (d_l - y_l) \quad (\text{B.19})$$

Definindo

$$\mathbf{d}_l = d_l - y_l$$

finalmente obtém-se

$$W(n+1) = W(n) + \mathbf{D}W(n) \quad (\text{B.20})$$

com

$$\mathbf{D}W(n) = -\mathbf{h} \nabla E(W) = -\mathbf{h} \sum_{l=1}^L X_l \mathbf{d}_l \quad (\text{B.21})$$

Tabela B.2 – Algoritmo de Treinamento pela Regra Delta

- 1 Inicializa-se o vetor de pesos $W = \{0\}$
- 2 Apresenta-se os L pares de treinamento, e atualiza-se os pesos por

$$W(n+1) = W(n) + \mathbf{h} \sum_{l=1}^L X_l \mathbf{d}_l$$

- 3 Volta ao passo 2 e repete-se o processo até que algum critério de convergência tenha sido obedecido.
-
-

B.3. REGRA DELTA GENERALIZADA (RETRO-PROPAGAÇÃO)

A *regra delta generalizada* é uma extensão da *regra delta* para redes multicamadas.

Considere um conjunto de treinamento com L pares de treinamento e que

$$E_p = \frac{1}{2} \sum_{j=1}^J (d_{pj} - y_{pj})^2 = \frac{1}{2} \sum_{j=1}^J e_{pj}^2 \quad (\text{B.22})$$

seja a medida do erro na apresentação do p -ésimo par de treinamento, com d_{pj} e y_{pj} sendo os valores desejado e calculado por uma rede com J neurônios na camada de saída, conforme ilustrado na Figura B.3.

Seja

$$E = \sum_{p=1}^L E_p \quad (\text{B.23})$$

o erro total medido sobre todo o conjunto de treinamento.

A variação do erro fornecido pela Equação B.22 com relação ao peso que liga o neurônio j ao neurônio i da camada anterior é calculada por

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial y_{pj}} \frac{\partial y_{pj}}{\partial w_{ij}} \quad (\text{B.24})$$

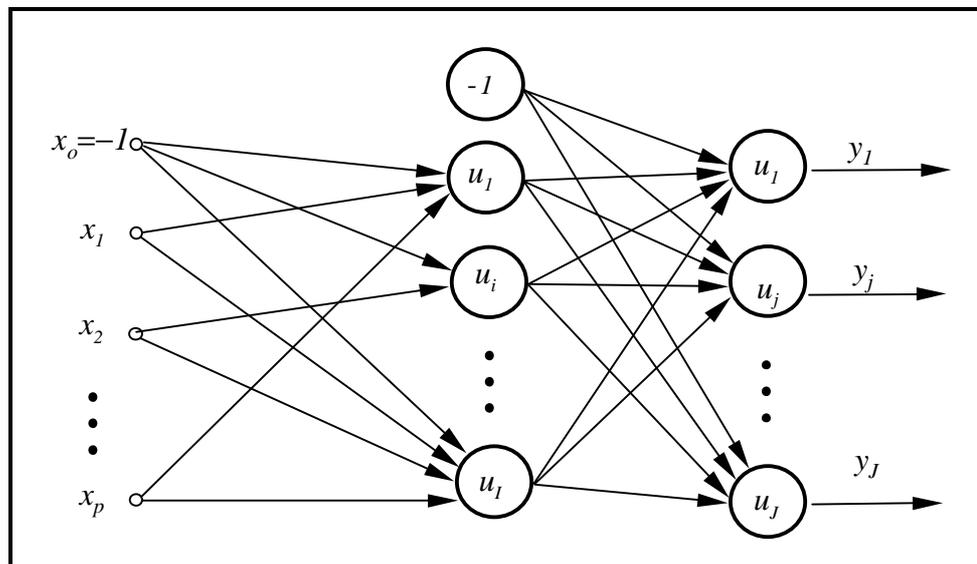


Figura B-3 – Rede Neural com Camada Oculta.

Da Equação B.22 vem

$$\frac{\partial E_p}{\partial y_{pj}} = -(d_{pj} - y_{pj}) = -\mathbf{d}_{pj} \quad (\text{B.25})$$

Sendo a saída do neurônio p definida por

$$y_{pj} = \sum_{i=0}^I w_{ij} x_{pi} \quad (\text{B.26})$$

em que I é o número de neurônios da camada anterior ligados ao neurônio j , obtém-se

$$\frac{\partial y_{pj}}{\partial w_{ij}} = x_{pi} \quad (\text{B.27})$$

Logo, substituindo as Equações B.25 e B.27 na Equação B.24 obtém-se

$$-\frac{\partial E_p}{\partial w_{ij}} = \mathbf{d}_{pj} x_{pi} \quad (\text{B.28})$$

Reescrevendo a Equação B.17a para o peso w_{ij} obtemos

$$\Delta w_{ij} = \mathbf{h} \mathbf{d}_{pj} x_{pi} \quad (\text{B.29})$$

Ainda, da Equação B.23 pode-se escrever

$$\frac{\partial E}{\partial w_{ij}} = \sum_{p=1}^L \frac{\partial E_p}{\partial w_{ij}} \quad (\text{B.30})$$

Assim, a variação do erro total sobre todos os pares de treinamento E em relação ao peso w_{ij} após a apresentação de um *epoch*, ou seja, de todos os pares de treinamento, é proporcional à variação do erro E_p com relação ao mesmo peso, calculada pela Equação B.28, após a apresentação de cada par de treinamento p . A rigor, isto só é verdadeiro se os pesos w_{ij} não mudarem durante este ciclo. Contudo, segundo Rumelhart³², se a constante de proporcionalidade (a taxa de aprendizado \mathbf{h}) for suficientemente pequena, a diferença entre os dois procedimentos pode ser considerada desprezível.

Conforme mostrado na Equação B.26, a função de ativação utilizada até agora é simplesmente a combinação linear das entradas do neurônio. Para redes com camadas ocultas, no entanto, esta função não traz nenhuma vantagem, visto que as várias camadas podem ser convertidas em uma única. Assim, a generalização da regra delta em redes multi-camadas será feita para uma função de ativação F do tipo *sigmóide*, a qual é não decrescente e diferenciável. Por facilidade, no desenvolvimento do algoritmo será utilizada uma rede com 3 camadas. Como será visto adiante, a extensão para N camadas é imediata.

Nestas condições, considere um conjunto de treinamento com L pares de treinamento (x_i, d_i) . Seja também uma rede neural com quatro camadas, sendo a camada inicial, ou camada zero, somente para a entrada das J_0 variáveis que compõem o vetor x_i . A primeira contém J_1 neurônios, a segunda J_2 neurônios e a terceira J_3 neurônios. Pela *regra delta*, para um neurônio qualquer, a atualização do peso w_{ij}^s na apresentação do p -ésimo par de treinamento é proporcional ao gradiente do erro E_p , ou seja,

$$\Delta(w_{ij}^s)_p = -\mathbf{h} \frac{\partial E_p}{\partial w_{ij}^s} \quad (\text{B.31})$$

para as camadas $s = 1, 2, 3$.

Inicialmente será determinada a expressão para atualização dos pesos w_{ij}^3 para os neurônios da camada de saída. Usando a regra da cadeia para a Equação B.22 pode-se escrever

$$\Delta(w_{ij}^3)_p = -\mathbf{h} \frac{\partial E_p}{\partial w_{ij}^3} = -\mathbf{h} \frac{\partial E_p}{\partial u_j^3} \frac{\partial u_j^3}{\partial w_{ij}^3} \quad (\text{B.32})$$

Por simplificação, a não ser em casos específicos, o índice p será omitido nas equações vindouras neste apêndice; Entenda-se que o desenvolvimento é para o p -ésimo par de treinamento.

O somatório das entradas no neurônio j é dado por

$$u_j^3 = \sum_{i=1}^{J3} w_{ij}^3 x_i^3 = \sum_{i=1}^{J3} w_{ij}^3 o_i^2 \quad (\text{B.33})$$

e

$$o_i^k = F(u_i^k) \quad (\text{B.34})$$

em que o_i^k é a saída do neurônio i , da camada k , para $k = 1, 2, 3$. Para $k=3$, $o_i=y_i$.

O erro local, ou gradiente local, é definido por

$$\mathbf{d}_j^3 = -\frac{\partial E_p}{\partial u_j^3} = -\frac{\partial E_p}{\partial e_j} \frac{\partial e_j}{\partial u_j^3} = e_j \frac{\partial F_j^3}{\partial u_j^3} \quad (\text{B.35})$$

sendo que na terceira igualdade foram utilizadas as equações B.33 e B.34.

A equação para atualização dos pesos na camada de saída é definida substituindo-se a Equação B.35 na Equação B.32, ou seja,

$$\Delta w_{ij}^3 = \mathbf{h} \mathbf{d}_j^3 o_i^2 \quad (\text{B.36})$$

com \mathbf{d}_j^3 definido pela Equação B.35.

Para os neurônios da segunda camada, a atualização dos pesos é mais complicada. Escrevendo a Equação B.31 para a segunda camada tem-se:

$$\Delta(w_{ij}^2)^2 = -\mathbf{h} \frac{\partial E_p}{\partial w_{ij}^2} = -\mathbf{h} \frac{\partial E_p}{\partial u_j^2} \frac{\partial u_j^2}{\partial w_{ij}^2} = \mathbf{h} \mathbf{d}_j^2 o_i^1 \quad (\text{B.37})$$

em que

$$\mathbf{d}_j^2 = -\frac{\partial E_p}{\partial u_j^2} \quad (j = 1, 2, \dots, J2) \quad (\text{B.38})$$

é o gradiente local para o neurônio j na segunda camada.

Neste caso, no entanto, o erro não pode ser calculado diretamente como na camada de saída. A proposta de Rumelhart³², e o cerne do algoritmo de retro-propagação, foi expressar este erro em função daqueles já conhecidos. Assim, usando a regra da cadeia pode-se escrever,

$$\mathbf{d}_j^2 = -\frac{\partial E_p}{\partial u_j^2} = -\frac{\partial E_p}{\partial o_j^2} \frac{\partial o_j^2}{\partial u_j^2} \quad (\text{B.39})$$

Considerando a Equação B.34, para a segunda camada, obtém-se

$$\mathbf{d}_j^2 = -\frac{\partial E_p}{\partial o_j^2} \frac{\partial F_j^2}{\partial u_j^2} \quad (\text{B.40})$$

O primeiro fator na Equação B.40 pode ser calculado por

$$\begin{aligned} -\frac{\partial E_p}{\partial o_j^2} &= -\sum_{m=1}^{J3} \frac{\partial E_p}{\partial u_m^3} \frac{\partial u_m^3}{\partial o_j^2} = \sum_{m=1}^{J3} \left(-\frac{\partial E_p}{\partial u_m^3} \right) \frac{\partial}{\partial o_j^2} \left(\sum_{k=1}^{J2} w_{km}^3 x_k^3 \right) \\ &= \sum_{m=1}^{J3} \mathbf{d}_m^3 \frac{\partial}{\partial o_j^2} \left(\sum_{k=1}^{J2} w_{km}^3 o_k^2 \right) = \sum_{m=1}^{J3} \mathbf{d}_m^3 w_{jm}^3 \end{aligned} \quad (\text{B.41})$$

Assim, substituindo a Equação B.41 na Equação B.40, o erro local na segunda camada pode ser calculado por

$$\mathbf{d}_j^2 = \frac{\partial F_j^2}{\partial u_j^2} \sum_{i=1}^{J3} \mathbf{d}_i^3 w_{ji}^3 \quad (\text{B.42})$$

Analogamente, a expressão de atualização dos pesos para a primeira camada é dada por

$$\Delta(w_{ij})^1 = \mathbf{h} \mathbf{d}_j^1 x_i^1 = \mathbf{h} \mathbf{d}_j^1 o_i^0 = \mathbf{h} \mathbf{d}_j^1 x_i \quad (\text{B.43})$$

com o erro

$$\mathbf{d}_j^1 = \frac{\partial F_j^1}{\partial u_j^1} \sum_{i=1}^{J2} \mathbf{d}_i^2 w_{ji}^2 \quad (\text{B.44})$$

Para uma rede com N camadas ocultas, o procedimento é análogo, calculando-se o erro, camada a camada, até que a primeira seja alcançada.

B.3.1 Função de Ativação Logística.

A função de ativação F mais utilizada é a função logística, ilustrada na Figura 3.4(a) e definida por

$$y_j = F(u_j) = \frac{1}{1 + e^{-u_j}} \quad (\text{B.45})$$

com

$$-\infty \leq u_j \leq \infty$$

Diferenciando a Equação B.45 obtemos

$$F'(u_j) = y_j(1 - y_j) \quad (\text{B.46})$$

Lembrando as Equações B.22 e B.35, o gradiente local para um neurônio j localizado na camada de saída é calculado por

$$\mathbf{d}_j = e_j F'(u_j) = (d_j - y_j) y_j (1 - y_j) \quad (\text{B.47})$$

Para um neurônio j na N -ésima camada oculta, partindo da Equação B.42, obtém-se

$$\mathbf{d}_j^N = F'(u_j) \sum_{k=1}^{JS} \mathbf{d}_k w_{jk} = y_j (1 - y_j) \sum_{k=1}^{JS} \mathbf{d}_k w_{jk} \quad (\text{B.48})$$

em que JS é o número de neurônios na camada $N+1$ e \mathbf{d}_k é calculado pela Equação B.47, se o neurônio j pertencer à penúltima e por B.48 se o neurônio j pertencer a uma camada anterior à penúltima.

B.3.2 Função Resíduo Tangente Hiperbólica.

No desenvolvimento do algoritmo de retro-propagação, Rumelhart³² utilizou a Equação B.22 como função a ser minimizada durante o processo de treinamento.

A utilização de outra função resíduo pode ser implementada sem muitas alterações no algoritmo. Admita-se, assim, que a função resíduo seja definida por

$$E_p = \frac{1}{2} \sum_{i=1}^{J3} \text{tgh}(d_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^{J3} \text{tgh}(e_i)^2 \quad (\text{B.49})$$

A Equação B.31 define a atualização do peso w_{ij} , que liga o neurônio j da camada s ao neurônio i da camada anterior, pode ser reescrita como

$$\Delta(w_{ij})_p^s = -\mathbf{h} \frac{\partial E_p}{\partial o_j^s} \frac{\partial o_j^s}{\partial u_j^s} \frac{\partial u_j^s}{\partial w_{ij}^s} \quad (\text{B.50})$$

Analisando a Equação B.50, verifica-se que os últimos dois fatores dependem apenas das características do neurônio, como função de ativação e pesos, ou seja, eles são independentes da função resíduo adotada. Com isso, a alteração da função resíduo não modifica a estrutura básica do algoritmo de retro-propagação. Na verdade, a modificação na medida do erro provoca apenas uma alteração no segundo fator da Equação B.50, para os neurônios da camada de saída. Lembrando a Equação B.49 pode-se escrever

$$-\frac{\partial E_p}{\partial o_j^s} = -\frac{\partial E_p}{\partial y_j} = \frac{1}{2} \frac{\partial}{\partial y_j} \text{tgh}(e_j)^2 \quad (\text{B.51})$$

Diferenciando a Equação B.51 com relação a y_j obtém-se

$$-\frac{\partial E_p}{\partial o_j^s} = -\frac{\partial E_p}{\partial y_j} = \frac{e_j}{\cosh^2(e_j)^2} \quad (\text{B.52})$$

Logo, o gradiente local para o neurônio j na camada de saída pode ser escrito como

$$\mathbf{d}_j^3 = -\frac{\partial E_p}{\partial u_j^3} = -\frac{\partial E_p}{\partial o_j^3} \frac{\partial o_j^3}{\partial u_j^3} = \frac{e_j}{\cosh^2(e_j)^2} \frac{\partial F_j^3}{\partial u_j^3} \quad (\text{B.53})$$

Esta equação é semelhante à Equação B.35. Assim, a atualização do peso w_{ij} que liga o neurônio j , na camada de saída, ao neurônio i na camada anterior pode ser feito pela Equação B.36, com \mathbf{d}_j^3 calculado pela Equação B.53.

Para as camadas internas, o processo de cálculo é idêntico ao desenvolvido anteriormente, pois a Equação B.52, para a segunda camada é definida por

$$-\frac{\partial E_p}{\partial o_j^2} = \sum_{m=1}^{J^3} \mathbf{d}_m^3 w_{jm}^3 \quad (\text{B.54})$$

conforme mostrado no desenvolvimento da Equação B.41. A atualização dos pesos, de modo análogo, é feita por

$$\Delta(w_{ij})^2 = \mathbf{h} \mathbf{d}_j^2 x_i^2 = \mathbf{h} \mathbf{d}_j^2 o_i^1 \quad (\text{B.55})$$

em que \mathbf{d}_j^2 é calculado pela Equação B.42, reproduzida abaixo

$$\mathbf{d}_j^2 = \frac{\partial F_j^2}{\partial u_j^2} \sum_{i=1}^{J^3} \mathbf{d}_i^3 w_{ji}^3 \quad (\text{B.42})$$

Para redes com um número maior de camadas ocultas o processo é análogo ao discutido anteriormente.

B.4. ALGORITMO PARA APRESENTAÇÃO ALEATÓRIA DE PARES DE TREINAMENTO

O objetivo deste algoritmo é evitar, no treinamento da rede com apresentação aleatória dos pares de treinamento, a necessidade de verificar se cada par já foi apresentado à rede ou não. Do ponto de vista de tempo computacional, este procedimento é conveniente para casos em que o número de pares de treinamento é elevado. Antes de apresentá-lo, porém, convém verificar como ocorre a apresentação seqüencial dos pares de treinamento.

Para tanto, admita-se um conjunto de treinamento com L pares de treinamento, utilizado para treinar uma rede neural. Por facilidade, porém sem significar restrição ao algoritmo, considere-se ainda que os vetores que compõem cada par de treinamento contêm somente um elemento. Assim, pode-se construir um vetor $V1$, para as variáveis de entrada e outro, $V2$, para as de saída, ambos com comprimento L .

Assim, a apresentação dos pares de treinamento é feita pelo algoritmo

para N iterações (ou enquanto erro calculado > erro permissível)

para i de 1 até L faça

- 1. apresenta [V1(i),V2(i)] à rede;*
- 2. calcula a saída da rede com o par [V1(i),V2(i)];*
- 3. atualiza os pesos da rede;*

fim.

fim

O algoritmo para apresentação aleatória elaborado neste trabalho baseia-se na utilização de um vetor de números inteiros, $C1$, de comprimento L , para “coordenar” a apresentação dos pares de treinamento à rede.

Assim, a apresentação dos pares de treinamento utilizada no programa NEUROWELD é feita pelo seguinte algoritmo:

```

para N iterações ( ou enquanto erro calculado > erro permissível)
  para k de 1 até M faça
    a = número randômico inteiro entre 0 e (L+1);
    b = número randômico inteiro entre 0 e (L+1);
    aux = CI(a);
    CI(a) = CI(b);
    CI(b) = aux;
  end;
  para i de 1 até L faça
    1. apresenta [V1( C1(i) ),V2( C1(i) )] à rede;
    2. calcula a saída da rede com o par [V1( C1(i) ),V2( C1(i) )] ;
    3. atualiza os pesos da rede;
  fim.
fim.

```

A diferença na ordem de apresentação entre dois *epochs* consecutivos é função direta do número *M*. Quanto maior o seu valor, a princípio, maior a modificação na ordem de apresentação. Pode-se alegar, é claro, que depois de *M* iterações o vetor tenha voltado ao seu estado original. Na prática, no entanto, foi verificado que esta condição não acontece.

No treinamento do *modelo RNA* foi utilizado *M* igual à metade do número de pares de treinamento.

APÊNDICE C

EQUAÇÕES PARA CÁLCULO DO FCT

A.1. EQUAÇÕES PARA CÁLCULO DE FCT PROPOSTAS POR KUANG.

para força axial no plano:

$$\text{primário} \quad FCT = 2.06g^{0.808}e^{-1.2b^3}t^{1.333}a^{0.057}\sin^{1.694}q$$

$$\text{secundário} \quad FCT = 4.076g^{0.55}e^{-1.35b^3}ta^{0.12}\sin^{1.94}q$$

para momento fletor no plano:

$$\text{primário} \quad FCT = 0.702g^{0.6}b^{-0.04}t^{0.86}\sin^{0.57}q$$

$$\text{secundário} \quad FCT = 1.301g^{0.23}b^{-0.38}t^{0.38}\sin^{0.21}q$$

A.2. EQUAÇÕES PARA CÁLCULO DE FCT PROPOSTAS POR EFTHYMIU.

para força axial no plano

primário:

$$\text{sela:} \quad FCT = gt^{1.1}[1.11 - 3(b - 0.5)^2]\sin^{1.6}q$$

$$\text{coroa:} \quad FCT = g^{0.2}t[2.65 + 5(b - 0.65)^2] + tb(0.25a - 3)\sin q$$

secundário:

$$\text{sela:} \quad FCT = 1.3 + gt^{0.52}a^{0.1}0.187 - 1.25b^{1.1}(b - 0.96)\sin^{(2.7 - 0.01a)}q$$

coroa:
$$FCT = 3 + \mathbf{g}^{1.2} [0.12e^{-4\mathbf{b}} + 0.011\mathbf{b}^2 - 0.045] + \mathbf{bt}(0.1\mathbf{a} - 1.2)$$

para momento fletor no plano:

primário

coroa:
$$FCT = 1.45\mathbf{bt}^{0.85}\mathbf{g}^{(1-0.68\mathbf{b})}\sin^{0.7}\mathbf{q}$$

secundário

coroa:
$$FCT = 1 + 0.65\mathbf{bt}^{0.4}\mathbf{g}^{(1.09-0.77\mathbf{b})}\sin^{(0.06\mathbf{g}-1.16)}\mathbf{q}$$

A.3. EQUAÇÕES PARA CÁLCULO DE FCT PROPOSTAS PELA UEG.

para força axial no plano

primário:

sela:
$$FCT = \mathbf{gtb}(6.78 - 6.42\mathbf{b}^{0.5}) \sin^{1.7+0.7\mathbf{b}^{0.3}}\mathbf{q}(\mathcal{Q}'_b \mathcal{Q}'_g)^{0.5}$$

coroa:
$$FCT = (X'_c + X_o X''_c)$$

com

$$X'_c = [0.7 + 1.37\mathbf{g}^{0.5}\mathbf{t}(1 - \mathbf{b})] (2\sin^{0.5}\mathbf{q} - \sin^3\mathbf{q}) ,$$

$$X_o = \frac{\mathbf{t}(2\mathbf{gb} - \mathbf{t})(0.5\mathbf{a} - \mathbf{b}/\sin\mathbf{q}) \sin\mathbf{q}}{2\mathbf{g} - 3} ,$$

$$X''_c = 1.05 + \frac{30\mathbf{t}^{1.5}(1.2 - \mathbf{b})(\cos^4\mathbf{q} + 0.15)}{\mathbf{g}}$$

secundário:

$$FCT_{\text{braço}} = 1 + 0.63FCT_{\text{principal}}$$

faixa de validade dos parâmetros:

$$0.13 \leq \mathbf{b} \leq 1.0$$

$$0.25 \leq \mathbf{t} \leq 1.0$$

$$12 \leq \mathbf{g} \leq 40$$

$$2.5 \leq \mathbf{a} \leq 40$$

$$30^\circ \leq \mathbf{q} \leq 90^\circ$$

A.4. EQUAÇÕES PARA CÁLCULO DE FCT PROPOSTAS POR GIBSTEIN

para força axial no plano

primário

$$FCT = [1.5 - 3.88(\mathbf{b} - 0.47)^2] \mathbf{g}^{0.87} \mathbf{t}^{1.37} \mathbf{a}^{0.06}$$

secundário

$$FCT = [1.09 - 1.93(\mathbf{b} - 0.5)^2] \mathbf{g}^{0.76} \mathbf{t}^{0.57} \mathbf{a}^{0.12}$$

momento fletor no plano

primário

$$FCT = [1.65 - 1.1(\mathbf{b} - 0.42)^2] \mathbf{g}^{0.36} \mathbf{t}^{1.05}$$

secundário

$$FCT = [0.95 - 0.65(\mathbf{b} - 0.41)^2] \mathbf{g}^{0.38} \mathbf{t}^{0.29}$$

A.5. EQUAÇÕES DO LLOYD'S REGISTER PARA CÁLCULO DE FCT

para força axial no plano

primário:

$$\text{sela: } FCT = \mathbf{tg}^{1.2} (2.12 - 2\mathbf{b}) \sin^2 \mathbf{q}$$

$$\text{coroa: } FCT = \mathbf{tg}^{0.2} (3.5 - 2.4\mathbf{b}) \sin^{0.3} \mathbf{q} + B0.B1$$

$$B0 = \frac{0.7\mathbf{t}(\mathbf{b} - \mathbf{t}/2\mathbf{g})(\mathbf{a}/2 - \mathbf{b}/\sin \mathbf{q}) \sin \mathbf{q}}{(1 - 3/2\mathbf{g})}$$

$$B1 = 1.05 + \frac{30\mathbf{t}^{1.5} (1.2 - \mathbf{b})(\cos^4 \mathbf{q} + 0.15)}{\mathbf{g}}$$

secundário:

$$\text{sela: } FCT = 1 + \mathbf{t}^{0.6} \mathbf{g}^{1.3} \mathbf{b} (0.76 - 0.7\mathbf{b}) \sin^{2.2} \mathbf{q}$$

$$\text{coroa: } FCT = 2.6\mathbf{b}^{0.65} \mathbf{g}^{(0.3-0.5\mathbf{b})}$$

para momento fletor no plano:

primário

$$FCT = 1.22\mathbf{t}^{0.8} \mathbf{bg}^{(1-0.68\mathbf{b})} \sin^{(1-\mathbf{b}^3)} \mathbf{q}$$

secundário

$$\text{coroa: } FCT = 1 + \mathbf{bt}^{0.2} \mathbf{g} (0.26 - 0.21\mathbf{b}) \sin^{1.5} \mathbf{q}$$

faixa de validade dos parâmetros:

$$0.13 \leq \mathbf{b} \leq 1.0$$

$$0.25 \leq \mathbf{t} \leq 1.0$$

$$10 \leq \mathbf{g} \leq 35$$

$$30^\circ \leq \mathbf{q} \leq 90^\circ$$

$$\mathbf{a} \geq 4$$

APÊNDICE D

FCT PARA OS 252 CASOS ANALISADOS

D1 - CASO FNP

Tabela D.1 – FCT Calculado pelo MEF²⁰, RNA e pelas Equações do LR⁵¹ e da UEG¹⁹

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.4	20	3.184	0.8	50	10	37.5	2.82	2.79	3.9	5.47
0.4	0.6	10	3.127	0.267	50	10	37.5	3.23	3.08	2.88	4.1
0.4	0.6	20	3.189	0.533	50	10	42.5	4.51	4.32	5.85	8.2
0.4	0.8	10	3.137	0.2	50	10	40	4.1	3.92	3.84	5.47
0.4	0.8	20	3.195	0.4	50	10	45	6.14	5.93	7.81	10.93
0.6	0.4	10	3.144	0.4	50	10	90	2.13	2.08	2.24	2.67
0.6	0.4	20	3.213	0.8	50	10	92.5	2.57	2.5	3.94	5.29
0.6	0.6	10	3.156	0.267	50	10	27.5	2.77	2.65	3	3.97
0.6	0.6	20	3.219	0.533	50	10	32.5	3.65	3.46	5.92	7.94
0.6	0.8	10	3.169	0.2	50	10	30	3.49	3.43	4	5.29
0.6	0.8	20	3.225	0.4	50	10	37.5	4.94	4.79	7.9	10.59
0.8	0.4	10	3.114	0.4	50	10	90	2.19	2.16	1.96	2.28
0.8	0.4	20	3.186	0.8	50	10	92.5	2.54	2.53	2.94	4.07
0.8	0.6	10	3.131	0.267	50	10	92.5	2.6	2.4	2.25	3.05
0.8	0.6	20	3.195	0.533	50	10	92.5	3.1	3.03	4.42	6.1
0.8	0.8	10	3.148	0.2	50	10	12.5	3.1	2.99	3.01	4.07
0.8	0.8	20	3.203	0.4	50	10	92.5	3.85	3.69	5.9	8.14
0.4	0.4	10	3.116	0.4	50	25	27.5	2.25	2.18	2.18	2.73
0.4	0.4	20	3.184	0.8	50	25	32.5	2.8	2.8	3.9	5.47
0.4	0.6	10	3.127	0.267	50	25	35	2.91	2.76	2.88	4.1
0.4	0.6	20	3.189	0.533	50	25	40	4.15	4.11	5.85	8.2
0.4	0.8	10	3.137	0.2	50	25	37.5	3.65	3.42	3.84	5.47
0.4	0.8	20	3.195	0.4	50	25	45	5.56	5.38	7.81	10.93
0.6	0.4	10	3.144	0.4	50	25	17.5	2.08	1.97	2.24	2.67
0.6	0.4	20	3.213	0.8	50	25	25	2.44	2.32	3.94	5.29
0.6	0.6	10	3.156	0.267	50	25	22.5	2.54	2.38	3	3.97
0.6	0.6	20	3.219	0.533	50	25	30	3.39	3.25	5.92	7.94
0.6	0.8	10	3.169	0.2	50	25	27.5	3.13	3.04	4	5.29

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.6	0.8	20	3.225	0.4	50	25	35	4.38	4.32	7.9	10.59
0.8	0.4	10	3.114	0.4	50	25	0	1.94	1.86	1.96	2.28
0.8	0.4	20	3.186	0.8	50	25	12.5	2.13	2.11	2.94	4.07
0.8	0.6	10	3.131	0.267	50	25	10	2.29	2.2	2.25	3.05
0.8	0.6	20	3.195	0.533	50	25	0	2.82	2.84	4.42	6.1
0.8	0.8	10	3.148	0.2	50	25	10	2.81	2.67	3.01	4.07
0.8	0.8	20	3.203	0.4	50	25	12.5	3.46	3.4	5.9	8.14
0.4	0.4	10	3.019	0.4	70	10	42.5	3.42	3.2	2.87	3.9
0.4	0.4	20	3.087	0.8	70	10	45	4.25	4.08	5.78	7.81
0.4	0.6	10	3.030	0.267	70	10	45	4.7	4.33	4.3	5.86
0.4	0.6	20	3.093	0.533	70	10	47.5	6.73	6.37	8.68	11.71
0.4	0.8	10	3.041	0.2	70	10	47.5	5.94	5.57	5.74	7.81
0.4	0.8	20	3.098	0.4	70	10	47.5	9.09	8.76	11.58	15.62
0.6	0.4	10	2.999	0.4	70	10	35	2.82	2.67	2.97	3.86
0.6	0.4	20	3.068	0.8	70	10	37.5	3.41	3.17	5.77	7.73
0.6	0.6	10	3.012	0.267	70	10	42.5	3.96	3.71	4.46	5.8
0.6	0.6	20	3.074	0.533	70	10	42.5	5.25	5.01	8.67	11.59
0.6	0.8	10	3.024	0.2	70	10	45	5.12	4.99	5.95	7.73
0.6	0.8	20	3.080	0.4	70	10	47.5	7.32	7.15	11.57	15.46
0.8	0.4	10	2.921	0.4	70	10	92.5	2.48	2.28	2.48	3.1
0.8	0.4	20	2.993	0.8	70	10	100	3.11	2.81	4.25	6.2
0.8	0.6	10	2.938	0.267	70	10	22.5	2.96	2.76	3.33	4.65
0.8	0.6	20	3.002	0.533	70	10	22.5	3.65	3.5	6.39	9.29
0.8	0.8	10	2.955	0.2	70	10	22.5	3.74	3.48	4.45	6.2
0.8	0.8	20	3.010	0.4	70	10	30	4.76	4.46	8.54	12.39
0.4	0.4	10	3.019	0.4	70	35	42.5	3.19	2.93	2.87	3.9
0.4	0.4	20	3.087	0.8	70	35	42.5	4.3	3.99	5.78	7.81
0.4	0.6	10	3.030	0.267	70	35	45	3.96	3.65	4.3	5.86
0.4	0.6	20	3.093	0.533	70	35	47.5	5.99	5.75	8.68	11.71
0.4	0.8	10	3.041	0.2	70	35	45	4.93	4.49	5.74	7.81
0.4	0.8	20	3.098	0.4	70	35	47.5	7.88	7.54	11.58	15.62
0.6	0.4	10	2.999	0.4	70	35	35	2.69	2.49	2.97	3.86
0.6	0.4	20	3.068	0.8	70	35	37.5	3.24	3.04	5.77	7.73
0.6	0.6	10	3.012	0.267	70	35	42.5	3.48	3.25	4.46	5.8
0.6	0.6	20	3.074	0.533	70	35	42.5	4.71	4.48	8.67	11.59
0.6	0.8	10	3.024	0.2	70	35	42.5	4.33	4.21	5.95	7.73
0.6	0.8	20	3.080	0.4	70	35	45	6.39	6.12	11.57	15.46
0.8	0.4	10	2.921	0.4	70	35	17.5	2.2	2.05	2.48	3.1
0.8	0.4	20	2.993	0.8	70	35	0	2.49	2.46	4.25	6.2
0.8	0.6	10	2.938	0.267	70	35	27.5	2.61	2.41	3.33	4.65

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.8	0.6	20	3.002	0.533	70	35	22.5	3.26	3.2	6.39	9.29
0.8	0.8	10	2.955	0.2	70	35	22.5	3.21	2.99	4.45	6.2
0.8	0.8	20	3.010	0.4	70	35	27.5	4.15	3.88	8.54	12.39
0.4	0.4	10	2.994	0.4	90	10	50	3.81	3.44	3.24	4.35
0.4	0.4	20	3.062	0.8	90	10	50	4.74	4.42	6.52	8.7
0.4	0.6	10	3.004	0.267	90	10	50	5.25	4.72	4.87	6.53
0.4	0.6	20	3.067	0.533	90	10	50	7.51	7.09	9.79	13.05
0.4	0.8	10	3.015	0.2	90	10	50	6.65	6.19	6.49	8.7
0.4	0.8	20	3.073	0.4	90	10	50	10.2	9.66	13.07	17.41
0.6	0.4	10	2.961	0.4	90	10	50	3.1	2.86	3.35	4.34
0.6	0.4	20	3.029	0.8	90	10	50	3.76	3.53	6.49	8.67
0.6	0.6	10	2.973	0.267	90	10	50	4.46	4.12	5.03	6.5
0.6	0.6	20	3.036	0.533	90	10	50	5.93	5.65	9.74	13.01
0.6	0.8	10	2.986	0.2	90	10	50	5.78	5.56	6.72	8.67
0.6	0.8	20	3.042	0.4	90	10	50	8.4	8.01	13.01	17.34
0.8	0.4	10	2.869	0.4	90	10	100	2.6	2.27	2.69	3.52
0.8	0.4	20	2.942	0.8	90	10	100	3.12	2.96	4.76	7.04
0.8	0.6	10	2.887	0.267	90	10	32.5	2.95	2.64	3.76	5.28
0.8	0.6	20	2.951	0.533	90	10	12.5	3.73	3.53	7.16	10.56
0.8	0.8	10	2.904	0.2	90	10	32.5	3.85	3.51	5.02	7.04
0.8	0.8	20	2.959	0.4	90	10	40	5.06	4.75	9.56	14.08
0.4	0.4	10	2.994	0.4	90	45	50	3.41	3.07	3.24	4.35
0.4	0.4	20	3.062	0.8	90	45	50	4.69	4.28	6.52	8.7
0.4	0.6	10	3.004	0.267	90	45	50	4.19	3.79	4.87	6.53
0.4	0.6	20	3.067	0.533	90	45	50	6.5	6.15	9.79	13.05
0.4	0.8	10	3.015	0.2	90	45	50	5.14	4.63	6.49	8.7
0.4	0.8	20	3.073	0.4	90	45	50	8.43	7.94	13.07	17.41
0.6	0.4	10	2.961	0.4	90	45	50	2.88	2.66	3.35	4.34
0.6	0.4	20	3.029	0.8	90	45	50	3.52	3.36	6.49	8.67
0.6	0.6	10	2.973	0.267	90	45	50	3.77	3.56	5.03	6.5
0.6	0.6	20	3.036	0.533	90	45	50	5.16	4.91	9.74	13.01
0.6	0.8	10	2.986	0.2	90	45	50	4.63	4.5	6.72	8.67
0.6	0.8	20	3.042	0.4	90	45	50	6.95	6.53	13.01	17.34
0.8	0.4	10	2.869	0.4	90	45	15	2.09	1.87	2.69	3.52
0.8	0.4	20	2.942	0.8	90	45	50	2.5	2.29	4.76	7.04
0.8	0.6	10	2.887	0.267	90	45	45	2.62	2.41	3.76	5.28
0.8	0.6	20	2.951	0.533	90	45	50	3.36	3.16	7.16	10.56
0.8	0.8	10	2.904	0.2	90	45	50	3.24	3.04	5.02	7.04
0.8	0.8	20	2.959	0.4	90	45	50	4.18	4	9.56	14.08
0.4	0.4	10	3.116	0.2	50	25	27.5	2.42	2.3	2.18	2.73

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.4	20	3.184	0.4	50	25	30	3.15	3.07	3.9	5.47
0.4	0.6	10	3.127	0.133	50	25	35	3.02	2.9	2.88	4.1
0.4	0.6	20	3.189	0.267	50	25	42.5	4.52	4.38	5.85	8.2
0.4	0.8	10	3.137	0.1	50	25	37.5	3.83	3.59	3.84	5.47
0.4	0.8	20	3.195	0.2	50	25	42.5	5.96	5.83	7.81	10.93
0.6	0.4	10	3.144	0.2	50	25	17.5	2.23	2.08	2.24	2.67
0.6	0.4	20	3.213	0.4	50	25	25	2.84	2.64	3.94	5.29
0.6	0.6	10	3.156	0.133	50	25	27.5	2.7	2.54	3	3.97
0.6	0.6	20	3.219	0.267	50	25	30	3.68	3.59	5.92	7.94
0.6	0.8	10	3.169	0.1	50	25	27.5	3.31	3.19	4	5.29
0.6	0.8	20	3.225	0.2	50	25	37.5	4.87	4.8	7.9	10.59
0.8	0.4	10	3.114	0.2	50	25	0	2.1	1.98	1.96	2.28
0.8	0.4	20	3.186	0.4	50	25	12.5	2.52	2.4	2.94	4.07
0.8	0.6	10	3.131	0.133	50	25	10	2.4	2.33	2.25	3.05
0.8	0.6	20	3.195	0.267	50	25	10	3.06	3.09	4.42	6.1
0.8	0.8	10	3.148	0.1	50	25	10	2.93	2.8	3.01	4.07
0.8	0.8	20	3.203	0.2	50	25	15	3.74	3.69	5.9	8.14
0.4	0.4	10	3.019	0.2	70	35	40	3.37	3.11	2.87	3.9
0.4	0.4	20	3.087	0.4	70	35	42.5	4.74	4.39	5.78	7.81
0.4	0.6	10	3.030	0.133	70	35	45	4.2	3.84	4.3	5.86
0.4	0.6	20	3.093	0.267	70	35	47.5	6.41	6.13	8.68	11.71
0.4	0.8	10	3.041	0.1	70	35	45	5.15	4.72	5.74	7.81
0.4	0.8	20	3.098	0.2	70	35	47.5	8.47	8.11	11.58	15.62
0.6	0.4	10	2.999	0.2	70	35	35	2.89	2.64	2.97	3.86
0.6	0.4	20	3.068	0.4	70	35	37.5	3.81	3.51	5.77	7.73
0.6	0.6	10	3.012	0.133	70	35	42.5	3.68	3.43	4.46	5.8
0.6	0.6	20	3.074	0.267	70	35	45	5.08	4.96	8.67	11.59
0.6	0.8	10	3.024	0.1	70	35	42.5	4.53	4.4	5.95	7.73
0.6	0.8	20	3.080	0.2	70	35	45	6.86	6.69	11.57	15.46
0.8	0.4	10	2.921	0.2	70	35	17.5	2.37	2.18	2.48	3.1
0.8	0.4	20	2.993	0.4	70	35	0	2.95	2.79	4.25	6.2
0.8	0.6	10	2.938	0.133	70	35	27.5	2.75	2.53	3.33	4.65
0.8	0.6	20	3.002	0.267	70	35	27.5	3.51	3.46	6.39	9.29
0.8	0.8	10	2.955	0.1	70	35	22.5	3.33	3.12	4.45	6.2
0.8	0.8	20	3.010	0.2	70	35	30	4.47	4.24	8.54	12.39
0.4	0.4	10	2.994	0.2	90	45	50	3.57	3.26	3.24	4.35
0.4	0.4	20	3.062	0.4	90	45	50	5.04	4.67	6.52	8.7
0.4	0.6	10	3.004	0.133	90	45	50	4.38	3.98	4.87	6.53
0.4	0.6	20	3.067	0.267	90	45	50	6.93	6.57	9.79	13.05
0.4	0.8	10	3.015	0.1	90	45	50	5.35	4.86	6.49	8.7

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.8	20	3.073	0.2	90	45	50	8.95	8.53	13.07	17.41
0.6	0.4	10	2.961	0.2	90	45	50	3.07	2.82	3.35	4.34
0.6	0.4	20	3.029	0.4	90	45	50	4.13	3.81	6.49	8.67
0.6	0.6	10	2.973	0.133	90	45	50	3.97	3.72	5.03	6.5
0.6	0.6	20	3.036	0.267	90	45	50	5.55	5.37	9.74	13.01
0.6	0.8	10	2.986	0.1	90	45	50	4.82	4.69	6.72	8.67
0.6	0.8	20	3.042	0.2	90	45	50	7.43	7.1	13.01	17.34
0.8	0.4	10	2.869	0.2	90	45	15	2.22	1.99	2.69	3.52
0.8	0.4	20	2.942	0.4	90	45	50	2.85	2.58	4.76	7.04
0.8	0.6	10	2.887	0.133	90	45	40	2.73	2.49	3.76	5.28
0.8	0.6	20	2.951	0.267	90	45	50	3.7	3.45	7.16	10.56
0.8	0.8	10	2.904	0.1	90	45	50	3.35	3.16	5.02	7.04
0.8	0.8	20	2.959	0.2	90	45	50	4.53	4.34	9.56	14.08
0.4	0.4	10	3.116	0.2	50	10	35	2.56	2.45	2.18	2.73
0.4	0.4	20	3.184	0.4	50	10	35	3.23	3.15	3.9	5.47
0.4	0.6	10	3.127	0.133	50	10	40	3.5	3.28	2.88	4.1
0.4	0.6	20	3.189	0.267	50	10	42.5	4.89	4.67	5.85	8.2
0.4	0.8	10	3.137	0.1	50	10	40	4.36	4.1	3.84	5.47
0.4	0.8	20	3.195	0.2	50	10	45	6.64	6.45	7.81	10.93
0.6	0.4	10	3.144	0.2	50	10	90	2.31	2.23	2.24	2.67
0.6	0.4	20	3.213	0.4	50	10	25	2.91	2.71	3.94	5.29
0.6	0.6	10	3.156	0.133	50	10	27.5	2.98	2.82	3	3.97
0.6	0.6	20	3.219	0.267	50	10	32.5	4	3.87	5.92	7.94
0.6	0.8	10	3.169	0.1	50	10	30	3.7	3.58	4	5.29
0.6	0.8	20	3.225	0.2	50	10	37.5	5.39	5.33	7.9	10.59
0.8	0.4	10	3.114	0.2	50	10	90	2.4	2.29	1.96	2.28
0.8	0.4	20	3.186	0.4	50	10	92.5	2.84	2.76	2.94	4.07
0.8	0.6	10	3.131	0.133	50	10	92.5	2.82	2.52	2.25	3.05
0.8	0.6	20	3.195	0.267	50	10	92.5	3.52	3.32	4.42	6.1
0.8	0.8	10	3.148	0.1	50	10	12.5	3.25	3.12	3.01	4.07
0.8	0.8	20	3.203	0.2	50	10	92.5	4.24	4.04	5.9	8.14
0.4	0.4	10	3.019	0.2	70	10	42.5	3.88	3.53	2.87	3.9
0.4	0.4	20	3.087	0.4	70	10	42.5	4.95	4.7	5.78	7.81
0.4	0.6	10	3.030	0.133	70	10	45	5.14	4.65	4.3	5.86
0.4	0.6	20	3.093	0.267	70	10	47.5	7.3	6.92	8.68	11.71
0.4	0.8	10	3.041	0.1	70	10	47.5	6.32	5.85	5.74	7.81
0.4	0.8	20	3.098	0.2	70	10	47.5	9.81	9.41	11.58	15.62
0.6	0.4	10	2.999	0.2	70	10	32.5	3.07	2.9	2.97	3.86
0.6	0.4	20	3.068	0.4	70	10	37.5	4.02	3.74	5.77	7.73
0.6	0.6	10	3.012	0.133	70	10	42.5	4.27	3.96	4.46	5.8

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.6	0.6	20	3.074	0.267	70	10	45	5.82	5.6	8.67	11.59
0.6	0.8	10	3.024	0.1	70	10	45	5.48	5.22	5.95	7.73
0.6	0.8	20	3.080	0.2	70	10	45	8.08	7.84	11.57	15.46
0.8	0.4	10	2.921	0.2	70	10	5	2.71	2.61	2.48	3.1
0.8	0.4	20	2.993	0.4	70	10	95	3.52	3.24	4.25	6.2
0.8	0.6	10	2.938	0.133	70	10	22.5	3.19	2.95	3.33	4.65
0.8	0.6	20	3.002	0.267	70	10	92.5	4.01	3.79	6.39	9.29
0.8	0.8	10	2.955	0.1	70	10	27.5	3.93	3.62	4.45	6.2
0.8	0.8	20	3.010	0.2	70	10	35	5.21	4.95	8.54	12.39
0.4	0.4	10	2.994	0.2	90	10	50	4.38	3.83	3.24	4.35
0.4	0.4	20	3.062	0.4	90	10	50	5.62	5.13	6.52	8.7
0.4	0.6	10	3.004	0.133	90	10	50	5.75	5.12	4.87	6.53
0.4	0.6	20	3.067	0.267	90	10	50	8.23	7.73	9.79	13.05
0.4	0.8	10	3.015	0.1	90	10	50	7.08	6.54	6.49	8.7
0.4	0.8	20	3.073	0.2	90	10	50	11.02	10.33	13.07	17.41
0.6	0.4	10	2.961	0.2	90	10	50	3.37	3.12	3.35	4.34
0.6	0.4	20	3.029	0.4	90	10	50	4.44	4.15	6.49	8.67
0.6	0.6	10	2.973	0.133	90	10	50	4.81	4.4	5.03	6.5
0.6	0.6	20	3.036	0.267	90	10	50	6.5	6.27	9.74	13.01
0.6	0.8	10	2.986	0.1	90	10	50	6.18	5.83	6.72	8.67
0.6	0.8	20	3.042	0.2	90	10	50	9.14	8.77	13.01	17.34
0.8	0.4	10	2.869	0.2	90	10	5	2.84	2.64	2.69	3.52
0.8	0.4	20	2.942	0.4	90	10	100	3.72	3.44	4.76	7.04
0.8	0.6	10	2.887	0.133	90	10	30	3.19	2.83	3.76	5.28
0.8	0.6	20	2.951	0.267	90	10	10	4.07	3.88	7.16	10.56
0.8	0.8	10	2.904	0.1	90	10	32.5	4.08	3.68	5.02	7.04
0.8	0.8	20	2.959	0.2	90	10	60	5.58	5.15	9.56	14.08
0.4	0.4	10	3.216	0.4	40	15	0	1.8	1.83	1.8	2.73
0.4	0.4	20	3.284	0.8	40	15	12.5	2.08	2.01	2.78	4.03
0.4	0.6	10	3.227	0.267	40	15	27.5	2.33	2.3	2.47	3.72
0.4	0.6	20	3.290	0.533	40	15	37.5	3.1	3.07	4.18	6.04
0.4	0.8	10	3.238	0.2	40	15	32.5	2.93	2.83	3.36	4.8
0.4	0.8	20	3.295	0.4	40	15	40	4.2	4.07	5.57	8.05
0.6	0.4	10	3.294	0.4	40	15	90	1.87	1.83	1.87	2.51
0.6	0.4	20	3.363	0.8	40	15	92.5	2.05	2.09	2.85	3.83
0.6	0.6	10	3.307	0.267	40	15	5	2.17	2.09	2.16	3.23
0.6	0.6	20	3.369	0.533	40	15	17.5	2.72	2.71	4.28	5.74
0.6	0.8	10	3.319	0.2	40	15	12.5	2.67	2.62	2.97	4.15
0.6	0.8	20	3.375	0.4	40	15	25	3.44	3.43	5.71	7.65
0.8	0.4	10	3.314	0.4	40	15	90	1.89	1.82	1.79	2.25

b	t	g	a	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.8	0.4	20	3.387	0.8	40	15	92.5	1.98	2.01	2.33	2.84
0.8	0.6	10	3.331	0.267	40	15	92.5	2.14	2.03	1.85	2.64
0.8	0.6	20	3.395	0.533	40	15	0	2.54	2.58	3.22	4.25
0.8	0.8	10	3.348	0.2	40	15	0	2.57	2.58	2.47	3.29
0.8	0.8	20	3.404	0.4	40	15	2.5	3.1	3.15	4.3	5.67
0.4	0.4	10	3.216	0.2	40	15	87.5	1.92	1.87	1.8	2.73
0.4	0.4	20	3.284	0.4	40	15	22.5	2.29	2.26	2.78	4.03
0.4	0.6	10	3.227	0.133	40	15	27.5	2.51	2.41	2.47	3.72
0.4	0.6	20	3.290	0.267	40	15	35	3.35	3.28	4.18	6.04
0.4	0.8	10	3.238	0.1	40	15	32.5	3.09	2.96	3.36	4.8
0.4	0.8	20	3.295	0.2	40	15	40	4.53	4.43	5.57	8.05
0.6	0.4	10	3.294	0.2	40	15	90	2	1.94	1.87	2.51
0.6	0.4	20	3.363	0.4	40	15	92.5	2.29	2.27	2.85	3.83
0.6	0.6	10	3.307	0.133	40	15	12.5	2.28	2.23	2.16	3.23
0.6	0.6	20	3.369	0.267	40	15	17.5	2.97	2.97	4.28	5.74
0.6	0.8	10	3.319	0.1	40	15	12.5	2.8	2.73	2.97	4.15
0.6	0.8	20	3.375	0.2	40	15	25	3.76	3.79	5.71	7.65
0.8	0.4	10	3.314	0.2	40	15	90	2.04	1.92	1.79	2.25
0.8	0.4	20	3.387	0.4	40	15	92.5	2.21	2.13	2.33	2.84
0.8	0.6	10	3.331	0.133	40	15	92.5	2.29	2.14	1.85	2.64
0.8	0.6	20	3.395	0.267	40	15	2.5	2.79	2.81	3.22	4.25
0.8	0.8	10	3.348	0.1	40	15	0	2.69	2.7	2.47	3.29
0.8	0.8	20	3.404	0.2	40	15	2.5	3.4	3.45	4.3	5.67

D2 - CASO MNP**Tabela D.2 – FCT Calculado pelo MEF²⁰, RNA e pelas Equações do LR⁵¹ e da UEG¹⁹**

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.4	20	0.8	10	50	90	2.11	2.07	1.79	2.26
0.4	0.6	10	0.267	10	50	100	2.03	1.91	1.43	2.15
0.4	0.6	20	0.533	10	50	90	2.39	2.4	2.24	2.78
0.4	0.8	10	0.2	10	50	100	2.07	2.05	1.7	2.45
0.4	0.8	20	0.4	10	50	90	3.02	2.97	2.82	3.49
0.6	0.4	10	0.4	10	50	90	1.76	1.73	1.45	1.9
0.6	0.4	20	0.8	10	50	90	1.94	1.9	1.9	2.37
0.6	0.6	10	0.267	10	50	90	1.97	1.95	1.54	2.25
0.6	0.6	20	0.533	10	50	92.5	2.33	2.34	2.33	3.01
0.6	0.8	10	0.2	10	50	90	2.22	2.18	1.94	2.58
0.6	0.8	20	0.4	10	50	92.5	2.98	2.93	2.93	3.79
0.8	0.4	10	0.4	10	50	90	1.71	1.67	1.41	1.91
0.8	0.4	20	0.8	10	50	90	1.82	1.73	1.82	2.38
0.8	0.6	10	0.267	10	50	90	1.91	1.91	1.63	2.26
0.8	0.6	20	0.533	10	50	92.5	2.24	2.21	2.23	3.02
0.8	0.8	10	0.2	10	50	90	2.17	2.16	2.05	2.58
0.8	0.8	20	0.4	10	50	92.5	2.84	2.78	2.81	3.8
0.4	0.4	10	0.4	25	50	100	1.63	1.66	1.39	1.83
0.4	0.4	20	0.8	25	50	87.5	1.73	1.75	1.79	2.26
0.4	0.6	10	0.267	25	50	100	1.76	1.71	1.43	2.15
0.4	0.6	20	0.533	25	50	90	2.15	2.13	2.24	2.78
0.4	0.8	10	0.2	25	50	100	1.8	1.81	1.7	2.45
0.4	0.8	20	0.4	25	50	90	2.63	2.59	2.82	3.49
0.6	0.4	10	0.4	25	50	87.5	1.46	1.44	1.45	1.9
0.6	0.4	20	0.8	25	50	87.5	1.65	1.63	1.9	2.37
0.6	0.6	10	0.267	25	50	87.5	1.57	1.59	1.54	2.25
0.6	0.6	20	0.533	25	50	90	2.09	2.06	2.33	3.01
0.6	0.8	10	0.2	25	50	90	1.81	1.76	1.94	2.58
0.6	0.8	20	0.4	25	50	90	2.59	2.58	2.93	3.79
0.8	0.4	10	0.4	25	50	0	1.44	1.43	1.41	1.91
0.8	0.4	20	0.8	25	50	0	1.58	1.58	1.82	2.38
0.8	0.6	10	0.267	25	50	85	1.56	1.55	1.63	2.26
0.8	0.6	20	0.533	25	50	0	1.98	1.99	2.23	3.02
0.8	0.8	10	0.2	25	50	90	1.76	1.74	2.05	2.58
0.8	0.8	20	0.4	25	50	90	2.44	2.4	2.81	3.8

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.4	10	0.4	10	70	100	1.88	1.87	1.53	1.99
0.4	0.4	20	0.8	10	70	87.5	2.33	2.29	2.07	2.51
0.4	0.6	10	0.267	10	70	92.5	2.1	2.1	1.64	2.38
0.4	0.6	20	0.533	10	70	87.5	2.76	2.78	2.71	3.31
0.4	0.8	10	0.2	10	70	90	2.37	2.35	2.06	2.75
0.4	0.8	20	0.4	10	70	87.5	3.52	3.5	3.41	4.16
0.6	0.4	10	0.4	10	70	90	1.85	1.85	1.61	2.01
0.6	0.4	20	0.8	10	70	90	2.05	2.06	2.22	2.53
0.6	0.6	10	0.267	10	70	87.5	2.17	2.17	1.81	2.4
0.6	0.6	20	0.533	10	70	87.5	2.7	2.69	2.73	3.36
0.6	0.8	10	0.2	10	70	87.5	2.54	2.51	2.28	2.79
0.6	0.8	20	0.4	10	70	85	3.45	3.43	3.44	4.23
0.8	0.4	10	0.4	10	70	90	1.78	1.77	1.56	1.95
0.8	0.4	20	0.8	10	70	0	1.91	1.87	2.12	2.44
0.8	0.6	10	0.267	10	70	87.5	2.08	2.1	1.8	2.31
0.8	0.6	20	0.533	10	70	92.5	2.62	2.59	2.47	3.16
0.8	0.8	10	0.2	10	70	90	2.49	2.48	2.26	2.65
0.8	0.8	20	0.4	10	70	90	3.3	3.27	3.1	3.98
0.4	0.4	10	0.4	35	70	100	1.55	1.53	1.53	1.99
0.4	0.4	20	0.8	35	70	12.5	1.95	1.86	2.07	2.51
0.4	0.6	10	0.267	35	70	0	1.83	1.73	1.64	2.38
0.4	0.6	20	0.533	35	70	0	2.46	2.47	2.71	3.31
0.4	0.8	10	0.2	35	70	0	2.1	2.06	2.06	2.75
0.4	0.8	20	0.4	35	70	0	3.33	3.28	3.41	4.16
0.6	0.4	10	0.4	35	70	0	1.58	1.56	1.61	2.01
0.6	0.4	20	0.8	35	70	82.5	1.76	1.77	2.22	2.53
0.6	0.6	10	0.267	35	70	85	1.7	1.73	1.81	2.4
0.6	0.6	20	0.533	35	70	87.5	2.38	2.36	2.73	3.36
0.6	0.8	10	0.2	35	70	90	1.99	1.94	2.28	2.79
0.6	0.8	20	0.4	35	70	85	2.93	2.93	3.44	4.23
0.8	0.4	10	0.4	35	70	0	1.6	1.55	1.56	1.95
0.8	0.4	20	0.8	35	70	0	1.78	1.71	2.12	2.44
0.8	0.6	10	0.267	35	70	0	1.76	1.75	1.8	2.31
0.8	0.6	20	0.533	35	70	0	2.33	2.28	2.47	3.16
0.8	0.8	10	0.2	35	70	0	2.02	2.01	2.26	2.65
0.8	0.8	20	0.4	35	70	87.5	2.78	2.76	3.1	3.98
0.4	0.4	10	0.4	10	90	100	1.88	1.88	1.59	2.05
0.4	0.4	20	0.8	10	90	95	2.33	2.3	2.17	2.59
0.4	0.6	10	0.267	10	90	5	2.11	2.1	1.73	2.45
0.4	0.6	20	0.533	10	90	0	3	2.92	2.87	3.49

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.4	0.8	10	0.2	10	90	10	2.45	2.43	2.18	2.9
0.4	0.8	20	0.4	10	90	0	3.97	3.79	3.61	4.39
0.6	0.4	10	0.4	10	90	10	1.84	1.82	1.67	2.04
0.6	0.4	20	0.8	10	90	12.5	2.01	2.02	2.34	2.58
0.6	0.6	10	0.267	10	90	12.5	2.17	2.17	1.9	2.45
0.6	0.6	20	0.533	10	90	15	2.8	2.79	2.87	3.48
0.6	0.8	10	0.2	10	90	12.5	2.59	2.56	2.39	2.89
0.6	0.8	20	0.4	10	90	15	3.57	3.53	3.61	4.38
0.8	0.4	10	0.4	10	90	7.5	1.79	1.78	1.61	1.96
0.8	0.4	20	0.8	10	90	0	1.97	1.99	2.23	2.46
0.8	0.6	10	0.267	10	90	10	2.09	2.12	1.85	2.33
0.8	0.6	20	0.533	10	90	100	2.72	2.63	2.54	3.2
0.8	0.8	10	0.2	10	90	7.5	2.55	2.51	2.33	2.68
0.8	0.8	20	0.4	10	90	100	3.37	3.29	3.2	4.03
0.4	0.4	10	0.4	45	90	0	1.8	2.04	1.59	2.05
0.4	0.4	20	0.8	45	90	0	2.25	2.53	2.17	2.59
0.4	0.6	10	0.267	45	90	0	2.17	2.24	1.73	2.45
0.4	0.6	20	0.533	45	90	0	3.01	3.02	2.87	3.49
0.4	0.8	10	0.2	45	90	0	2.53	2.7	2.18	2.9
0.4	0.8	20	0.4	45	90	0	4.04	3.99	3.61	4.39
0.6	0.4	10	0.4	45	90	0	1.6	1.61	1.67	2.04
0.6	0.4	20	0.8	45	90	0	1.87	2.12	2.34	2.58
0.6	0.6	10	0.267	45	90	0	2.02	1.86	1.9	2.45
0.6	0.6	20	0.533	45	90	0	2.56	2.56	2.87	3.48
0.6	0.8	10	0.2	45	90	0	2.41	2.33	2.39	2.89
0.6	0.8	20	0.4	45	90	0	3.52	3.31	3.61	4.38
0.8	0.4	10	0.4	45	90	87.5	1.48	1.48	1.61	1.96
0.8	0.4	20	0.8	45	90	0	1.77	1.75	2.23	2.46
0.8	0.6	10	0.267	45	90	7.5	1.67	1.66	1.85	2.33
0.8	0.6	20	0.533	45	90	100	2.32	2.31	2.54	3.2
0.8	0.8	10	0.2	45	90	0	1.98	1.96	2.33	2.68
0.8	0.8	20	0.4	45	90	10	2.75	2.75	3.2	4.03
0.4	0.4	10	0.2	25	50	100	1.63	1.6	1.39	1.83
0.4	0.4	20	0.4	25	50	85	1.84	1.85	1.79	2.26
0.4	0.6	10	0.133	25	50	100	1.77	1.72	1.43	2.15
0.4	0.6	20	0.267	25	50	92.5	2.33	2.29	2.24	2.78
0.4	0.8	10	0.1	25	50	100	1.81	1.85	1.7	2.45
0.4	0.8	20	0.2	25	50	90	2.79	2.78	2.82	3.49
0.6	0.4	10	0.2	25	50	87.5	1.51	1.5	1.45	1.9
0.6	0.4	20	0.4	25	50	0	1.79	1.75	1.9	2.37

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.6	0.6	10	0.133	25	50	87.5	1.62	1.66	1.54	2.25
0.6	0.6	20	0.267	25	50	90	2.26	2.24	2.33	3.01
0.6	0.8	10	0.1	25	50	90	1.88	1.84	1.94	2.58
0.6	0.8	20	0.2	25	50	90	2.78	2.78	2.93	3.79
0.8	0.4	10	0.2	25	50	0	1.55	1.53	1.41	1.91
0.8	0.4	20	0.4	25	50	0	1.87	1.86	1.82	2.38
0.8	0.6	10	0.133	25	50	85	1.61	1.62	1.63	2.26
0.8	0.6	20	0.267	25	50	0	2.15	2.18	2.23	3.02
0.8	0.8	10	0.1	25	50	90	1.84	1.82	2.05	2.58
0.8	0.8	20	0.2	25	50	90	2.62	2.58	2.81	3.8
0.4	0.4	10	0.2	35	70	0	1.62	1.66	1.53	1.99
0.4	0.4	20	0.4	35	70	0	2.18	2.14	2.07	2.51
0.4	0.6	10	0.133	35	70	0	1.83	1.78	1.64	2.38
0.4	0.6	20	0.267	35	70	87.5	2.59	2.58	2.71	3.31
0.4	0.8	10	0.1	35	70	0	2.08	2.11	2.06	2.75
0.4	0.8	20	0.2	35	70	0	3.37	3.33	3.41	4.16
0.6	0.4	10	0.2	35	70	0	1.7	1.68	1.61	2.01
0.6	0.4	20	0.4	35	70	10	2.08	2.06	2.22	2.53
0.6	0.6	10	0.133	35	70	2.5	1.79	1.82	1.81	2.4
0.6	0.6	20	0.267	35	70	87.5	2.56	2.56	2.73	3.36
0.6	0.8	10	0.1	35	70	90	2.07	2.03	2.28	2.79
0.6	0.8	20	0.2	35	70	85	3.14	3.13	3.44	4.23
0.8	0.4	10	0.2	35	70	2.5	1.73	1.72	1.56	1.95
0.8	0.4	20	0.4	35	70	0	2.07	2.07	2.12	2.44
0.8	0.6	10	0.133	35	70	0	1.84	1.86	1.8	2.31
0.8	0.6	20	0.267	35	70	0	2.51	2.51	2.47	3.16
0.8	0.8	10	0.1	35	70	0	2.1	2.11	2.26	2.65
0.8	0.8	20	0.2	35	70	87.5	2.98	2.93	3.1	3.98
0.4	0.4	10	0.2	45	90	0	1.84	1.92	1.59	2.05
0.4	0.4	20	0.4	45	90	0	2.47	2.35	2.17	2.59
0.4	0.6	10	0.133	45	90	0	2.21	2.18	1.73	2.45
0.4	0.6	20	0.267	45	90	0	3	2.94	2.87	3.49
0.4	0.8	10	0.1	45	90	0	2.54	2.67	2.18	2.9
0.4	0.8	20	0.2	45	90	0	4.02	3.93	3.61	4.39
0.6	0.4	10	0.2	45	90	0	1.66	1.64	1.67	2.04
0.6	0.4	20	0.4	45	90	0	2.09	2.09	2.34	2.58
0.6	0.6	10	0.133	45	90	0	2.08	1.92	1.9	2.45
0.6	0.6	20	0.267	45	90	0	2.6	2.6	2.87	3.48
0.6	0.8	10	0.1	45	90	0	2.42	2.38	2.39	2.89
0.6	0.8	20	0.2	45	90	0	3.52	3.39	3.61	4.38

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.8	0.4	10	0.2	45	90	12.5	1.56	1.57	1.61	1.96
0.8	0.4	20	0.4	45	90	0	1.92	2	2.23	2.46
0.8	0.6	10	0.133	45	90	7.5	1.75	1.76	1.85	2.33
0.8	0.6	20	0.267	45	90	100	2.49	2.45	2.54	3.2
0.8	0.8	10	0.1	45	90	7.5	2.04	2.04	2.33	2.68
0.8	0.8	20	0.2	45	90	10	2.93	2.92	3.2	4.03
0.4	0.4	10	0.2	10	50	92.5	1.88	1.89	1.39	1.83
0.4	0.4	20	0.4	10	50	90	2.26	2.23	1.79	2.26
0.4	0.6	10	0.133	10	50	100	2.01	2.01	1.43	2.15
0.4	0.6	20	0.267	10	50	92.5	2.65	2.63	2.24	2.78
0.4	0.8	10	0.1	10	50	92.5	2.16	2.15	1.7	2.45
0.4	0.8	20	0.2	10	50	90	3.27	3.23	2.82	3.49
0.6	0.4	10	0.2	10	50	90	1.86	1.82	1.45	1.9
0.6	0.4	20	0.4	10	50	90	2.11	2.09	1.9	2.37
0.6	0.6	10	0.133	10	50	90	2.07	2.06	1.54	2.25
0.6	0.6	20	0.267	10	50	92.5	2.6	2.59	2.33	3.01
0.6	0.8	10	0.1	10	50	90	2.35	2.3	1.94	2.58
0.6	0.8	20	0.2	10	50	92.5	3.26	3.2	2.93	3.79
0.8	0.4	10	0.2	10	50	90	1.83	1.76	1.41	1.91
0.8	0.4	20	0.4	10	50	90	1.99	1.92	1.82	2.38
0.8	0.6	10	0.133	10	50	90	2.03	2.01	1.63	2.26
0.8	0.6	20	0.267	10	50	92.5	2.52	2.44	2.23	3.02
0.8	0.8	10	0.1	10	50	90	2.32	2.27	2.05	2.58
0.8	0.8	20	0.2	10	50	92.5	3.13	3.03	2.81	3.8
0.4	0.4	10	0.2	10	70	92.5	1.98	2.02	1.53	1.99
0.4	0.4	20	0.4	10	70	90	2.54	2.53	2.07	2.51
0.4	0.6	10	0.133	10	70	90	2.24	2.25	1.64	2.38
0.4	0.6	20	0.267	10	70	87.5	3.04	3.02	2.71	3.31
0.4	0.8	10	0.1	10	70	90	2.5	2.5	2.06	2.75
0.4	0.8	20	0.2	10	70	87.5	3.82	3.77	3.41	4.16
0.6	0.4	10	0.2	10	70	87.5	2	2.01	1.61	2.01
0.6	0.4	20	0.4	10	70	87.5	2.35	2.35	2.22	2.53
0.6	0.6	10	0.133	10	70	85	2.34	2.33	1.81	2.4
0.6	0.6	20	0.267	10	70	87.5	2.99	2.98	2.73	3.36
0.6	0.8	10	0.1	10	70	87.5	2.69	2.67	2.28	2.79
0.6	0.8	20	0.2	10	70	85	3.79	3.72	3.44	4.23
0.8	0.4	10	0.2	10	70	2.5	1.98	1.95	1.56	1.95
0.8	0.4	20	0.4	10	70	0	2.31	2.28	2.12	2.44
0.8	0.6	10	0.133	10	70	87.5	2.26	2.25	1.8	2.31
0.8	0.6	20	0.267	10	70	92.5	2.91	2.88	2.47	3.16

b	t	g	G/t	q	a _s	x	MEF	RNA	LR	UEG
0.8	0.8	10	0.1	10	70	90	2.66	2.63	2.26	2.65
0.8	0.8	20	0.2	10	70	90	3.62	3.54	3.1	3.98
0.4	0.4	10	0.2	10	90	97.5	2.1	2.07	1.59	2.05
0.4	0.4	20	0.4	10	90	0	2.61	2.58	2.17	2.59
0.4	0.6	10	0.133	10	90	7.5	2.33	2.31	1.73	2.45
0.4	0.6	20	0.267	10	90	0	3.17	3.14	2.87	3.49
0.4	0.8	10	0.1	10	90	10	2.59	2.58	2.18	2.9
0.4	0.8	20	0.2	10	90	0	4.11	3.98	3.61	4.39
0.6	0.4	10	0.2	10	90	90	2.05	2.06	1.67	2.04
0.6	0.4	20	0.4	10	90	12.5	2.42	2.42	2.34	2.58
0.6	0.6	10	0.133	10	90	12.5	2.41	2.38	1.9	2.45
0.6	0.6	20	0.267	10	90	15	3.07	3.06	2.87	3.48
0.6	0.8	10	0.1	10	90	12.5	2.75	2.74	2.39	2.89
0.6	0.8	20	0.2	10	90	15	3.87	3.81	3.61	4.38
0.8	0.4	10	0.2	10	90	7.5	2.01	1.99	1.61	1.96
0.8	0.4	20	0.4	10	90	92.5	2.31	2.23	2.23	2.46
0.8	0.6	10	0.133	10	90	87.5	2.32	2.28	1.85	2.33
0.8	0.6	20	0.267	10	90	100	2.97	2.96	2.54	3.2
0.8	0.8	10	0.1	10	90	7.5	2.7	2.67	2.33	2.68
0.8	0.8	20	0.2	10	90	100	3.65	3.6	3.2	4.03
0.4	0.4	10	0.4	15	40	100	1.77	1.81	1.3	1.72
0.4	0.4	20	0.8	15	40	90	1.72	1.7	1.6	2.09
0.4	0.6	10	0.267	15	40	100	1.91	1.78	1.33	1.99
0.4	0.6	20	0.533	15	40	92.5	2.05	1.98	1.9	2.5
0.4	0.8	10	0.2	15	40	100	1.95	1.85	1.44	2.25
0.4	0.8	20	0.4	15	40	92.5	2.51	2.43	2.39	3
0.6	0.4	10	0.4	15	40	90	1.47	1.49	1.34	1.82
0.6	0.4	20	0.8	15	40	90	1.62	1.59	1.69	2.25
0.6	0.6	10	0.267	15	40	90	1.57	1.58	1.37	2.14
0.6	0.6	20	0.533	15	40	92.5	1.91	1.91	2.03	2.74
0.6	0.8	10	0.2	15	40	92.5	1.77	1.71	1.69	2.43
0.6	0.8	20	0.4	15	40	92.5	2.43	2.39	2.55	3.45
0.8	0.4	10	0.4	15	40	90	1.45	1.46	1.32	1.87
0.8	0.4	20	0.8	15	40	92.5	1.54	1.44	1.63	2.32
0.8	0.6	10	0.267	15	40	87.5	1.58	1.57	1.49	2.21
0.8	0.6	20	0.533	15	40	90	1.73	1.75	2.05	2.91
0.8	0.8	10	0.2	15	40	90	1.7	1.7	1.88	2.52
0.8	0.8	20	0.4	15	40	90	2.21	2.18	2.58	3.66
0.4	0.4	10	0.2	15	40	100	1.76	1.7	1.3	1.72
0.4	0.4	20	0.4	15	40	92.5	1.85	1.82	1.6	2.09

b	t	g	G/t	q	a_s	x	MEF	RNA	LR	UEG
0.4	0.6	10	0.133	15	40	100	1.91	1.78	1.33	1.99
0.4	0.6	20	0.267	15	40	92.5	2.24	2.15	1.9	2.5
0.4	0.8	10	0.1	15	40	100	1.96	1.91	1.44	2.25
0.4	0.8	20	0.2	15	40	92.5	2.69	2.63	2.39	3
0.6	0.4	10	0.2	15	40	90	1.53	1.52	1.34	1.82
0.6	0.4	20	0.4	15	40	90	1.73	1.71	1.69	2.25
0.6	0.6	10	0.133	15	40	90	1.63	1.65	1.37	2.14
0.6	0.6	20	0.267	15	40	92.5	2.1	2.09	2.03	2.74
0.6	0.8	10	0.1	15	40	92.5	1.85	1.79	1.69	2.43
0.6	0.8	20	0.2	15	40	92.5	2.62	2.6	2.55	3.45
0.8	0.4	10	0.2	15	40	90	1.53	1.51	1.32	1.87
0.8	0.4	20	0.4	15	40	90	1.66	1.59	1.63	2.32
0.8	0.6	10	0.133	15	40	87.5	1.63	1.64	1.49	2.21
0.8	0.6	20	0.267	15	40	90	1.92	1.92	2.05	2.91
0.8	0.8	10	0.1	15	40	90	1.79	1.78	1.88	2.52
0.8	0.8	20	0.2	15	40	90	2.41	2.38	2.58	3.66

ademarcadoso@yahoo.com.br
ademar@usp.br