

# CÁLCULO DE CONCENTRAÇÃO DE TENSÕES EM JUNTAS TUBULARES UTILIZANDO REDES NEURAIS ARTIFICIAIS

Eng. MSc. Ademar de Azevedo Cardoso  
Prof. Dr. Oscar Brito Augusto  
Prof. Dr. Carlos Alberto Nunes Dias  
Depto. de Eng. Naval e Oceânica da  
Universidade de São Paulo



## Resumo

Neste trabalho, como alternativa para o cálculo do Fator de Concentrações de Tensão em juntas tubulares, propõe-se uma nova abordagem onde se utilizam Redes Neurais Artificiais (RNA), cuja característica principal é a capacidade de generalização, a partir de um conjunto de dados, sem a necessidade de se estabelecer, *a priori*, uma função explícita entre as variáveis de entrada e as de saída do problema. Para o treinamento da rede foram utilizados modelos calculados através do Método dos Elementos Finitos onde se contabilizou a geometria tridimensional do cordão de solda da junta. O procedimento proposto, como um todo, representa um avanço em relação aos métodos tradicionais de cálculo de concentração de tensões em juntas, quer seja porque contabiliza os efeitos do modo pelo qual se faz o preenchimento pela solda, quer seja porque utiliza RNA e prescinde do conhecimento explícito de fórmulas matemáticas.

## Abstract

As an alternative approach to calculate the Stress Concentration Factor we propose the Artificial Neural Networks (ANN). Neural networks have the ability to learn, to generalize and, besides, the user does not need to know *a priori* a function between input and output data. The training set used in this research work was obtained by FE simulations of the joint taking into account the 3D geometry of the welding fillet between chord and brace of the joint. The procedure proposed represents an advance among the traditional SCF calculations for tubular joints, both because it takes into account the effects of the welding fillet in the SCF and because it uses the Neural Network approach for the stress concentration factor computation.

## 1. INTRODUÇÃO

Da pesquisa na literatura existente sobre juntas tubulares soldadas, veja referências 1, 2 e 3, evidencia-se que as diversas formulações utilizadas para o cálculo do Fator de Concentração de Tensões (FCT) são, basicamente, obtidas por procedimento similar. Geralmente, combinam-se as variáveis julgadas relevantes para o cálculo do FCT, gerando-se inúmeras estruturas de conformação geométricas distintas que são ensaiadas mecanicamente em laboratório ou simuladas através de programas baseados no Método dos Elementos Finitos (MEF). De posse dos resultados, idealiza-se uma expressão que

represente o fenômeno e ajustam-se os parâmetros desta expressão com técnicas de regressão.

Muitas vezes, no entanto, a expressão idealizada para o cálculo do FCT fornece bons resultados apenas para uma faixa restrita de valores das variáveis envolvidas no modelo [4], ou porque o conjunto de dados é inadequado para a regressão, ou porque a expressão em seu todo não é a mais adequada. Em certos casos, como no da junta tipo Y, tubo principal e secundário têm expressões diferentes, ressaltando-se o que é, provavelmente, a principal dificuldade dos pesquisadores: encontrar uma

expressão matemática simples que represente adequadamente o fenômeno da concentração de tensões nas juntas soldadas. As formulações propostas por Kuang [1], Gibstein [2], UEG [3] e Smedley [4], por exemplo, são todas diferentes entre si e evidenciam o grau de incerteza presente em suas avaliações.

Neste trabalho propõe-se um procedimento alternativo para o cálculo do FCT, no qual duas investidas inovadoras são experimentadas no intuito de aprimorar os métodos anteriores.

Primeiro, considera-se um conjunto de dados obtidos de simulações pelo MEF, utilizando-se de elementos sólidos tridimensionais, o que possibilita a inclusão do cordão de solda na geometria do modelo. Com isso, os resultados obtidos tendem a ser mais acurados, seja pela melhor representação física do modelo, seja pela obtenção direta do FCT, sem a necessidade de extrapolações, como usualmente ocorrem nas análises através de modelos de casca.

Segundo, diferentemente do processo usual, o conjunto de dados obtido na etapa anterior não é utilizado para ajustar parâmetros em regressões e sim para treinar Redes Neurais Artificiais (RNA). Este enfoque é vantajoso na medida em que torna desnecessário o conhecimento *a priori* de uma expressão para o cálculo do FCT.

As RNA são baseadas nas redes neurais biológicas, com características de *aprendizado* e *generalização*. São estruturas formadas por muitos processadores simples, ditos *neurônios*, cada um deles com capacidade para pequenos cálculos. Os neurônios são conectados por *canais*, através de um valor numérico denominado *peso*. As RNA são *treinadas* através de um

processo que ajusta os pesos, utilizando-se do conjunto de treinamento, ou seja, *aprendem* de exemplos. Posteriormente, este conhecimento pode ser utilizado para previsão de novos casos, em um processo batizado de *generalização*.

No próximo item será apresentado uma descrição do funcionamento das RNA utilizadas neste trabalho. Em seguida, no item 3, uma descrição do modelo de elementos finitos utilizado para a simulação das juntas. No item 4 estão apresentados os resultados obtidos e, finalmente, no item 5, discorrem-se as principais conclusões e recomendações frutos do desenvolvimento deste trabalho.

#### ———— Nomenclatura —————

D, d	= diâmetros dos tubos primário e secundário
FCT	= fator de concentração de tensões
G	= <i>gap</i> , folga na raiz da solda entre o primário e o secundário
MEF	= Método dos Elementos Finitos
r	= raio de concordância
RNA	= Redes Neurais Artificiais
T, t	= espessura dos tubos primário, secundário
$X_i$	= vetor com valores das variáveis de entrada
$\bar{Y}_i$	= vetor com valores das variáveis de saída calculados pela rede.
$Y_i$	= vetor com valores das variáveis de saída obtidos pelo MEF.
$W_{ij}$	= pesos entre os neurônios <i>i</i> e <i>j</i> .
$\eta$	= taxa de aprendizado da rede.
$\delta_j$	= erro calculado no <i>j</i> -ésimo neurônio.
$\theta_j$	= limiar de disparo do <i>j</i> -ésimo neurônio.
$\zeta_j$	= soma ponderada dos sinais que chegam ao <i>j</i> -ésimo neurônio.
$\alpha$	= ângulo de chanfro na base do membro secundário
$\beta$	= d/D.
$\gamma$	= D/2T
$\tau$	= t/T.
$\theta$	= ângulo entre os tubos.
$\psi$	= ângulo de inclinação do secundário ou ângulo de <i>heel</i>

## 2. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são estruturas simples que podem armazenar conhecimento e torná-lo útil para posterior uso. Normalmente possuem alto grau de paralelismo, uma vez que os cálculos envolvidos em cada neurônio de uma camada são independentes dos outros neurônios daquela camada. Apresentam comportamento semelhante ao do cérebro humano em, pelo menos, três aspectos:

- o conhecimento é adquirido pela rede através de um processo de aprendizagem;
- as conexões entre os neurônios são usadas para armazenar o conhecimento.
- esse conhecimento pode ser utilizado para generalizações.

Lippmann [5] detalhou os tipos de RNA mais comuns, apresentando um estudo detalhado daquelas mais utilizadas, como por exemplo a máquina de Boltzmann, as redes de Hopfield, a rede de Kohonen e as redes do tipo *feed-forward*, com várias camadas interligadas entre si através de pesos.

As redes do tipo *feed-forward* envolvem aproximadamente 90% do total de aplicações de redes neurais utilizadas atualmente, conforme relata Haykin [6]. São particularmente indicadas para problemas em que o conjunto de dados conhecido é formado por casos relacionando entrada e saída, e por isso foram escolhidas para abordar o problema do cálculo do FCT.

### 2.1 - A Arquitetura

Na figura 1 estão representados os principais componentes de uma rede do tipo *feed-forward*. A primeira camada de

neurônios, chamada de camada inicial, possui tantos nós quantas forem as variáveis de entrada do problema. Na última camada são colocados tantos nós quantos forem as variáveis de saída. Assim, para resolver uma equação na variável  $z$ , que é função das variáveis  $x$  e  $y$ , por exemplo, seriam necessários dois neurônios na camada de entrada e um neurônio na camada de saída.

As camadas intermediárias, também chamadas de camadas ocultas, infelizmente, não obedecem a nenhuma regra geral.

Definir as camadas intermediárias, e também o número de neurônios em cada uma delas, é uma tarefa que depende de vários fatores, como o tamanho do conjunto de treinamento, o fenômeno a ser representado, o número de variáveis nas camadas de entrada e de saída.

As camadas são totalmente interconectadas, ou seja, todos os neurônios da primeira camada são conectados com todos os neurônios da camada seguinte, que por sua vez estão conectados com os neurônios da próxima camada, repetindo-se o processo até que se atinja a camada final. Essas conexões são realizadas por pesos aleatoriamente inicializados.

### 2.2 - O Treinamento

O tipo de treinamento da rede está diretamente associado aos dados disponíveis sobre o fenômeno que se deseja modelar. Voltando-se ao exemplo da função  $z(x,y)$ , imagine que exista um conjunto de dados composto por valores de  $x$  e  $y$ , associados a valores de  $z$ , o que, na nomenclatura de redes neurais, é chamado de pares de treinamento  $((x,y),z)$ . O treinamento com este conjunto é chamado de *supervisionado* porque,

~0000.3

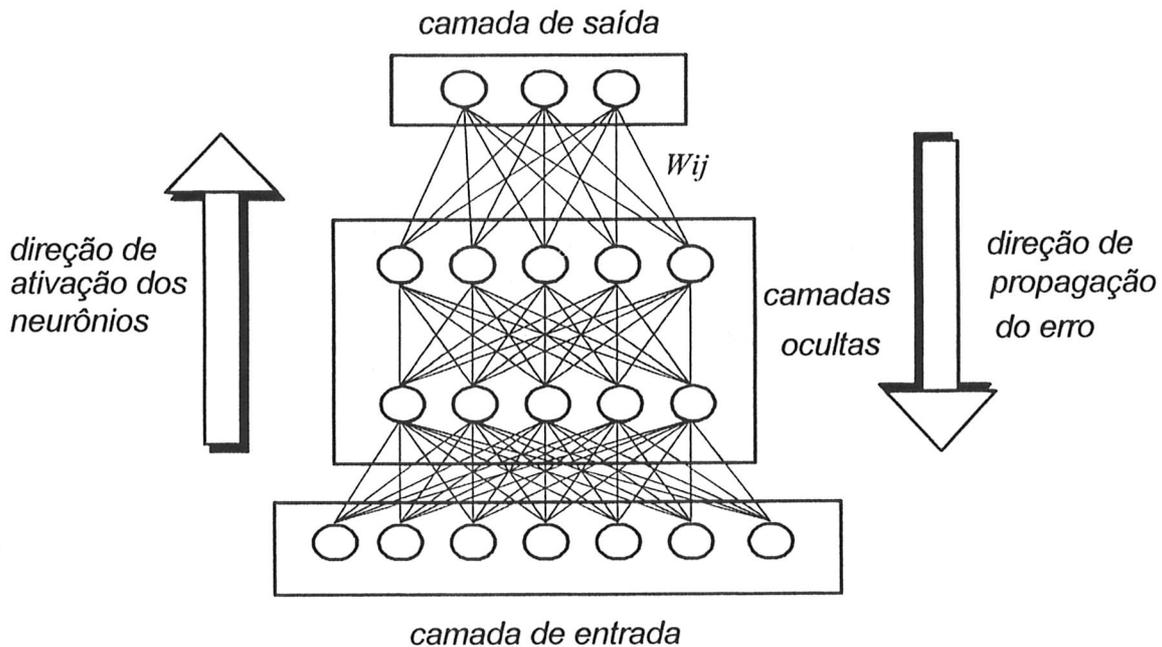


Figura 1- Rede Neural do tipo *feed-forward*

durante o treinamento, cada  $\bar{z}$  fornecido pela rede pode ser comparado com o  $z(x,y)$  da tabela. Por outro lado, se a tabela e dados contivesse apenas os pares  $(x,y)$ , o treinamento seria do tipo *não supervisionado*, o qual se caracteriza pela inexistência de um valor para comparação com o resultado fornecido pela rede. Este tipo de treinamento é comum em problemas de classificação, nos quais o objetivo é agrupar os dados segundo algum critério.

Para entender o treinamento das redes neurais do tipo *feed-forward*, considere-se, sem nenhuma perda de generalização, uma rede com uma camada de entrada com  $p$  neurônios, uma camada oculta com  $k$  neurônios e uma camada de saída com  $q$  neurônios. Considere-se ainda um conjunto de dados que relacionam causa e efeito do fenômeno em análise formados por  $m$  pares de treinamento  $((X_1, Y_1), (X_2, Y_2), \dots,$

$(X_m, Y_m)$ ), em que  $X_i$  e  $Y_i$  são vetores de dimensões  $p$  e  $q$ .

No treinamento, o vetor  $X_i$  é associado com os neurônios da camada de entrada. Cada neurônio da camada oculta recebe uma somatória dos produtos dos componentes de  $X_i$  pelos respectivos pesos que o conectam com os neurônios da camada inicial. Este produto é submetido a uma função, usualmente não linear, produzindo um *signal* de saída daquele neurônio. O mesmo ocorre para todos os  $k$  neurônios da camada oculta. Em seguida, repete-se o processo entre as camadas oculta e final. O vetor obtido na camada final,  $\bar{Y}_i$ , representa, para aquela iteração, a aproximação da rede para a entrada  $X_i$ .

A diferença entre  $\bar{Y}_i$  e o valor correto,  $Y_i$ , é então utilizada para modificarem-se os valores dos pesos entre as camadas de sorte a minimizar o desvio  $\bar{Y}_i - Y_i$ . Assim, na apresentação, à rede, do

~00004

próximo par de treinamento, ela estará configurada com os novos pesos.

Todos os  $m$  pares de treinamento são submetidos ao mesmo processo, sendo que, depois de cada um, os pesos são modificados até que a tolerância desejada seja atingida.

O algoritmo utilizado para fazer a modificação dos pesos é chamado de retro-propagação, nome oriundo do fato de se calcular o desvio na saída e “propagar” este desvio para trás até a primeira camada. Os principais passos do algoritmo podem ser resumidos, conforme representado na tabela 1. Maiores detalhes deste algoritmo podem ser encontrados em Freeman[7] e Wasserman[8].

**Tabela 1 - Algoritmo de Retro-Propagação**

1. Os pesos e os limiares são inicializados com valores aleatórios.
2. Apresenta-se o conjunto de treinamento, estabelecendo-se um conjunto de vetores na camada de entrada ( $X_1, X_2, \dots, X_m$ ) e o respectivo conjunto ( $Y_1, Y_2, \dots, Y_m$ ) na camada de saída.
3. Em cada nó, calcula-se a saída atual pela soma ponderada dos valores dos nós que chegam da camada anterior, fazendo-se uso da seguinte função:

$$y_j = \frac{1}{1 + e^{-(\zeta_j - \theta_j)}}$$

sendo:

$\zeta_j$  - a soma ponderada dos nós que chegam no  $j$ -ésimo nó;

$y_j$  - a saída do  $j$ -ésimo nó;

$\theta_j$  - o limiar do  $j$ -ésimo nó.

4. O erro é atualizado, a partir dos pesos entre a camada de saída e a próxima, utilizando-se a expressão

$$W_{ij}(t+1) = W_{ij}(t) + \eta \cdot \delta_j \cdot y_j$$

sendo:

$W_{ij}$  - peso entre o  $i$ -ésimo nó e o  $j$ -ésimo nó;

Se  $j$  é um nó de uma camada de saída, então:

$$\delta_j = \bar{Y}_j \cdot (1 - \bar{Y}_j) \cdot (\bar{Y}_j - Y_j)$$

Se  $j$  é um nó de uma camada interna então o valor de  $\delta_j$  é calculado por

$$\delta_j = y_j \cdot (1 - y_j) \cdot \sum_k (\delta_k \cdot W_{kj})$$

$\eta$  - a constante de aprendizagem da rede.

5. Volta-se ao passo 2 até atingir-se a tolerância desejada.

### 2.3 A generalização

Depois de treinada, ou seja, todos os pesos foram definidos de forma que, por algum critério, a tolerância requerida foi alcançada, a rede está pronta para fornecer resultados para casos que não foram utilizados durante o treinamento. Este processo, denominado de generalização, é o motivo pelo qual a rede foi treinada. O treinamento pode ser um processo extremamente demorado porém, uma vez treinada a rede estará apta a responder, quase que instantaneamente, à qualquer solicitação de entrada.

### 2.4 Principais dificuldades

O processo de treinamento é usualmente feito pelo algoritmo de *retro-*

200005

*propagação*, eventualmente com algumas modificações que podem acelerar o processo de convergência. Ainda assim, a minimização do desvio através da modificação do conjunto de pesos muitas vezes não atinge a precisão desejada. Isto porque, dependente da robustez do método de busca do mínimo da função erro, pode-se atingir alguma região de mínimo local que esteja longe de outra que poderia resultar a precisão desejada. Além disso, durante a busca pode-se atingir um patamar da função erro e não se conseguir sair, em um número aceitável de iterações, para uma outra região no domínio de busca. Alguns algoritmos, como por exemplo o "Simulated Annealing" [9], [10] sugerem técnicas que conseguem superar estes problemas, mas, em geral, o custo para tanto também é grande.

O número de neurônios na camada oculta é outro fator que pode introduzir erros nos resultados fornecidos pela rede e também tornar proibitivo o tempo necessário para o treinamento de um conjunto de dados. Um número insuficiente pode não conseguir extrair as características básicas do fenômeno estudado, assim como um número muito acima do ideal pode fazer com que a rede "memorize" os pares de treinamento. Mas, qual deve ser o número ideal? Depende do problema! Para atingi-lo é necessário que várias configurações sejam testadas, com um conjunto de treinamento, um de validação e um de teste, todos independentes entre si. Assim, depois de treinar um número suficiente de configurações, utiliza-se o conjunto de validação para comparar a performance dessas redes, com relação a uma função de erro arbitrada. Por fim, o desempenho da rede escolhida é verificado quanto ao conjunto de teste.

Todo este processo, dependendo do tamanho do conjunto de treinamento, pode levar dias e até semanas, mesmo em máquinas de alta performance.

### 3. MODELO DE ELEMENTOS FINITOS

Os dados utilizados para treinamento das RNA foram obtidos, por simulações numéricas através do MEF, de diversos casos de juntas tubulares soldadas tipo-Y. Para obter as geometrias discretizadas das juntas, foi desenvolvido um programa pré-processador específico de geração de malhas [11] com elementos sólidos isoparamétricos de oito nós (BRICK-8, com modos incompatíveis e ordem de integração igual a dois), possibilitando, assim, a representação precisa da intrincada geometria tridimensional do cordão de solda, conforme se mostra na figura 3.1.

O conjunto de dados gerado resulta de 256 casos de análise, para os quais foram tomados valores específicos de variáveis adimensionais, conforme o padrão usualmente encontrado na literatura. Nesses termos, foram consideradas as seguintes relações geométricas adimensionais típicas:

$0.4 \leq d/D \leq 0.8$ , relação de diâmetros entre membros principal e secundário,

$0.4 \leq t/T \leq 0.8$ , relação de espessuras entre membros principal e secundário,

$40 \leq \Psi \leq 90$ , ângulo entre os membros principal e secundário.

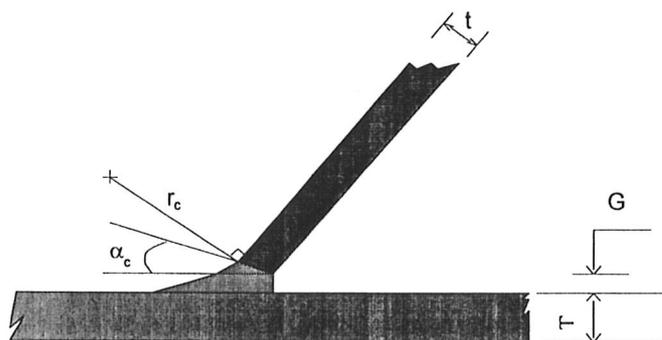
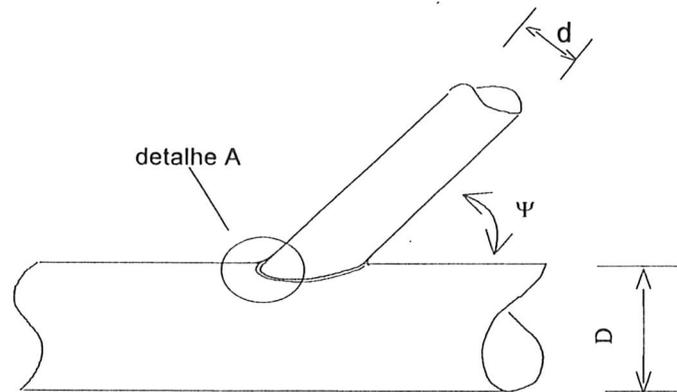
$10 \leq D/2T \leq 20$ , relação entre diâmetro e espessura do membro principal

$0.1 \leq G/t \leq 0.8$ , relação entre folga na raiz do cordão de solda e

00005

espessura do membro secundário,

$10 \leq \alpha \leq 45$ , ângulo de chanfro na base do membro secundário.



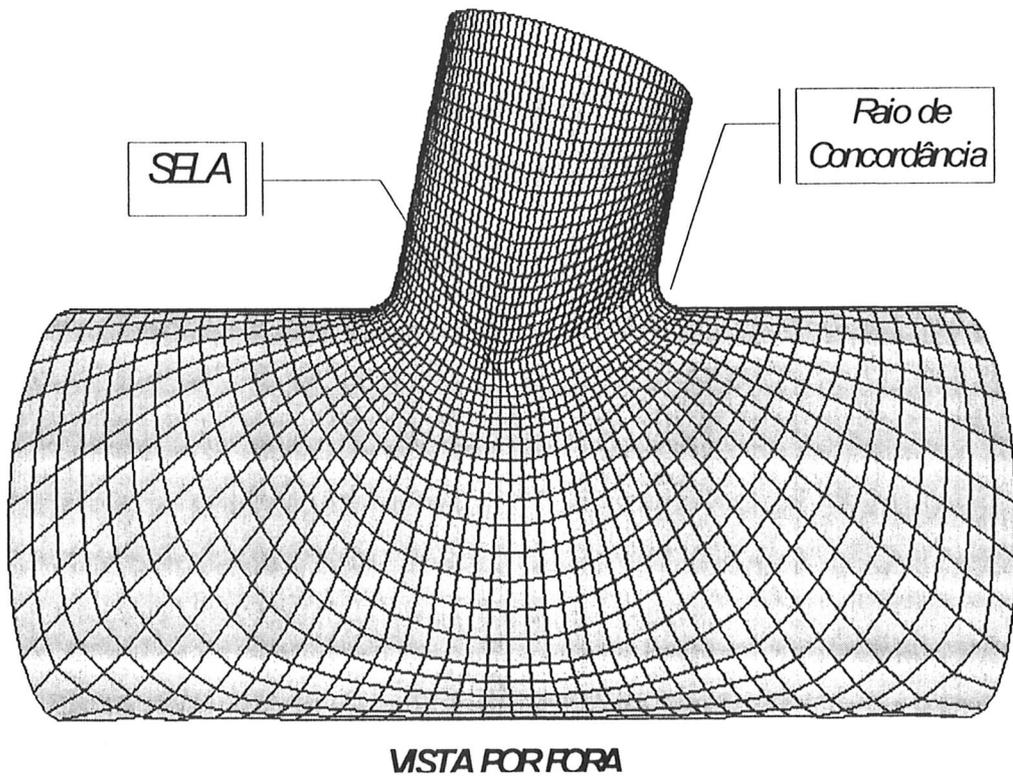
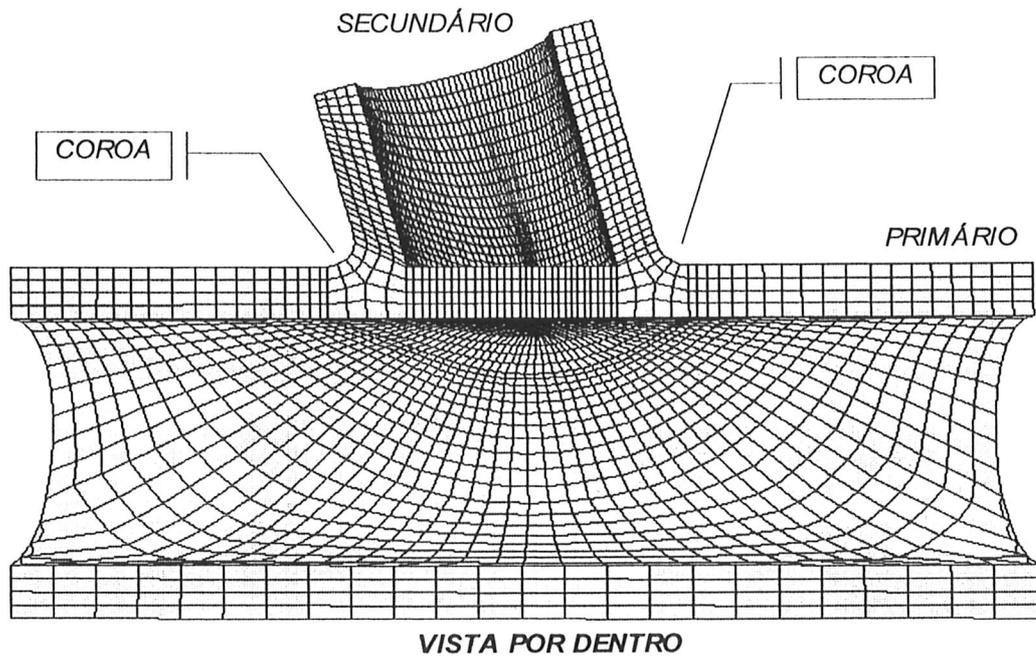
detalhe A

sendo:

- D diâmetro do tubo principal.
- d diâmetro do tubo secundário.
- $\Psi$  ângulo de "heel".
- $r_c$  raio de concordância.
- $\alpha_c$  ângulo de chanfro.
- G "GAP" entre os dois tubos.
- T espessura do tubo principal.
- t espessura do tubo secundário.

Figura 3.1 - Geometria da Junta tipo Y

200007



200008

Como solicitações sobre o membro secundário, foram tomados os casos típicos de força normal e de momento fletor no plano de simetria da junta. Nessa situação, as cargas nodais aplicadas na extremidade livre do secundário têm magnitude estabelecida de sorte a aí produzir máxima tensão de membrana com valor unitário, tal que a tensão de *Hot Spot* resulta igual ao Fator de Concentração de Tensões para ambos os casos de carga.

Todo o processo de cálculo e identificação das tensões máximas, por todos os 256 casos geométricos de juntas analisadas, foi automatizado em computador. Assim, após um total de aproximadamente 1000 horas de processamento (em microcomputador PENTIUM 133Mhz com o *software* ALGOR [12]) foram produzidos todos os dados necessários ao treinamento da RNA.

A título de ilustração, apresentamos na Figura 3.2 a malha de MEF de um dos casos analisados, onde se pode observar a presença do raio de concordância do cordão de solda que, em última instância, funciona como elemento de atenuação do fluxo de tensões entre primário e secundário.

#### 4. RESULTADOS

Conforme descrito nos itens 2.1 e 2.4, não existe um método consagrado para definir-se o número de nós da camada oculta. Portanto, foi necessário partir de uma configuração inicial arbitrada, com 10 nós na camada oculta. Após 40000 ciclos de treinamento, isto é, cada par de treinamento ter sido apresentado à rede 40000 vezes, o desvio médio entre os valores fornecidos pela rede e aqueles obtidos pelo modelo de elementos finitos era maior que 30%. Desta forma, outras configurações foram selecionadas, acrescentando-se um novo neurônio na camada oculta a cada nova configuração. Obteve-se, assim, uma configuração com 15 neurônios na camada oculta, com desvio médio de 2% e desvio máximo de 21%, após, aproximadamente, 20000 iterações. O tempo total para treinamento de todas as redes utilizadas foi de 240 horas, contabilizando-se as diversas paradas para alterações nas configurações.

No atual estágio da pesquisa, o principal resultado obtido está representado na figura 4.1. Trata-se da variação do FCT com o ângulo de chanfro do tubo secundário. Saliente-se que calculados nos moldes tradicionais,

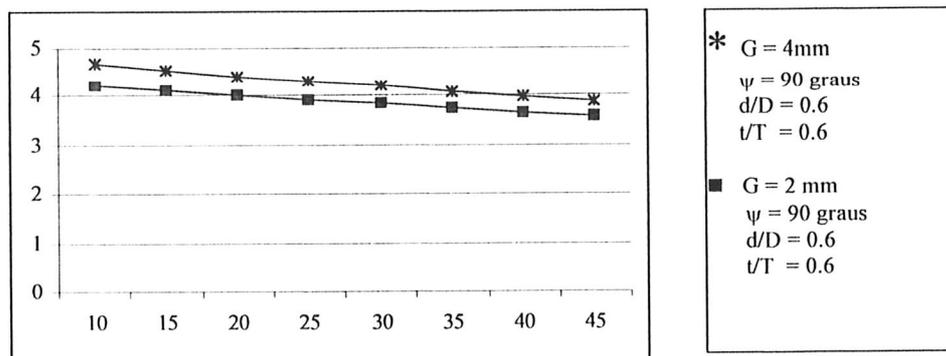


Figura 4.1 – FCT x Ângulo de Chanfro

00000

valores de FCT seriam constantes, pois tais abordagens não consideram essa variável em suas formulações.

## 5. CONCLUSÕES

Dos resultados obtidos fica claramente evidenciada a influência da geometria do cordão de solda no campo de tensões da junta, no sentido de atenuar a concentração de tensões, desde que *gap* e ângulo de chanfro sejam adequadamente escolhidos. Fato este não detectável nos métodos tradicionais onde, basicamente, faz-se uso de modelos elaborados apenas com elementos de casca.

A acuidade da solução obtida através da RNA ficou definida basicamente em função dos conjuntos de treinamento e, principalmente, do conjunto de teste, conforme descrito no item 2. Várias configurações de rede foram utilizadas até se chegar a uma solução satisfatória no que se refere aos desvios entre resultados calculados pelo MEF e fornecidos pela RNA.

Este trabalho é a primeira parte de um estudo que está em desenvolvimento, no sentido de fornecer uma nova proposta para o cálculo de FCT em juntas tubulares. Assim sendo, algumas questões ainda necessitam ser maturadas, como por exemplo o modo de utilização da RNA. No cálculo tradicional do FCT, por regressões, obtém-se uma ou duas expressões analíticas, juntamente com os limites de validade para as variáveis envolvidas no processo. Com as RNA, no entanto, a expressão que regula o fenômeno está implícita em um conjunto de números, na forma de pesos entre os neurônios que compõem a rede, fato este que dificulta a utilização da rede como ferramenta expedita de projeto.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

1. Kuang, J.G., Potvin, A.B., Leick, R.D., "Stress Concentration in Tubular Joints", Proc. of 7<sup>a</sup> Offshore Technology Conference 7, Houston, 1975.
2. Gibstein, M.B., "Stress Concentration in Tubular Joints with Diameter Ratio equal to one", Proc. of the 3<sup>rd</sup> International ECSC Offshore Conference on Steel in Marine Structures, Amsterdam, 1987.
3. Simpson, R.J. et ali, "UEG Design of Tubular Joints for Offshore Structures", Page Bros Limited, Great Britain, 1985.
4. Smedley P., Fisher, P., "A Review of Stress Concentration Factors for Tubular Complex Joints", Lloyd's Register of Shipping, London, 1990.
5. Lippmann, R., *An Introduction to Computing with Neural Nets*, IEEE ASSP Magazine, p. 4-22, abril, 1987.
6. Haykin, Simon, "Neural Networks – A Comprehensive Foundation", Prentice Hall, New Jersey, 1994.
7. Freeman, J.A., Skapura, D.M., "Neural Networks- Algorithms, Applications and Programming Techniques", Addison-Wesley, New York, 1992.
8. Wasserman, P.D., "Neural Computing – Theory and Practice", Van Nostrand Reinhold, New York, 1989.
9. Westead, S.T., "Neural Network and Fuzzic Logic Applications in C/C++", John Wiley & Sons, New York, 1994.
10. Rich, E., Knight, K., "Artificial Intelligence", McGraw Hill, Singapore, 1991.
11. Massaroti, V.M., Nunes Dias, C.A., *FEM Parametric Solid Modelling for Welded Tubular Joint Analysis*, IASTED International Conference Applied Modelling and Simulation, Banff, Canada, 1997, pag.109-114.
12. ALGOR, *Finite Element Analysis System*, Algor Interactive System Inc,

200010