

# 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá  
Itajuba, 24 a 27 de outubro de 1994

## Modelagem do Sistema de Inferência Difusa de Tsukamoto na Arquitetura Anfis<sup>1</sup>

André Gomes de Melo Medeiros  
(agmm@di.ufpe.br)

Edson Costa de Barros Carvalho Filho  
(ecdbcf@di.ufpe.br)

Departamento de Informática  
Cx 7851, 50.732-970, Recife, PE, Brasil  
Tel.: (081) 271-8430, Fax: (081) 271-4925

### Sumário

Este artigo tem por objetivo modelar o sistema de inferência difusa definido por Tsukamoto através da arquitetura Anfis, de forma a incorporar a capacidade de aprendizado e de refinamento das regras difusas. Esta modelagem propicia, portanto, que regras difusas sejam obtidas a partir do conhecimento disponível de um especialista, bem como através de um conjunto de pares entrada-saída de treinamento conforme aplicado no processo de aprendizado das redes neurais. Por fim, uma simulação é realizada para demonstrar o grau de aproximação de uma função não-linear obtido pela rede Anfis que implementa a inferência difusa de Tsukamoto.

### 1 Introdução

Técnicas de controle difuso são aplicadas a sistemas onde a elaboração de um modelo matemático através de métodos clássicos da Teoria de Controle apresenta grande complexidade e sérias limitações. Grande parte das limitações decorre da necessidade de resolução de um conjunto de equações complexas, como por exemplo equações diferenciais de segunda ordem, e do fato dos sistemas sob consideração serem comumente mal-definidos, incertos e altamente não-lineares.

O controle difuso[6] consiste na construção de um modelo de acordo com o comportamento de um

<sup>1</sup> Este trabalho contou com o apoio financeiro do CNPq e da FACEPE

especialista que é capaz de controlar o sistema. As ações do especialista são especificadas na forma de regras linguísticas, que serão posteriormente transcritas em termos da teoria da lógica difusa provendo um cálculo para simular o comportamento do especialista.

Um ponto crítico é que a especificação de regras linguísticas adequadas depende do conhecimento e experiência do especialista. Entretanto, a maior dificuldade é a não formalização do processo de transcrição das regras linguísticas em termos da teoria da lógica difusa. Isto implica na escolha arbitrária e subjetiva das funções de pertinência, o que pode influenciar sensivelmente a performance do controlador difuso. Desta forma, métodos de ajuste das funções de pertinência são necessários.

Redes neurais se candidatam a resolver o problema do ajuste das funções de pertinência, o que justifica o crescente interesse na combinação de redes neurais e sistemas difusos[3][4][5]. Do ponto de vista de redes neurais, esta combinação também traz vantagens, como será mostrado através da arquitetura Anfis[4], pois possibilita a aplicação de algum conhecimento disponível a priori sobre a estrutura da rede como forma de simplificar e acelerar o processo de aprendizagem. As redes neurais clássicas, como as derivadas do modelo de McCulloch-Pitts[7][9], não permitem a aplicação de conhecimento disponível a priori e, após treinadas, são normalmente entendidas como uma caixa-preta: não é possível, em geral, extrair qualquer tipo de conhecimento estrutural da rede neural treinada. Redes neurais e sistemas difusos se constituem em técnicas alternativas para aplicações como reconhecimento de padrões, interpolação de funções e controle.

Na seção 2, são discutidos alguns tipos de sistemas de inferência difusa, dando especial ênfase ao sistema de inferência difusa de Tsukamoto. Na seção 3, é derivada uma rede Anfis que é equivalente ao sistema de inferência difusa de Tsukamoto. Na seção 4, uma simulação é realizada para verificar o grau de aproximação de uma função não-linear pela rede Anfis equivalente ao sistema de inferência difusa de Tsukamoto. Na última seção, conclusões são estabelecidas.

## 2 Sistemas de Inferência Difusa

Sistemas de inferência difusa, conhecidos também como controladores difusos quando aplicados em controle, são constituídos por um conjunto de regras IF-THEN difusas, funções de pertinência associadas a termos linguísticos nas regras, e um mecanismo de inferência denominado raciocínio difuso.

Existem vários tipos de sistemas de inferência difusa proposto na literatura[1][2], como os formulados por Tsukamoto[11], Mandani[6], e Takagi e Sugeno[10]. Cada um destes tipos de sistema de inferência difusa compreende diferentes tipos de regras IF-THEN difusas e raciocínio difuso. O sistema de inferência difusa definido por Takagi e Sugeno, por exemplo, apresenta regras difusas da seguinte forma:

IF *deslocamento* é **pequeno** THEN *força* é 0.3

onde *deslocamento* é uma variável de entrada e *força*, uma variável de saída. O qualificador **pequeno** é um termo linguístico que denota um conjunto difuso. Neste tipo de inferência difusa, termos linguísticos (conjuntos difusos) só podem ocorrer na premissa (parte IF) da regra.

O sistema de inferência difusa proposto por Tsukamoto e o especificado por Mandani apresentam regras difusas da seguinte forma:

IF *deslocamento* é **pequeno** THEN *força* é **fraca**

onde *deslocamento* e *força* são variáveis de entrada e de saída, respectivamente. Os qualificadores **pequeno** e **fraca** são termos linguísticos que representam conjuntos difusos. Portanto, para os sistemas de inferência difusa de Tsukamoto e Mandani, termos linguísticos (conjuntos difusos) ocorrem tanto na premissa (parte IF) como no consequente (parte THEN) da regra. Para os sistemas de inferência difusa de Tsukamoto e Mandani, o consequente da regra atribui um conjunto difuso (**fraca**) à variável de saída (*força*), ao contrário do sistema de inferência difusa de Takagi e Sugeno que atribui um valor numérico (0.3). Desta forma, para a obtenção do resultado final, os sistemas de inferência de Tsukamoto e Mandani exigem a realização de um processo de *defuzzificação* que visa converter o valor difuso (conjunto difuso) atribuído à variável de saída da regra para um valor numérico simples.

O mecanismo de raciocínio difuso de Mandani realiza o processo de *defuzzificação* através do cálculo do centro de gravidade (centróide) da função de pertinência do conjunto difuso atribuído à variável de saída. No entanto, este método apresenta certa vulnerabilidade porque depende da rea-

lização do cálculo de integrais, que é notoriamente não trivial.

Afim de evitar tais dificuldades, o raciocínio difuso de Tsukamoto exige que as funções de pertinência dos termos linguísticos dos consequentes sejam monotônicas, de forma que um método de *defuzzificação* não-convencional baseado nas funções inversas destas funções de pertinência possa ser aplicado na avaliação das regras.


Para ilustrar o procedimento de raciocínio difuso de Tsukamoto, é assumido uma base de regras contendo exatamente duas regras IF-THEN difusas com duas variáveis de entrada *x* e *y* e uma variável de saída *z*. Considerando as regras do sistema de inferência difusa:

Regra 1: IF *x* é  $A_1$  and *y* é  $B_1$  THEN *z* é  $C_1$   
 Regra 2: IF *x* é  $A_2$  and *y* é  $B_2$  THEN *z* é  $C_2$

onde  $A_1, A_2, B_1, B_2, C_1$  e  $C_2$  são termos linguísticos (**pequeno, médio, fraca, etc**). Por simplicidade, as funções de pertinência dos termos linguísticos  $C_1$  e  $C_2$  dos consequentes das regras são restritas a funções lineares, que são monotônicas. Uma função de pertinência linear,  $\mu$ , é definida por

$$\mu(x) = \begin{cases} \frac{-x+a}{a-b}, & \text{se } (x \in [a, b] \wedge a < b) \\ \vee (x \in [b, a] \wedge a > b) \\ 0, & \text{se } (x \notin [a, b] \wedge a < b) \\ \vee (x \notin [b, a] \wedge a > b) \end{cases} \quad (1)$$

com  $\mu(a) = 0$  e  $\mu(b) = 1$ .



$$Z = \frac{w_1 z_1 + w_2 z_2}{w_1 + w_2} = \bar{w}_1 z_1 + \bar{w}_2 z_2$$

Figura 1: Sistema de inferência difusa de Tsukamoto com 2 regras

O mecanismo de raciocínio difuso de Tsukamoto é mostrado na Figura 1. Inicialmente, os graus de compatibilidade (graus de pertinência) do valor de *x* em relação aos termos linguísticos  $A_1, A_2$  e do valor de *y* em relação aos termos linguísticos

$B_1$  e  $B_2$  são calculados. Esta etapa do processo de raciocínio difuso é conhecida como *fuzzyficação*.

A seguir, o grau de verdade da premissa da  $i$ -ésima regra é obtido através da operação AND da lógica difusa, usualmente efetuada multiplicando-se ou tomando-se o mínimo dos graus de pertinência dos valores contidos nas variáveis de entrada em relação aos conjuntos difusos definidos pelos termos linguísticos na premissa da regra:

$$w_i = \mu_{A_i}(x_1)\mu_{B_i}(x_2), \text{ ou} \quad (2)$$

$$= \min(\mu_{A_i}(x_1), \mu_{B_i}(x_2))$$

O valor  $z_i$ , resultante da avaliação da  $i$ -ésima regra, é obtido através da *defuzzyficação* baseada na função inversa da função de pertinência do termo linguístico do consequente da regra, sendo calculado pela equação:

$$z_i = \mu_{C_i}^{-1}(w_i) \quad (3)$$

A equação específica que o resultado da avaliação de cada regra,  $z_i$ , deve ser um valor que possui grau de pertinência em relação ao termo linguístico  $C_i$  do consequente da regra igual a  $w_i$ , que é o grau de verdade da premissa da regra. Sendo  $\mu_{C_i}$ , a função de pertinência do termo linguístico  $C_i$  definida pela equação (1), a sua função inversa é dada por:

$$\mu_{C_i}^{-1}(x) = -x(a - b) + a = px + q \quad (4)$$

com  $x \in [0,1]$ ,  $p = b - a$  e  $q = a$ .

A saída geral do sistema de inferência difusa de Tsukamoto com  $n$  regras é calculada através da média ponderada da saída de cada regra, onde os pesos são os graus de verdade da premissa de cada regra:

$$z = \frac{\sum_{i=1}^n w_i z_i}{\sum_{i=1}^n w_i} = \frac{\sum_{i=1}^n w_i \mu_{C_i}^{-1}(w_i)}{\sum_{i=1}^n w_i} \quad (5)$$

### 3 Arquitetura Anfis

A arquitetura **Anfis**[4], um acrônimo para *Adaptive Network-based Fuzzy Inference System*, engloba uma classe de redes adaptativas que são funcionalmente equivalentes a tipos de sistemas de inferência difusa. Uma rede adaptativa é um tipo especial de rede *feedforward* multi-nível em que cada nó computa uma função específica. As conexões que interligam os nós numa rede adaptativa somente indicam a direção do fluxo de sinais que se propagam entre os nós, não havendo pesos associados a elas. A rede adaptativa é constituída por dois tipos de nós: os adaptativos, que possuem parâmetros que podem ser alterados pelo algoritmo de aprendizado, e os não-adaptativos que não possuem nenhum parâmetro. A capacidade de aprendizado da rede adaptativa decorre da presença dos parâmetros dos nós adaptativos.

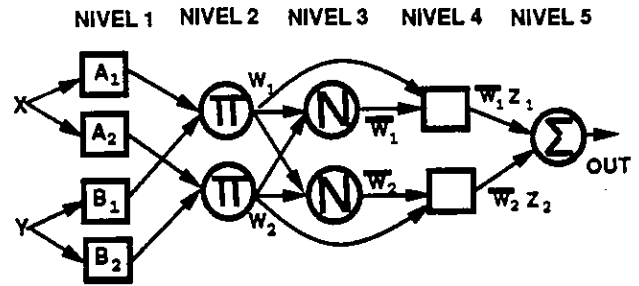


Figura 2: Anfis equivalente ao Sistema de Inferência Difusa de Tsukamoto da Figura 1

A seguir, é derivada a estrutura dos cinco níveis de uma rede **Anfis**(Figura 1), que é equivalente a um sistema de inferência difusa de Tsukamoto. Denotando-se por  $O_i^k$  o  $i$ -ésimo nó do nível  $k$ , tem-se:

- **Nível 1:** Todo nó  $i$  neste nível é um nó adaptativo computando a função

$$O_i^1 = \mu_{A_i}(x), \quad (6)$$

onde  $x$  é a entrada para o nó  $i$ , e  $A_i$  é um termo linguístico (como **pequeno**, **grande**, **alto**, etc) que denota um conjunto difuso, sendo  $\mu_{A_i}$ , a função de pertinência associada. Portanto,  $O_i^1$  é a função de pertinência de  $A_i$  e especifica o grau que  $x$  satisfaz o conceito expresso por  $A_i$ . Usualmente a função  $\mu_{A_i}$  é escolhida tendo a forma semelhante a uma distribuição gaussiana com máximo igual a 1 e mínimo igual 0, como

$$\mu_{A_i} = \frac{1}{1 + \left[ \frac{(x - \gamma_i)}{\alpha_i} \right]^2}^{\beta_i} \quad (7)$$

ou

$$\mu_{A_i} = \exp \left\{ - \left[ \frac{(x - \gamma_i)}{\alpha_i} \right]^2 \right\}^{\beta_i} \quad (8)$$

onde  $\{\alpha_i, \beta_i, \gamma_i\}$  é o conjunto de parâmetros do nó  $i$ . Alterando-se os valores destes parâmetros, provocam-se variações nas funções de pertinência do termo linguístico  $A_i$ . Funções diferenciáveis em intervalos e contínuas, tais como as que apresentam forma trapezoidal e triangular, são também qualificadas como candidatas para funções dos nós neste nível. Esses nós são responsáveis pelo processo de *fuzzyficação*. Parâmetros neste nível são referidos como **parâmetros das premissas**, em analogia ao fato de que em um sistema de inferência difusa o resultado da *fuzzyficação* é usado para a avaliação do grau de verdade das premissas das regras.

- **Nível 2:** Todo nó neste nível é um nó não-adaptativo, que computa o produto dos sinais recebidos de alguns dos nós do nível anterior:

$$O_i^2 = w_i = x_1 \times x_2 \times \dots \times x_j \quad (9)$$

onde  $x_k$  denota o  $k$ -ésimo elemento do vetor de entrada do nó, que recebe os sinais do nível anterior. A saída de cada nó neste nível corresponde ao grau de verdade da premissa de uma regra no sistema de inferência difusa. A função dos nós deste nível é realizar a operação AND da lógica difusa, que neste caso é implementada através do produto.

- **Nível 3:** Todo nó neste nível é um nó não-adaptativo. O  $i$ -ésimo nó calcula a proporção do grau de verdade da  $i$ -ésima regra (saída do  $i$ -ésimo nó do nível anterior) e a soma dos graus de verdade de todas as  $n$  regras:

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_n w_i} \quad (10)$$

Portanto, nós deste nível calculam o grau de verdade normalizado de cada regra. Assim, o número de nós neste nível é igual ao número de nós do nível anterior, que corresponde ao número  $n$  de regras.

- **Nível 4:** Todo nó  $i$  neste nível é um nó adaptativo computando a seguinte função:

$$O_i^4 = \bar{w}_i(\rho_i w_i + \sigma_i) \quad (11)$$

onde  $\bar{w}_i$  e  $w_i$  correspondem as saídas dos  $i$ -ésimos nós das níveis 2 e 3, respectivamente. O conjunto  $\{\rho_i, \sigma_i\}$  representa os parâmetros do nó  $i$ . Parâmetros neste nível são referidos como **parâmetros dos consequentes**. Este nível efetua o processo de *defuzzificação*. A parcela  $\rho_i w_i + \sigma_i$  corresponde ao valor da função inversa da função de pertinência do termo linguístico do consequente da regra em  $w_i$ , conforme especificado na *defuzzificação* de Tsukamoto (equações (3) e (4)).

- **Nível 5:** Todo nó neste nível é um nó não-adaptativo, que computa a saída da rede adaptativa através da soma dos sinais que chegam até ele, ou seja,

$$Output = O_i^5 = x_1 + x_2 + \dots + x_m \quad (12)$$

onde  $x_k$  denota o  $k$ -ésimo elemento do vetor de entrada do nó, que recebe os sinais do nível imediatamente anterior. O número de nós neste nível determina o tamanho do vetor de saída da rede.

Um algoritmo de aprendizado híbrido[4], que consiste na combinação do método do decaimento do gradiente e da estimativa dos mínimos quadrados, é aplicado na determinação e ajuste dos parâmetros dos nós adaptativos da rede. A partir da arquitetura Anfis equivalente a inferência de Tsukamoto, pode-se constatar que dado os valores dos parâmetros do nível 1 e os vetores de entrada, a saída da rede pode ser expressa como combinação linear dos parâmetros do nível 4. Precisamente a saída *output* da rede adaptativa na Figura 2 pode ser reescrita como:

$$\begin{aligned} output &= \frac{w_1}{w_1+w_2} \mu_{C_1}^{-1}(w_1) + \frac{w_2}{w_1+w_2} \mu_{C_2}^{-1}(w_2) \\ &= \bar{w}_1 \mu_{C_1}^{-1}(w_1) + \bar{w}_2 \mu_{C_2}^{-1}(w_2) \\ &= (\bar{w}_1 w_1) \rho_1 + (\bar{w}_2 w_2) \rho_2 + (\bar{w}_1) \sigma_1 + (\bar{w}_2) \sigma_2 \end{aligned} \quad (13)$$

Isto é possível devido a restrição de que as funções de pertinência dos conjuntos difusos associados à conclusão das regras devam ser lineares (equação (1)) o que implica que a sua função inversa, usada pelo processo de *defuzzificação*, será também linear (equação (4)).

Em virtude da saída da rede Anfis ser uma combinação linear dos parâmetros do nível 4 (equação (13)), a estimativa dos mínimos quadrados pode ser utilizada para determinar o valor desses parâmetros durante o passo *forward* em que  $P$  vetores de treinamento são apresentados à rede e os sinais propagam-se na direção da saída da rede, de forma a obter-se o seguinte sistema de equações:

$$AX = B \quad (14)$$

onde  $X$  é um vetor desconhecido cujos elementos são os parâmetros dos nós do nível 4. Sendo o número total de parâmetros do nível 4 igual a  $M$ , então as dimensões de  $A$ ,  $X$  e  $B$  são  $P \times M$ ,  $M \times 1$  e  $P \times 1$ , respectivamente. Desde que  $P$ , o número de pares entrada-saída do conjunto de treinamento, é normalmente maior que  $M$ , isto é um sistema com mais equações do que variáveis e geralmente não existe nenhuma solução exata para a equação (14). Ao invés disto, a estimativa dos mínimos quadrados de  $X$ , que minimiza o erro quadrático  $\|AX - B\|^2$ , é calculada através do algoritmo do filtro de Kalman[8]:

$$\left. \begin{aligned} X_{i+1} &= X_i + S_{i+1} a_{i+1}^T (b_{i+1} - a_{i+1} X_i) \\ S_{i+1} &= S_i - \frac{S_i a_{i+1}^T a_{i+1} S_i}{1 + a_{i+1} S_i a_{i+1}^T}, i = 0, 1, \dots, P-1 \end{aligned} \right\} \quad (15)$$

onde  $a_i$  é a  $i$ -ésima linha da matriz  $A$  definida na equação (14),  $b_i$  é o  $i$ -ésimo elemento de  $B$ ,  $S_i$  é frequentemente denominado **matriz de covariância**, e a estimativa dos mínimos quadrados de  $X$  é igual a  $X_P$ . As condições iniciais para equação (15)

são  $X_0$  igual a matriz nula de dimensão  $M \times 1$  e  $S_0 = \gamma I$ , onde  $\gamma$  é um número positivo grande e  $I$  é a matriz identidade de dimensão  $M \times M$ . Quando a rede Anfis apresenta múltiplas saídas, a equação (15) continua aplicável exceto que  $b_i$  é a  $i$ -ésima linha da matriz  $B$ .

O método do decaimento do gradiente é usado para ajustar os parâmetros do nível 1, não alterados pela estimativa dos mínimos quadrados, sendo aplicado no passo *backward* em que as taxas de erros, propagam-se do extremo de saída da rede para o extremo de entrada da rede. Considerando  $P$  vetores de treinamento, pode-se definir a **medida do erro** para o  $p$ -ésimo vetor, com  $1 \leq p \leq P$ , do conjunto de treinamento como sendo a soma dos quadrados dos erros:

$$E_p = \sum_{m=1}^{\#(5)} (T_{m,p} - O_{m,p}^5)^2 \quad (16)$$

onde  $\#(5)$  representa o número de nós do nível 5;  $T_{m,p}$  é o  $m$ -ésimo componente do  $p$ -ésimo vetor de saída desejado; e  $O_{m,p}^5$  é o  $m$ -ésimo componente do vetor saída que foi realmente obtido a partir da apresentação do  $p$ -ésimo vetor de entrada à rede Anfis equivalente a inferência de Tsukamoto. Logo, a medida do erro total é  $E = \sum_{p=1}^P E_p$ .

Para desenvolver um procedimento de aprendizagem que implementa o decaimento do gradiente de  $E$  sobre o espaço dos parâmetros, primeiro é necessário calcular a **taxa de erro**  $\frac{\partial E_p}{\partial O}$  para cada nó. A taxa de erro para a saída do nó  $i$  do nível 5 pode ser calculado prontamente da equação (16):

$$\frac{\partial E_p}{\partial O_{i,p}^5} = -2(T_{i,p} - O_{i,p}^5) \quad (17)$$

Analogamente, pode ser derivada a taxa de erro para o  $i$ -ésimo nó de um nível interno  $k$  como combinação linear das taxas de erros dos nós dos níveis subsequentes. Considerando  $\alpha$  como um parâmetro da rede adaptativa em questão, tem-se:

$$\frac{\partial E_p}{\partial \alpha} = \sum_{O^* \in S} \frac{\partial E_p}{\partial O^*} \frac{\partial O^*}{\partial \alpha} \quad (18)$$

onde  $S$  é o conjunto de nós cuja saída depende de  $\alpha$ . Logo a derivada do erro total  $E$  com relação a  $\alpha$  é

$$\frac{\partial E}{\partial \alpha} = \sum_{p=1}^P \frac{\partial E_p}{\partial \alpha} \quad (19)$$

Logo, as fórmulas para atualização dos parâmetros  $\alpha_i$ ,  $\beta_i$  e  $\gamma_i$  do  $i$ -ésimo nó do nível 1 são definidas por:

$$\left. \begin{aligned} \Delta \alpha_i &= -\eta \frac{\partial E}{\partial \alpha_i} \\ \Delta \beta_i &= -\eta \frac{\partial E}{\partial \beta_i} \\ \Delta \gamma_i &= -\eta \frac{\partial E}{\partial \gamma_i} \end{aligned} \right\} \quad (20)$$

onde  $\eta$  representa a taxa de aprendizado.

A derivação da rede Anfis equivalente ao sistema de inferência difusa de Takagi e Sugeno[10] pode ser encontrada em [4].

## 4 Aplicação como Aproximador de Função

Uma das características primordiais de um sistema de inferência difusa é ser um aproximador funcional, de forma que possa simular adequadamente o comportamento do sistema a ser modelado. Objetivando verificar tal característica, a rede Anfis equivalente a inferência difusa de Tsukamoto foi utilizada para modelar a seguinte função não-linear:

$$y = \frac{\sin(x)}{x} \quad (21)$$

Foram amostrados 33 pares de dados de treinamento e 32 pares de teste a partir da equação acima uniformemente espaçados no intervalo  $[-16, 16]$  e  $[-15.5, 15.5]$ , respectivamente. A estrutura da rede Anfis usada apresentava cinco nós nas níveis 1, 2, 3 e 4; e mais um nó no nível 5. Esta rede equivale a um sistema de inferência difusa de Tsukamoto com 5 regras, uma variável de entrada e uma de saída. Cada nó do nível 1 possui três parâmetros  $(\alpha, \beta, \gamma)$ , e cada nó do nível 4 apresenta dois parâmetros  $(\rho, \sigma)$ . Portanto o número total de parâmetros da rede é igual a 25. Esses parâmetros são ajustados pelo algoritmo de aprendizado híbrido. Considerando a ausência de especialista ou conhecimento disponível a priori, os parâmetros das premissas são inicialmente estabelecidos, de forma que as suas funções de pertinência associadas sejam igualmente espaçadas ao longo do intervalo de operação de cada variável de entrada. Valores iniciais para os parâmetros dos consequentes não são necessários, uma vez que os valores destes parâmetros serão apropriadamente determinados pela estimativa dos mínimos quadrados. Na fase de treinamento após 100 ciclos aplicando o algoritmo de aprendizado híbrido, o erro quadrado médio estabilizou em 0.008. Na Figura 3, são exibidas as curvas obtidas pelos valores de teste através da equação (21), da saída da rede Anfis, e do erro absoluto entre esses valores. Pode-se constatar que, de fato, a rede Anfis equivalente ao sistema de inferência difusa de Tsukamoto apresenta uma ótima aproximação da função não-linear definida pela equação (21).




Figura 3: Resultados obtidos pela rede Anfis equivalente a inferência difusa de Tsukamoto

## 5 Conclusão

A modelagem do sistema de inferência difusa de Tsukamoto através de uma rede Anfis equivalente visa enriquecer este importante e bastante usado tipo de sistema de inferência difusa com capacidade de aprendizado e refinamento de regras difusas, de forma que objetivos prescritos possam ser atingidos da melhor maneira possível.

Durante o processo de aprendizado, as funções de pertinência podem sofrer alterações que não preservam características linguisticamente desejáveis, tais como suficiente sobreposição das funções de pertinência e cobertura total do intervalo do domínio, criando dificuldades para a interpretação linguística das regras obtidas. Neste caso, a solução consiste em elevar o número dos parâmetros das premissas e dos consequentes através de uma maior quantidade de nós na estrutura da rede (ou seja, um maior número de regras e funções de pertinência), para prover a rede com maior grau de liberdade. Isto faz com que os parâmetros não precisem sofrer mudanças consideráveis, de modo que as funções de pertinência obtidas preservem as características que facilitam sua interpretação linguística.

Em suma, a rede Anfis equivalente ao Sistema de inferência difusa de Tsukamoto pode automaticamente derivar as regras IF-THEN difusas se um especialista não é disponível, ou refinar as regras IF-THEN difusas obtidas de um especialista. No último caso, um processo de aprendizado mais

rápido é esperado, pois o conjunto de regras e das funções de pertinência estabelecidas pelo especialista se encontra mais próximo da configuração ideal.

## Referências

- [1] C. Lee. *Fuzzy Logic in Control Systems: Fuzzy Logic Controller - Part 1*. IEEE Trans. on Systems, Man, and Cybernetics. Vol. 20, No. 5, 1990
- [2] C. Lee. *Fuzzy Logic in Control Systems: Fuzzy Logic Controller - Part 2*. IEEE Trans. on Systems, Man, and Cybernetics. Vol. 20, No. 5, 1990.
- [3] C. Lin, C. G. Lee. *Neural-Network-based Fuzzy Logic Control and Decision System*. IEEE Trans. on Computers, Vol. 40, No. 12, 1991.
- [4] J. R. Jang. *ANFIS: Adaptive-Network-Based Fuzzy Inference System*. IEEE Trans. on Systems, Man, and Cybernetics. May, 1993.
- [5] B. Kosko. *Neural Networks and Fuzzy Systems*. Prentice-Hall, USA, 1992.
- [6] E. H. Mandani. *Applications of Fuzzy Algorithms for Control of Simple Dynamical Plants*. IEE Proc. Vol. 121, No. 12, 1974.
- [7] W. S. McCulloch, W. H. Pitts. *A logical calculus of the ideas immanent in nervous activity*. Bull Math Biophys. Volume 5, 1943, p115-133.
- [8] C. Goodwin, K. Sin. *Adaptive Filtering Prediction and Control*. Prentice-Hall, N. J., 1984.
- [9] D. E. Rumelhart, G. E. Hinton, R. J. Williams. *Learning Internal Representations by Error Propagation*. Parallel Distributed Processing, MIT Press, 1986, p318-362
- [10] T. Takagi, M. Sugeno. *Derivation of Fuzzy Control Rules from Human Operator's Control Actions*. Proc. of the IFAC Symp. on Fuzzy Information, Knowledge Representation and Decision Analysis, p55-60, 1993.
- [11] Y. Tsukamoto. *An Approach to Fuzzy Reasoning Method*. Advances in Fuzzy Set Theory and Applications, North-Holland, Amsterdam, 1979.