

# ANÁLISE COMPARATIVA DO DESEMPENHO DE UM CONTROLADOR FUZZY ACOPLADO A UM PID NEURAL SINTONIZADO POR UM ALGORITMO GENÉTICO COM UM PID CONVENCIONAL.

MARCELO R. B. G. VALE, ANDRE L. MAITELLI

*Departamento de Engenharia de Computação e Automação, Universidade Federal do RN  
Campus Universitário, s/n – cep 58.072-190 – Natal /RN  
E-mails:marceloguerra@dca.ufrn.br, matitelli@dca.ufrn.br*

**Abstract**— With the technological advance, the presence of intelligent computational techniques in devices of the daily industrial, advertising and domestic, to facilitate its use and to automatize its functioning. Based in this tendency and objective of developing the comparison of a conventional PID with a controller fuzzy connected to a neural PID applied in a system of connected tanks (model of 2<sup>o</sup> order Nonlinear) becomes indispensable the theoretical survey of all the involved techniques as well as the implementation of the simulation of the system and its results.

**Keywords**— Fuzzy logic, Artificial Neural Networks, genetic Algorithm, system of level of tanks.

**Resumo**— Com o avanço tecnológico, é cada vez mais evidente a presença de técnicas computacionais inteligentes em aparelhos do cotidiano industrial, comercial e até mesmo doméstico, para facilitar a sua utilização e automatizar seu funcionamento. Baseado nessa tendência e com o intuito de realizar a comparação de um PID convencional com um controlador fuzzy acoplado a um PID neural aplicado em um sistema de tanques acoplados (modelo de 2<sup>o</sup> ordem–não linear) torna-se indispensável o levantamento teórico de todas as técnicas envolvidas assim como a implementação da simulação do sistema e seus resultados.

**Palavras-chave**— Lógica Fuzzy, Redes Neurais, Algoritmo genético, sistema de nível de tanques.

## 1 Introdução

Há algumas décadas, o homem vem procurando controlar de forma inteligente suas tarefas para facilitar seu dia-a-dia, buscando melhorar a sua segurança e garantir um melhor rendimento produtivo em algumas áreas. Para alcançar esse objetivo foram desenvolvidas diversas técnicas e ferramentas, dentre as quais se podem destacar três ferramentas, que deram um grande impulso na área de controle inteligente.

Uma dessas ferramentas foi apresentada como Lógica Fuzzy que procura traduzir valores lingüísticos, imprecisos, comuns na comunicação humana, em valores numéricos precisos, comuns para os computadores, Shaw, Ian et. al (2001).

Outra ferramenta importante é as Redes Neurais Artificiais, na qual sua utilização para a Identificação e o Controle não necessita de conhecimento aprofundado acerca do sistema para se extrair do processo as informações necessárias para identificar e gerar o sinal de controle, Hankin, S.(1994).

A terceira ferramenta são os algoritmos genéticos (AGs) que normalmente são vistos como otimizadores de funções, embora a quantidade de problemas para o qual os AG's se aplicam seja bastante abrangente, Lacerda, E.G. M et. al (1999).

Neste artigo será apresentado um controlador fuzzy acoplado a um PID neural sintonizado por um algoritmo genético. Ainda no artigo serão realizadas simulações desse controlador em uma planta de controle de nível e seus resultados serão comparados com os resultados de um PID convencional, também aplicado na planta de controle de nível. A planta a ser controlada é um processo de tanques acoplados que é

bastante adequado para ser utilizado neste tipo de estudo, pelo fato de ser muito comum encontrá-lo nos ramos industriais, principalmente nos químico, petroquímico e de alimentos.

## 2 Lógica Fuzzy

Para modelar um controlador Fuzzy em um determinado problema, é preciso respeitar basicamente três etapas: Fuzzificação, Inferência e Defuzzificação, Santos, G. J. C. (2003).

### 2.1 Fuzzificação

Essa primeira etapa é responsável pela tradução dos valores de entradas (não-fuzzy), que normalmente são provenientes de sensores ou dispositivos de entrada computadorizados, em valores nebulosos (imprecisos, verbais), S. Dutta. (1993). Os valores de entradas devem estar contidos nos universos de discursos, ou seja, devem se comportar dentro do intervalo estabelecido pelo projetista, além de obedecer as funções de pertinência que normalmente são definidas nos formatos triangulares ou trapezoidais, podendo também ser encontradas no formato gaussiana, sigmoidal etc.

Na etapa de Fuzzificação também devem ser definidas, pelo projetista, as variáveis lingüísticas e a quantidade necessária para atender ao sistema. De uma forma sucinta, para se concluir a Fuzzificação deve-se obedecer os seguintes passos:

- Analisar quais são as variáveis usadas no projeto para tornar possível seu controle automático;

- Após escolher as variáveis a serem controladas, deve-se estabelecer o universo de discurso de cada variável;
- Escolher a forma das funções de pertinências
- E, finalmente, nomear cada variável lingüística e obter as funções (pertinência x universo discurso).

Nesse controlador foi estabelecido que as funções de pertinências tivessem formatos triangulares e as variáveis controladas seriam o erro e a variação do erro que são dadas pela Equação 1.

$$\begin{aligned} e(t) &= r(t) - y(t) \\ de(t) &= e(t) - e(t-1) \end{aligned} \quad (1)$$

Onde  $e(t)$  é o erro no instante  $t$ ,  $r(t)$  é a referência no instante  $t$ ,  $y(t)$  é a saída do sistema no instante  $t$  e  $de(t)$  é a variação do erro no instante  $t$ .

Tendo assim um sistema de controle de duas entradas e uma saída, como mostra a Figura 1.

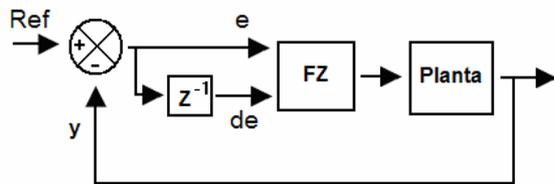


Figura 1. Controle Fuzzy MISO.

## 2.2 Inferência

A etapa de inferência, como mostra a Figura 2, é composta de dois blocos funcionais. O primeiro bloco (Base de conhecimento), nada mais é do que um especialista da planta que vai ser controlada, ou seja, nesta etapa deve-se contar com a contribuição de um especialista no processo a ser controlado, pois a partir dos conhecimentos do especialista é que se vai obter as regras de inferência. É nesta etapa também que vai ser feita toda a lógica de tomada de decisão, que irá analisar todas as situações possíveis do processo, de acordo com todos os possíveis estados em que as variáveis a serem controladas possam se encontrar, C. C. Lee. (1990).

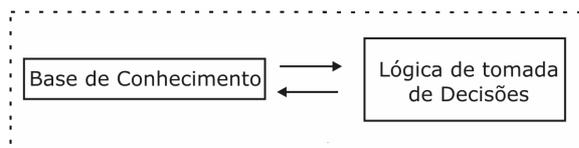


Figura 2. Inferência.

É importante observar que toda a análise é feita em relação às variáveis ditas controladas (entradas) e que essas variáveis são relacionadas com variáveis

lingüísticas, o que caracteriza a lógica Fuzzy. A saída vai ser a ação a ser tomada pelo sistema todas as vezes em que se observar uma combinação relacionada. Essa saída, que ainda não é a saída para a planta e sim uma saída para fins de cálculos na lógica Fuzzy, é dada de acordo com a base de conhecimento do especialista. Depois de todas as análises serem realizadas, já se tem todas as possíveis saídas do sistema de acordo com cada situação. A partir desses resultados torna-se possível a montagem da Matriz de Associação Fuzzy (FAM). Essa matriz nada mais é do que todos os resultados provindos das análises.

Finalmente, depois de já ter em mãos a matriz de associação Fuzzy (FAM), deve-se usar um mecanismo de inferência para poder fazer associações que possam resultar em interpretações para expressões do tipo “SE (condição) ENTÃO (ação)”.

O mecanismo de tomada de decisão escolhido, foi o “min de Mamdani” que baseia-se na Equação 2.

$$\mu_{A \rightarrow B} = \min[\mu_A(x), \mu_B(x)] \quad (2)$$

Esse mecanismo auxiliará para achar a saída de defuzzificação, ou seja, a saída pronta para a próxima etapa que é a etapa de defuzzificação. Para isso, precisa-se relacionar as regras de inferência e as funções de pertinências, para finalmente aplicar as operações de Agregação e Composição. Com a aplicação dos operadores, teremos como resposta de saída uma área que pode ser exemplificada pela Figura 3. A área hachurada de cinza corresponde à saída que deverá ser defuzzificada na etapa seguinte.

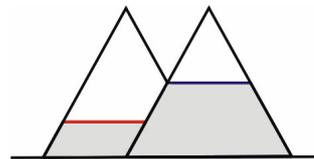


Figura 3. Saída Fuzzy.

## 2.3 Defuzzificação

A última etapa consiste na aplicação dos valores obtidos na etapa de inferência no método abaixo (Equação 3) para se obter um valor dito 'não fuzzy'.

- Centro dos máximos:

$$X_{CM} = \frac{\sum_{i=1}^M X_{m\acute{a}x}(i) \cdot \mu[X_{m\acute{a}x}(i)]}{\sum_{i=1}^M \mu[X_{m\acute{a}x}(i)]} \quad (3)$$

Existe vários outros métodos de defuzzificação além do citado acima, como por exemplo: centro de massa e média dos máximos, J. L. Castro. (1995). Na implementação utilizou-se o centro dos máximos por se tratar de um método de baixo custo computacional.

### 3 PID Neural

Nesse sistema de controle a rede neural irá simular o funcionamento de um PID convencional, onde os pesos da rede corresponderão aos valores dos ganhos de um PID:  $K_p$ ,  $K_i$ ,  $K_d$ . Nesse caso a rede neural é usada no acoplamento do controlador fuzzy por causa de sua potencialidade de aprendizagem. Os ganhos  $K_i$ ,  $K_p$  e  $K_d$  podem ser inicializados aleatoriamente, e em seguida, o valor dos pesos da rede neural irá sintonizar o PID de acordo com a evolução de aprendizagem da rede neural. O sistema de controle fuzzy acoplado ao PID neural pode ser visto na Figura 4.

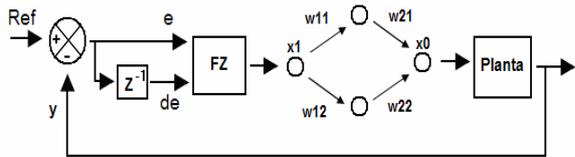


Figura 4. PID Neuro-Fuzzy.

Para esta estrutura a saída da RNA será dada através da Equação 4.

$$u_{PID}(t) = w_{21} \cdot w_{11} \cdot x_1(t) + w_{22} \cdot w_{12} [x_1(t) + x_1(t-1)] \quad (4)$$

Nesse caso, as duas entradas do controlador fuzzy mais o PID neural são formadas pelas duas entradas do controlador fuzzy e os ganhos  $K_p$ ,  $K_i$ . Em outras palavras, o erro e a variação do erro que entram no controlador fuzzy são obtidas pelo erro do controlador fuzzy mais o erro do PID.

### 4 Algoritmo genético

Para o aprendizado da rede neural foi utilizado um algoritmo genético, ao invés do *backpropagation*. O AG irá ajustar os pesos da RNA baseado na média do erro quadrático que pode ser escrita de acordo com a Equação 5.

$$M_{erro}(ind) = \frac{\sum_{t=0}^{t_{final}} [erro(t)]^2}{t_{final}} \quad (5)$$

Onde  $M_{erro}(ind)$  é a média do erro quadrático para um determinado indivíduo,  $erro(t)$  é o erro para um determinado instante da simulação e  $t_{final}$  é o tempo de simulação do indivíduo.

O Algoritmo genético implementado pode ser melhor compreendido observando a Figura 5, sendo que utilizou-se uma nova técnica de reprodução que pode ser descrita em alguns passos:

- 1º passo: Escolhe dois cromossomos da população aleatoriamente;

- 2º passo: Escolhe diferentes localizações de genes nos dois cromossomos separadamente e aleatoriamente;
- 3º passo: Troca os dois genes selecionados entre os dois cromossomos.
- 4º passo: Evolui a geração com os dois novos indivíduos gerados.

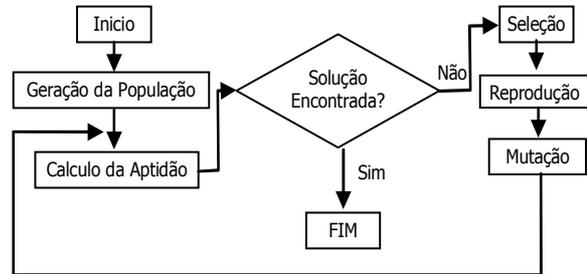


Figura 5. Fluxograma AG.

Este tipo de *crossover* foi implementado por ter apresentado um rendimento melhor do que os *crossover* convencionais, de acordo com Yu Yongqnan et. al (2004).

### 5 Ambiente de simulação

O programa foi desenvolvido na plataforma Borland C++ Builder® e sua interface está mostrada na Figura 6.

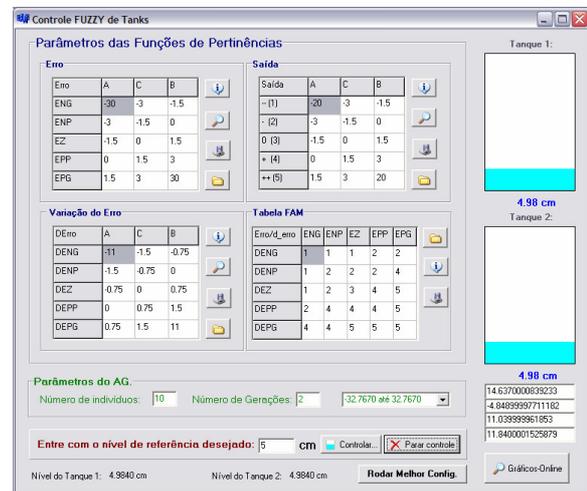


Figura 6. Ambiente de simulação PID Neuro-Fuzzy.

O programa permite o usuário importar funções de pertinência de arquivos *.txt*, visualizar as funções geradas desses arquivos, ou se achar melhor, o usuário pode criar suas funções de pertinência na própria janela e visualizá-las. Além de importar, o usuário também pode gravar uma suposta alteração em alguma função de pertinência, como também visualizar gráficos importantes do sistema de controle, como por exemplo: erro x tempo, variação do erro x tempo

e nível dos tanques x tempo. Além das entradas das funções de pertinências o usuário também deve entrar com:

- Número de indivíduos do AG;
- Número de gerações;
- *SetPoint* desejado;
- “Range” dos cromossomos.

O ambiente de simulação foi programado baseado no sistema de controle mostrado na Figura 7, onde foi incluído um Fuzzy em cascata para evitar o transbordamento do tanque 1. Observe que o segundo Fuzzy (FZ') possui como entrada o resultado do fuzzy anterior (FZ) e o nível do tanque 1, logo, o segundo fuzzy (FZ') serve apenas como uma chave de segurança para evitar o transbordamento do tanque 1.

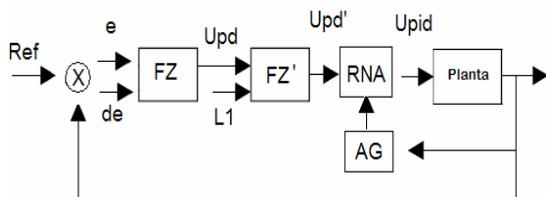


Figura 7. Sistema de controle implementado.

Para fins de comparação um outro ambiente de simulação, similar ao mostrado na Figura 6, foi implementado com o intuito de simular um controlador PID convencional, onde o usuário entra com os valores de  $K_p$ ,  $K_i$  e  $K_d$ .

Nos ambientes de simulação, o sistema de tanques acoplados (mostrado na Figura 8) foi representado pelo modelo discreto da planta (Equação 6), obtido através do método de Euler, M. A. Carla. (2006).

$$h_1(k) = h_1(k-1) + dT \left( \frac{km \cdot vp}{A_2} - \frac{a_1 \cdot \sqrt{2 \cdot g \cdot h_1(k-1)}}{A_1} \right) \quad (6)$$

$$h_2(k) = h_2(k-1) + dT \left( \frac{a_1 \cdot \sqrt{2 \cdot g \cdot h_1(k)}}{A_2} - \frac{a_2 \cdot \sqrt{2 \cdot g \cdot h_2(k-1)}}{A_2} \right)$$

Onde  $h_1$  é o nível do tanque 1,  $h_2$  é o nível do tanque 2,  $dT$  é o período de amostragem,  $km$  é a constante da bomba,  $vp$  é a tensão na bomba,  $a_1$  é o diâmetro do orifício de saída do tanque 1,  $a_2$  é o diâmetro do orifício de saída do tanque 2,  $g$  é aceleração da gravidade,  $A_1$  diâmetro do tanque 1 e  $A_2$  diâmetro do tanque 2.

Todos os parâmetros relacionados no modelo discreto da planta foram obtidos do manual (Quanser, Inovation Educate. Manual Coupled Water Tank Experiments).

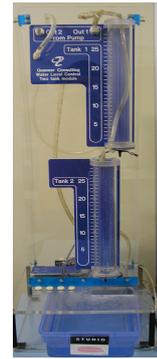


Figura 8. Sistema de Tanques.

## 6 Resultados

Para fins comparativos entre o PID convencional e o fuzzy acoplado a um PID neural, foram realizados alguns testes. Nos testes realizados a sintonia dos parâmetros do PID convencional foi obtida através do método LGR (Lugar geométrico das raízes). A Figura 9 mostra o teste realizado com o controlador fuzzy acoplado a um PID neural. O gráfico mostra o nível do tanque 2 (tanque a ser controlado em cm) em relação ao tempo (segundos), a linha vermelha é o nível do tanque 2, a linha verde delimita a faixa de acomodação de  $\pm 5\%$  e linha azul é o *set point*. Nota-se na Figura 9 que para um *setpoint* de 5cm o PID neuro-fuzzy consegue convergir (entrar na faixa de acomodação) em menos de 10 segundos e apresenta um *overshoot* de 10%, já para os outros valores de *setpoint* o *overshoot* é menor que 5%.

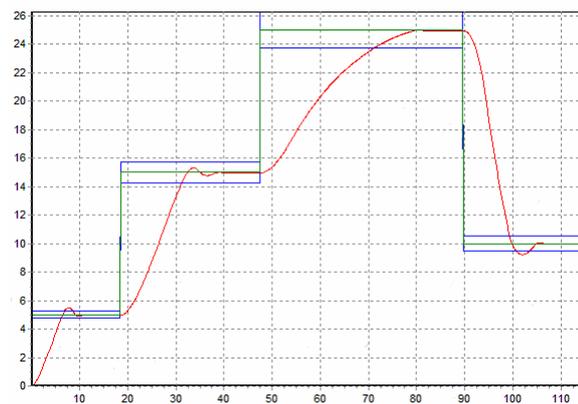


Figura 9. Gráfico do nível do tanque 2 x tempo(s).

A Figura 10 mostra a tensão na bomba (volts) em relação ao tempo (s). A bomba recebe tensão de -22v a +22v, sendo que o controlador por questão de segurança trabalha entre  $\pm 3v$ , haja vista que o sinal é amplificado ao entrar na bomba com um ganho de 5, neste caso a bomba trabalhará entre -15v e +15v.

A linha em vermelho representa a tensão calculada pelo segundo fuzzy (FZ'), a linha em azul é a tensão determinada pelo primeiro fuzzy (FZ) e a linha em roxo é a tensão calculada pelo PID neuro-fuzzy, ou seja, a tensão aplicada de fato na bomba para o controle de nível do tanque 2.

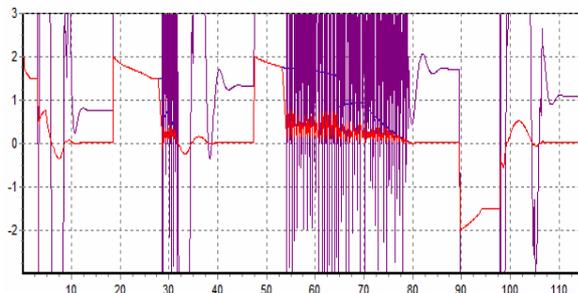


Figura 10. Gráfico da tensão na bomba x tempo(s).

Fica claro na Figura 10 a ação da chave de segurança (FZ'), no intervalo entre 55 e 80 segundos, onde o primeiro fuzzy tende a calcular um determinado valor para a tensão e o segundo fuzzy, para não deixar transbordar o tanque 1, age aplicando uma tensão negativa em vez de positiva. Neste período o controlador fica oscilando entre +15v e -15v, em vez de estar direto em +15v como manda o primeiro fuzzy (FZ), evitando assim o transbordamento.

Na Figura 11 tem-se o resultado do controlador PID convencional com os parâmetros projetado pelo método LGR, onde foi calculado baseado em um fator de amortecimento de 16% e um tempo de acomodação de 25 segundos. A legenda do gráfico é igual ao da Figura 9.

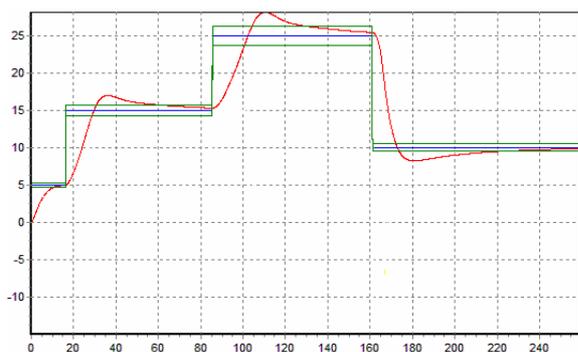


Figura 11. Gráfico PID convencional.

A Figura 11 mostra que para um *setpoint* de 5 cm o tempo de acomodação foi de 17 segundos e para os outros *setpoint* estabelecidos a diferença de desempenho se compara com o PID neuro-fuzzy foi ainda maior, apresentando *overshoots* bastantes superiores. Nota-se também que a duração do teste do PID convencional foi bastante superior, mesmo para uma quantidade similar de *setpoints* estabelecidos.

Na Figura 12 a linha azul representa a tensão aplicada na bomba (variando entre +15v e -15v) em relação ao tempo (segundos).

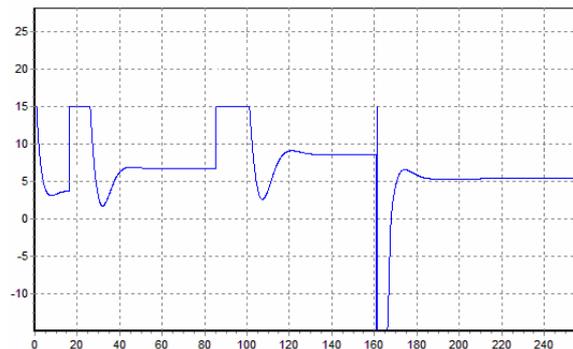


Figura 12. Gráfico da tensão na bomba x tempo PID convencional.

Ao comparar a Figura 12 com a Figura 10 pode-se observar que em ambas as Figuras a tensão aplicada na bomba estaciona para todos *setpoints* estabelecidos, sendo que a tensão da Figura 12 é bem menos oscilatória do que a tensão mostrada na Figura 10. Em compensação o resultado do PID convencional é mais lento do que o do controle proposto neste artigo.

## 7 Conclusão

Os resultados mostrados comprovaram que o controlador proposto no artigo (Controlador Fuzzy com PID Neural sintonizado por um AG) apresenta um desempenho melhor do que um PID convencional, se comparado tempo de acomodação e *overshoots* máximo. Porém, em termos de oscilação da tensão na bomba, o controlador proposto apresentou um número excessivo de oscilações podem diminuir a vida útil da bomba. Esse número excessivo de oscilações pode ser melhorado fazendo um ajuste fino nas funções de pertinência da lógica fuzzy, tornando o sistema mais amortecido. Porém deve-se levar em conta que quando se quer velocidade de convergência em um sistema, corre-se o risco de tornar o sistema oscilatório, ou até mesmo levar o sistema a instabilidade. Os resultados mostraram ainda a eficiência da chave de segurança fuzzy que evita o transbordamento do tanque 1 no decorrer do processo.

A utilização de mais de uma técnica inteligente em sistemas de controle, se bem empregadas, pode facilitar o trabalho do projetista. Neste projeto a utilização do PIDN sintonizado pelo AG substituiu os cansativos ajustes dos parâmetros do KP, KI e KD.

## Agradecimentos

CAPES pelo apoio financeiro.

## Referências Bibliográficas

- C. C. Lee. (1990). Fuzzy logic in control systems: Fuzzy logic controller (part i). IEEE Transactions on Systems, Man and Cybernetics., 20(2):404 – 418.
- J. L. Castro. (1995) Fuzzy logic controllers are universal approximators. IEEE Transactions on Systems, Man and Cybernetics, 25(4):629 – 635.
- S. Dutta. (1993). Fuzzy logic applications: Technological and strategic issues. IEEE Transactions on Engineering Management, 40(3):237 – 254.
- Quanser, Inovation Educate. Manual Coupled Water Tank Experiments.
- Hankin, S.(1994). Neural Networks. Macmillan College Publishing Company. Ontario. Canada.
- M. A. Carla. (2006). Ajustes de controladores PID através de algoritmos genéticos.
- Lacerda, E.G. M, Carvalho, A.C.P.L. (1999) Introdução aos algoritmos genéticos. Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais. Porto Alegre: Ed. Universidade/UFRGS.
- Santos, G. J. C. (2003) Lógica Fuzzy. Universidade Estadual de Santa Cruz, Bahia, 2003.
- Shaw, Ian; Simões, Marcelo. (2001). Controle e modelagem Fuzzy. São Paulo: Edgard Blucher LTDA.
- Yu Yongqnan, Huang Ying, Zeng Bi. (2004). Fuzzy Neural PID controller and tuning its weight factors using genetic algorithm based on Werent location crossover.