

Determinação Automática da Estratégia de Controle através de Sistema Híbrido Neuro-Fuzzy-Genético

J. F. M. Amaral¹, M. M. Vellasco², R. Tanscheit², M. A. C. Pacheco²

¹DETEL-UERJ, R. S. F. Xavier 524 SL.5036A, 20550-013 Rio de Janeiro, RJ

²DEE-PUC-Rio, CP 38063, 22452-970 Rio de Janeiro, RJ

E-mails: franco@uerj.br,[marley, ricardo, marco]@ele.puc-rio.br

Abstract

This work deals with the design of control systems based on hybrid techniques of computational intelligence. Initially a neuro-fuzzy system is employed in the control of several plants. Neuro-fuzzy systems implement a fuzzy inference system through a parallel distributed architecture, so that learning paradigms common to artificial neural networks can be of use in this hybrid architecture. The neuro-fuzzy system used in this work is the NEFCON model, which is capable of learning and optimizing on line the rule-base of a Mamdani-type fuzzy controller. The algorithm is based on reinforcement learning which uses a fuzzy measure for the error. Its performances in the control of linear plants of diverse complexity and also of a nonlinear one have been evaluated. Results are compared to those obtained through conventional techniques. The main focus of this work is on a new Neuro-Fuzzy-Genetic System which makes use of genetic algorithms in the optimization stage of the NEFCON algorithm. The satisfactory results obtained with the two more complex plants show the potential of this hybrid model in the design of control systems.

1. Introdução

De um modo geral, dentre as chamadas técnicas inteligentes de controle, os sistemas de controle baseados em lógica fuzzy imitam os especialistas implementando o que eles *dizem* (informações subjetivas) numa base de regras, que representa a estratégia de controle. Por outro lado, os controladores baseados em redes neurais podem imitar, o que os especialistas *fazem* (informações objetivas) em função dos sinais dos sensores e atuadores do sistema. Os controladores neurais se caracterizam pela capacidade de aprender o comportamento de controladores automáticos ou humanos, através da captura de dados para treinamento das respectivas redes. Os dois tipos de controladores, fuzzy ou neurais, são capazes de manter um certo valor final ou rastrear uma referência, tanto em sistemas considerados simples, como um termostato [1], como em sistemas mais complexos [9].

Uma abordagem neuro-fuzzy [8] une as vantagens tanto da lógica fuzzy como das redes neurais. Busca-se,

deste modo, implementar um sistema de inferência fuzzy através de uma arquitetura paralela distribuída, de tal forma que os paradigmas de aprendizado, comuns às redes neurais, possam ser aproveitados nessa arquitetura híbrida. Os controladores neuro-fuzzy implementados neste trabalho foram baseados no modelo NEFCON [10]. Este modelo é capaz de aprender e otimizar uma base de regras de um controlador fuzzy do tipo Mamdani de modo ‘on-line’ através de um algoritmo de aprendizado baseado em ‘reinforcement learning’ que utiliza uma medida fuzzy para o erro (*erro fuzzy*).

Um dos objetivos deste trabalho é averiguar como o modelo NEFCON opera com sistemas lineares de diversas complexidades e com um sistema com características não-lineares, como é o caso da modelagem apresentada para um motor DC. Em especial, o controle obtido com o *erro fuzzy* é comparado ao obtido com a definição usual do erro (erro usual = referência – saída). Além disso, técnicas tradicionais também foram utilizadas como base de comparação. Da análise dos resultados surge a proposta e a implementação de um novo modelo híbrido.

O foco principal do trabalho é avaliar o novo modelo híbrido proposto. Ele foi concebido a partir do aprendizado de uma base de regras iniciais utilizando-se o algoritmo NEFCON e o *erro usual*, e inclui Algoritmos Genéticos [4] na etapa de otimização da base de regras.

Algoritmos Genéticos (AG) são algoritmos matemáticos inspirados nos mecanismos de evolução natural e recombinação genética. Esta técnica fornece um procedimento de busca adaptativa e paralela para problemas complexos que privilegia a reprodução e a sobrevivência das soluções mais aptas. A literatura aborda aplicações de AG em conjunto com outras técnicas inteligentes, neurais e fuzzy [11][12].

O trabalho está dividido em quatro outras seções. A segunda seção aborda conceitos básicos relativos aos sistemas neuro-fuzzy, em especial o modelo NEFCON. Na seção 3 são apresentadas as características do novo modelo híbrido proposto. Os estudos de casos de diferentes complexidades e os resultados experimentais obtidos com a simulação dos controladores são apresentados na seção 4. Nesta seção, após avaliar a possibilidade de utilização do *erro usual* para o aprendizado das regras com o algoritmo NEFCON, implementa-se o controle de duas plantas, uma linear e

outra não-linear, com controladores desenvolvidos pelo novo modelo híbrido proposto que utiliza Algoritmos Genéticos para otimizar a base de regras (modelo neuro-fuzzy-genético). Por fim, na seção 5, o trabalho é encerrado com a apresentação das conclusões relativas aos resultados obtidos.

2. Sistemas Neuro-Fuzzy

Os sistemas neuro-fuzzy combinam a capacidade de aprendizado das redes neurais artificiais com o poder de interpretação linguística dos sistemas de inferência fuzzy. Os sistemas neuro-fuzzy estão sob intensa investigação.

A idéia básica de um sistema neuro-fuzzy é implementar um sistema de inferência fuzzy numa arquitetura paralela distribuída, de tal forma que os paradigmas de aprendizado comuns às redes neurais artificiais possam ser aproveitados nesta arquitetura híbrida. Existem diversas aplicações na área de controle, sendo que podemos destacar dois modelos de sistemas neuro-fuzzy: ANFIS (Adaptive Network based Fuzzy Inference System) [7] e NEFCON (NEural Fuzzy CONtroller) [10].

Os controladores desenvolvidos neste trabalho foram implementados tendo por base o modelo NEFCON, que é capaz de aprender e otimizar de modo ‘on-line’ a base de regras de um controlador fuzzy do tipo Mamdani através de um algoritmo de aprendizado do tipo ‘reinforcement learning’ que utiliza uma medida fuzzy para o erro (*erro fuzzy*). O modelo NEFCON é baseado numa rede de retropropagação com uma camada escondida. Um exemplo de uma estrutura neuro-fuzzy com seis regras, duas entradas e uma saída está ilustrado na Figura 1.

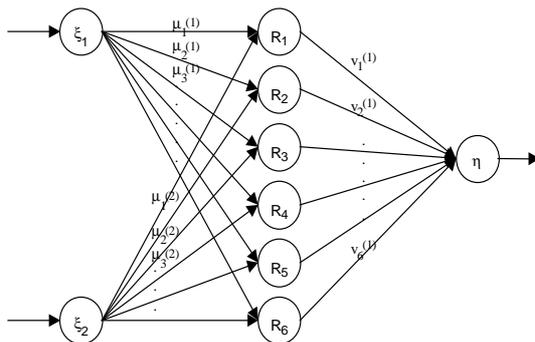


Figura 1 : Exemplo de Sistema NEFCON

Os nós da camada escondida representam as regras $R_1, R_2, R_3, \dots, R_6$; os nós de entrada (ξ_1, ξ_2) representam os valores de entrada; o nó de saída (η) corresponde à saída do controlador. Os pesos $\mu_r^{(i)}$ representam os antecedentes A_r e os pesos $v_r^{(i)}$ representam o conseqüente B_r . Por exemplo, a regra 1 (R_1) pode ser reproduzida do seguinte modo:

$$R_1 \Rightarrow \text{SE } \xi_1 \text{ é } A_1 \text{ E } \xi_2 \text{ é } A_2 \text{ ENTÃO } \eta \text{ é } B_1$$

Regras com os mesmos antecedentes (A_r) têm os mesmos pesos, garantindo assim a integridade da base de regras.

O processo de aprendizado do sistema neuro-fuzzy é realizado em duas etapas: (i) inicialização dos pesos e aprendizado baseado em ‘reinforcement learning’ e (ii) otimização da base de regras. Como o processo de aprendizado é baseado em ‘reinforcement learning’, a geração de um conjunto adequado de regras está fortemente associado à informação de erro fornecida ao sistema neuro-fuzzy durante a fase de aprendizado. O sistema NEFCON apresenta diversas opções para a definição deste erro e a mais típica é a descrição linguística do erro através de regras fuzzy, o chamado *erro fuzzy*. Essas regras descrevem, de modo intuitivo, como o sistema deve se comportar quando está se dirigindo para seu estado ótimo. Considerando-se o algoritmo de aprendizado incremental da base de regras, inicialmente a base de regras está vazia e são fornecidas ao sistema neuro-fuzzy informações relativas às partições dos universos de entrada e saída. Por sua vez, o sistema passa a gerar regras a partir da informação do erro a ele fornecida. A etapa de otimização do conjunto de regras no modelo NEFCON é efetuada através do deslocamento dos conseqüentes e da alteração dos conjuntos suporte dos antecedentes utilizando uma série de heurísticas.

Uma implementação muito interessante do NEFCON foi realizada para o MATLAB 5.3 [6][11] e foi utilizada nas simulações deste trabalho.

3. Modelo Híbrido Neuro-fuzzy-genético

Este novo modelo é baseado no algoritmo de aprendizado incremental da base de regras do modelo NEFCON, com descrição usual do erro do sistema (*erro usual*) e na otimização desta base de regras pela técnica de Algoritmos Genéticos.

Os Algoritmos Genéticos (AG) são algoritmos matemáticos inspirados nos mecanismos de evolução natural e recombinação genética. A técnica de AG fornece um mecanismo de busca adaptativa que se baseia no princípio Darwiniano de reprodução e sobrevivência dos mais aptos. Isto é obtido a partir de uma população de indivíduos (soluções), representados por cromossomas, cada um associado a uma aptidão (avaliação do problema), que são submetidos a um processo de evolução (seleção e reprodução) por vários ciclos.

As operações básicas da técnica são: seleção, reprodução, cruzamento e mutação. A etapa de seleção privilegia os indivíduos mais aptos para em seguida reproduzi-los. Uma parcela dos indivíduos reproduzidos cruza promovendo a troca de suas características genéticas. Mutações podem ocorrer em pequena porcentagem e acarretam uma mudança aleatória no material genético, contribuindo para introduzir variedade na população. A evolução faz com que o AG

seja guiado para regiões mais promissoras do espaço de busca.

Dentre as principais vantagens de AG, podemos citar: técnica de busca global, viabiliza a otimização de problemas mal estruturados e dispensa a formulação matemática precisa do problema. Em resumo, a técnica é robusta e aplicável a uma grande diversidade de problemas, além de ser eficaz e eficiente, pois é capaz de encontrar soluções sub-ótimas, inclusive ótimas, em um tempo razoável.

A modelagem para implementar a otimização da base de regras utilizando algoritmos genéticos partiu da concepção do cromossoma. A Figura 2 ilustra o formato do cromossoma escolhido. Ele é formado pelos parâmetros de cada função de pertinência das variáveis de entrada e saída a serem ajustados para obtenção do desempenho adequado.

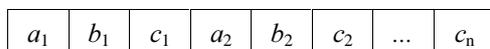


Figura 2 : Cromossoma

No método proposto, os Algoritmos Genéticos são aplicados como técnica de busca/otimização dos valores a , b e c das funções de pertinência relacionadas. Estes parâmetros caracterizam o indivíduo a ser avaliado.

A aptidão de cada indivíduo será avaliada com base na Figura 3, que mostra a resposta desejada (especificação) e a saída real do sistema.

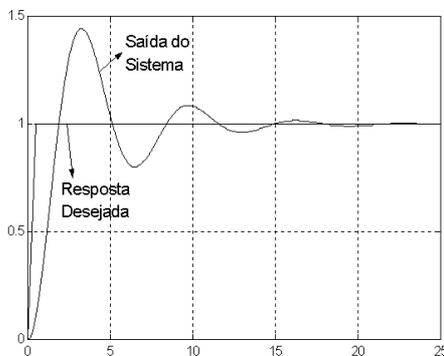


Figura 3 : Resposta desejada

Tendo em vista o objetivo principal, que é realizar o ajuste tendo como ponto de partida a resposta desejada ao degrau para o sistema global em malha fechada, o cálculo da aptidão para os indivíduos foi efetuado segundo a Equação 1 abaixo:

$$Aptidão = \sum^n [Valor\ desejado - Valor\ obtido]^2 \quad (1)$$

Considerando-se o gráfico da Figura 3, a aptidão é calculada dividindo-se o intervalo de observação da resposta em n pontos. Para cada um destes pontos o erro é avaliado. O somatório no cálculo da aptidão se refere a esses pontos de amostragem. A idéia básica é fazer o AG minimizar este somatório, ajustando os parâmetros dos

conjuntos fuzzy para tornar a resposta obtida, a mais próxima possível da resposta desejada (especificação).

A implementação do novo modelo híbrido utilizou o software *Evolver*® para o AG e o *Matlab/Simulink*® para simulação do sistema.

4. Estudo de Casos

Quatro experimentos foram selecionados para avaliar o desempenho dos controladores desenvolvidos.

No desenvolvimento do controlador NEFCON tradicional foi utilizada a *descrição do erro por intervalos fuzzy*, devido à sua flexibilidade. Esta descrição possibilita a definição de uma região em torno da resposta desejada, na qual se considera o erro como zero. Fora de tal região é utilizado o erro fuzzy default. O algoritmo NEFCON I realizou a otimização.

Para o controlador baseado no *erro usual* (referência – saída), apenas a primeira etapa relativa à extração de regras foi efetuada. O objetivo era verificar se apenas com a *definição usual do erro* o modelo seria capaz de controlar as plantas mais complexas. Além disso, para as plantas lineares, controladores tradicionais foram implementados para a comparação de resultados.

Após avaliar a questão relativa à definição do erro, implementou-se controladores pelo novo modelo Neuro-Fuzzy-Genético somente para as duas plantas mais complexas.

A primeira planta avaliada representa um sistema de segunda ordem utilizado para verificar a questão relativa à definição do erro e a funcionalidade básica do modelo NEFCON. Os resultados foram comparados com os obtidos por um controlador analítico tradicional.

A segunda planta é de terceira ordem, e foi utilizada com os mesmos objetivos da primeira. Os resultados do NEFCON foram comparados com os obtidos com um controlador PID sintonizado pelo método de Ziegler-Nichols.

A terceira planta apresenta retardo e o novo modelo híbrido (neuro-fuzzy-genético) foi utilizado. Novamente é realizada uma comparação com um controlador PID sintonizado pelo método de Ziegler-Nichols.

A quarta planta avaliada é mais complexa e representa um motor DC controlado pela armadura que tem características não-lineares de saturação. Também foi utilizado o novo modelo para desenvolvimento de um controlador.

Experimento 1

Neste experimento projetou-se um controlador para compensar a planta especificada na Equação 2.

$$G_1(s) = \frac{4}{s(s+0.5)} \quad (2)$$

Os dois sistemas de controle, NEFCON e *erro usual*, foram capazes de controlar a planta fazendo a

saída rastrear um sinal de referência, conforme ilustra a Figura 4.

Para fins de comparação, empregou-se um método analítico para obter a função de transferência do compensador [3], $G_c(s)$. O resultado é apresentado na Equação 3.

$$G_c(s) = \frac{10 \cdot (2s + 1) \cdot (5s + 1)}{(0.1992s + 1) \cdot (80.19s + 1)} \quad (3)$$

A Figura 4 apresenta as respostas transientes do método analítico e dos controladores NEFCON avaliados.

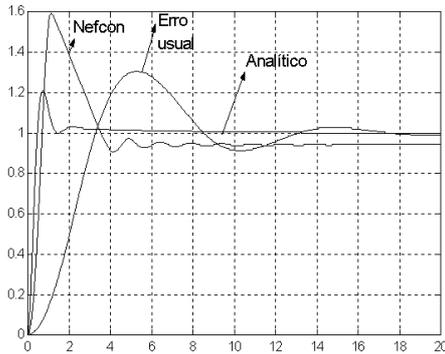


Figura 4: Respostas transientes do sistema obtidas pelos métodos analíticos e NEFCON (NEFCON tradicional e erro usual).

Os controladores NEFCON utilizaram uma configuração bastante simples com apenas três conjuntos fuzzy para cada um dos antecedentes (erro e variação do erro) e cinco para o conseqüente (saída). O algoritmo de aprendizado incremental de regras foi capaz de gerar nove regras para os dois modelos avaliados.

O tempo de subida do controlador NEFCON tradicional é similar ao do método analítico, porém o NEFCON apresenta um valor de ultrapassagem bem maior. O NEFCON tradicional também apresentou um offset em regime permanente. Foi constatado que este offset foi acentuado durante a fase de otimização das regras.

O modelo NEFCON baseado no *erro usual* apresenta uma resposta mais “suave” com um valor máximo de ultrapassagem razoável, similar ao do método analítico, porém com maior tempo de subida e alguma oscilação em regime.

Conclui-se que para as duas definições de erro (NEFCON tradicional e erro usual) as estratégias de controle obtidas foram capazes de controlar a planta.

Experimento 2

O segundo experimento foi realizado com a planta de terceira ordem representada pela Equação 4.

$$G_2(s) = \frac{1}{s(s+1)(s+5)} \quad (4)$$

Neste experimento, para fins de comparação com o NEFCON utilizou-se um controlador PID sintonizado pelas regras de Ziegler-Nichols ($K_p = 18$, $K_i = 12,81$ e $K_d = 6,32$) [2]. A Figura 5 ilustra os resultados obtidos. Os parâmetros do NEFCON foram iguais aos da planta anterior.

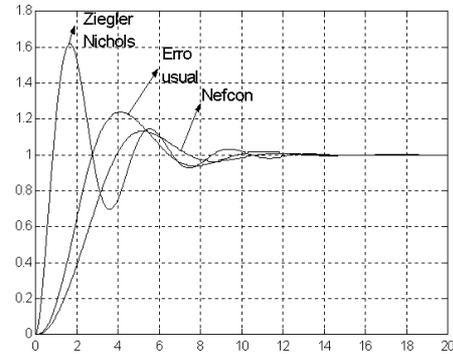


Figura 5: Respostas da planta de terceira ordem

Uma análise do gráfico da Figura 5 mostra que a resposta obtida com o controlador PID sintonizado pelas regras de Ziegler-Nichols apresenta um grande valor de ultrapassagem e um comportamento oscilatório. Por outro lado, ambos os controladores NEFCON obtiveram respostas mais lentas, porém com pouca ultrapassagem.

Tendo em vista os resultados obtidos nas duas primeiras plantas com a geração de regras utilizando-se o erro usual e o algoritmo de aprendizado do NEFCON, dois experimentos mais complexos foram especialmente selecionados para avaliar o método híbrido proposto. O primeiro foi uma planta com retardo; o segundo foi com a modelagem feita para um motor DC não-linear. Em ambos os experimentos, utilizou-se a definição dos conjuntos fuzzy e as regras obtidas com a descrição do *erro usual* do NEFCON. A Figura 6 ilustra os conjuntos fuzzy iniciais para as entradas *erro* e *variação do erro* e a Figura 7 apresenta os conjuntos fuzzy para a saída.

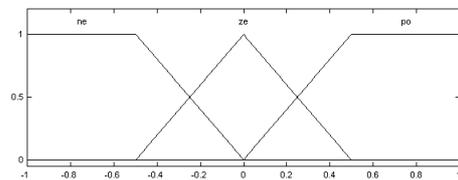


Figura 6: Conjuntos fuzzy para as entradas

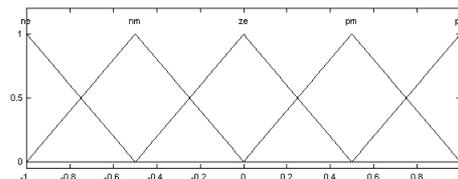


Figura 7: Conjuntos fuzzy iniciais para a saída

Experimento 3

No terceiro experimento foi avaliada a capacidade dos modelos NEFCON e híbrido de controlar uma planta com retardo. A função de transferência da planta 3 [5] é dada pela Equação 5 e os resultados obtidos estão na Figura 8.

$$G_3(s) = \frac{5 \exp(-2s)}{(5s+1)(3s+1)} \quad (5)$$

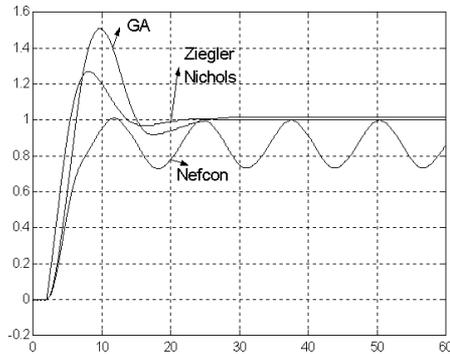


Figura 8 : Resposta ao degrau da planta com retardo

Para fins de comparação com o método proposto utilizou-se um controlador PID sintonizado pelas regras de Ziegler-Nichols. Pode-se constatar, pela resposta obtida para esta planta com *delay*, que o NEFCON apresentou dificuldades em regime permanente. Enquanto o tempo de subida foi um pouco maior e a ultrapassagem um pouco menor do que os valores obtidos pelo controlador PID, o controlador NEFCON apresentou um *offset* em regime permanente. O novo controlador neuro-fuzzy-genético apresentou uma resposta melhor do que o controlador NEFCON tradicional. Este resultado foi obtido com a seguinte base de regras:

1. Se (input1 é ze) e (input2 é ze) então (output é ze)
2. Se (input1 é ze) e (input2 é ne) então (output é ze)
3. Se (input1 é ze) e (input2 é po) então (output é ze)
4. Se (input1 é po) e (input2 é po) então (output é pm)
5. Se (input1 é po) e (input2 é ze) então (output é po)
6. Se (input1 é po) e (input2 é ne) então (output é po)
7. Se (input1 é ne) e (input2 é ne) então (output é nm)
8. Se (input1 é ne) e (input2 é ze) então (output é nm)
9. Se (input1 é ne) e (input2 é po) então (output é nm)

Apenas os conjuntos fuzzy relativos à entrada *erro* foram alterados no procedimento de otimização. A resposta apresentou tempo de subida similar ao obtido pelo método de Ziegler-Nichols, porém com maior valor de ultrapassagem. O resultado final obtido é muito melhor do que o do método NEFCON tradicional.

Experimento 4

A quarta planta é mais complexa e representa um servomotor DC controlado pela armadura que tem características não-lineares de saturação.

O desenvolvimento da função de transferência do sistema pode ser acompanhada com detalhes em [2]. Atribuindo-se valores numéricos aos parâmetros, a função de transferência da planta é dada pela Equação 6.

$$G_4(s) = \frac{C(s)}{E(s)} = \frac{1}{s(1,3s+1)} \quad (6)$$

Para levar em conta um modelo não-linear do motor, introduziu-se um bloco de saturação logo na entrada do sinal de acionamento na armadura do motor, conforme ilustra a Figura 9.

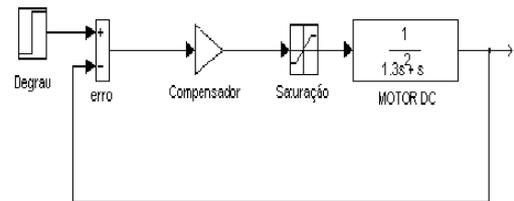


Figura 9: Sistema de Controle para motor DC com não-linearidades

Durante a otimização vários conjuntos fuzzy foram alterados. A Figura 10 ilustra as alterações sofridas nos conjuntos fuzzy da entrada *erro*.

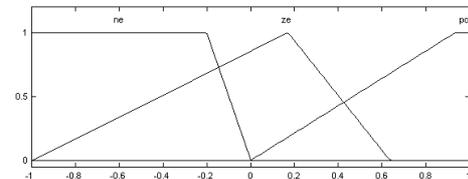


Figura 10: Conjuntos fuzzy da entrada *erro* após otimização pelo GA para a planta do Motor não-linear

A Figura 11 ilustra as respostas ao degrau do sistema do diagrama de blocos da Figura 9.

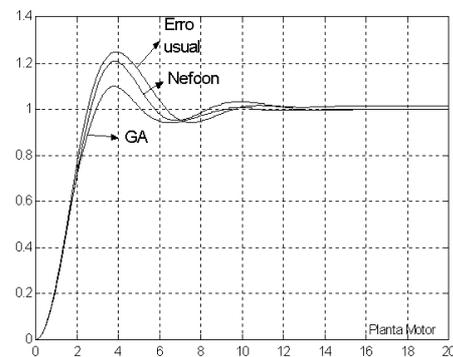


Figura 11 : Respostas ao degrau do Motor com não-linearidade

A resposta apresentou tempo de subida similar ao obtido pelo NEFCON original e um menor valor de ultrapassagem. O resultado final obtido é melhor do que o do método NEFCON tradicional. Numa comparação

entre as curvas *Erro usual* e *GA* constata-se que a otimização foi efetiva

5. Conclusões

Os experimentos realizados mostraram desempenhos satisfatórios dos compensadores desenvolvidos. Tendo em vista, o número de conjuntos fuzzy utilizados para as entradas (três) e para a saída (cinco) e a diversidade de plantas avaliadas, inclusive com uma planta não-linear, os resultados obtidos foram considerados satisfatórios.

O sistema de desenvolvimento mostrou que o modelo NEFCON foi concebido para o *auxílio* no projeto de controladores fuzzy. Ele não é um gerador automático de controladores fuzzy e o usuário deve sempre supervisionar e interpretar os resultados. No entanto, é uma ferramenta poderosa para o desenvolvimento de controladores fuzzy. Sua capacidade de extração de regras 'on-line' no ambiente de treinamento é sem dúvida muito interessante, pois ele aprende a controlar o sistema utilizando apenas a informação relativa ao erro. Além disso, não é necessário nenhum modelo matemático para implementar o controle. Este enfoque apresenta grande vantagem sobre os procedimentos tradicionais no tratamento de sistemas não-lineares, pois não é necessário determinar um sistema linear "equivalente" em substituição ao não-linear.

Cabe ressaltar que a qualidade do controle exercido depende diretamente da capacidade do algoritmo de aprendizado em extrair uma base de regras capaz de realizar um controle com as características desejadas. A utilização tanto do chamado *erro fuzzy* como do *erro usual* levaram a resultados consistentes.

O projeto de compensadores com o modelo NEFCON utilizando o *erro usual* pode ser interessante em aplicações reais, pois permite o desenvolvimento de compensadores sem a preocupação em definir bem o *erro fuzzy*, o que também funcionou para um sistema não-linear.

A proposta do novo modelo híbrido Neuro-Fuzzy-Genético foi efetiva no sentido de melhorar as respostas obtidas inicialmente e automatizar a sintonia dos controladores neuro-fuzzy com a poderosa técnica de otimização com Algoritmos Genéticos. A função de avaliação escolhida leva a minimizar as diferenças entre a resposta especificada e a resposta obtida.

Referências

- [1] J. F. M. Amaral & J. L. M. Amaral. Controle de temperatura baseado em lógica nebulosa utilizando controladores programáveis. In *Anais do Seminário de Instrumentação e Automação*, 1998.
- [2] K. Ogata. *Engenharia de Controle Moderno*. 3^a Ed., Prentice-Hall do Brasil, 1997.
- [3] K. Ogata. *Modern Control Engineering*. 2nd Ed., Prentice-Hall, 1990.
- [4] L. Davis. *Handbook of Genetic Algorithms*. VNR Computer Library, 1990.

- [5] G. F. Franklin, J. D. Powell, A. Emami-Naieni. *Feedback Control of Dynamic Systems*. Addison-Wesley, Massachusetts, 1988.
- [6] A. Nürnberger, D. Nauck, R. Kruse. Neuro-fuzzy control based on the NEFCON model under MATLAB/SIMULINK. In *Proceedings of the 2nd on-line World Conference on Soft Computing in Engineering Design and Manufacturing (WSC2)*, pages 393-400, 1997.
- [7] J. R. Jang. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 1993.
- [8] C-T Lin and C. S. G. Lee. *Neural Fuzzy Systems*. Prentice-Hall, USA, 1996.
- [9] P. J. Werbos. Applications of Neural Computation - Control. In *Handbook of Neural Computation*, E. Fiesler, R. Beale (Eds), Oxford University Press, 1997.
- [10] A. Nürnberger, D. Nauck, R. Kruse. Neuro-fuzzy control based on the NEFCON-model: recent developments. *Soft Computing Abstract* 2(4): 168-182, 1999.
- [11] J. J. Buckley and K. D. Reilly, K. V. Penmetcha. Backpropagation and genetic algorithms for training fuzzy neural nets. In *Genetic Algorithms and Soft Computing*, F. Herrera, F., J. Verdegay (Eds), Physica-Verlag, 1996.
- [12] A. González and R. Pérez. A learning system of fuzzy control rules based on genetic algorithms. In *Genetic Algorithms and Soft Computing*, F. Herrera, F., J. Verdegay (Eds), Physica-Verlag, 1996.