

OTIMIZAÇÃO DE CONTROLE FUZZY USANDO ALGORITMO GENÉTICO

ANDRÉ H. M. PIRES¹, ÁLVARO R. DE FIGUEIREDO¹, ALCEMY G. V. SEVERINO¹, MICHEL J. DA SILVA¹, FÁBIO MENEGHETTI UGULINO DE ARAÚJO¹.

1. *Laboratório de Controle e Processos, Departamento de Engenharia de Computação e Automação, Universidade Federal do Rio Grande do Norte*
59078-900, Natal, RN, BRASIL

E-mails: andrehmp@hotmail.com, alvaro_ramos@bct.ect.ufrn.br, alcemygabriel@hotmail.com, micheljanura@hotmail.com, meneghet@dca.ufrn.br

Abstract—This paper talks about the optimization of a fuzzy controller by a genetic algorithm. The fuzzy systems are an alternative to some problems, and in this work it is used to control a tank level. The fuzzy control that was used implements a simple strategy of the Proportional Derivative control and it is the Takagi-Sugeno-Kang type. The plant used is from the Tanks Quanser, and consists in two tanks and a pump, this plant were modeled and simulated in computer to test the fuzzy control optimized. To optimize the fuzzy control were used a genetic algorithm implemented in computer too and the results were compared with a hand tuned fuzzy control, analyzing by evaluation indices and graphics answer.

Keywords—Genetic Algorithm, Optimization, Fuzzy, Control, Automation.

Resumo—Neste trabalho pretende-se otimizar um controlador *fuzzy* usando um algoritmo genético. A pesquisa foi desenvolvida no Laboratório de Controle e Processos, do Departamento de Engenharia de Computação e Automação, na Universidade Federal do Rio Grande do Norte. O controlador foi desenvolvido em computador e testado em um modelo de simulação de uma planta, usou-se um *fuzzy* do tipo Takagi-Sugeno-Kang com estratégia Proporcional Derivativa, que possui duas entradas, o erro e a derivada do erro, e uma saída, uma tensão. A planta usada foi a de Tanques acoplados da Quanser, que consiste em dois tanques e uma bomba com a intenção de controlar o nível de um desses tanques. O algoritmo genético foi desenvolvido em uma rotina de computador e tentou-se achar um controlador *fuzzy* ótimo usando ele, partindo de uma população de controladores aleatórios.

Palavras-chave—Controle, *Fuzzy*, Algoritmo Genético, Otimização.

1 Introdução

Os sistemas *fuzzy* são estudados e desenvolvidos pelo mundo, e segundo Mandani (1974), o campo de controle tem sido bastante beneficiado. O estudo de controladores que implementam a lógica *fuzzy* tem se mostrado uma alternativa muito interessante ao modelo atualmente usado, que é o de controles Proporcional Integral Derivativo (PID), segundo Silva (2002), a maior parte de controle e processos industrial no mundo opera com esse tipo de controlador. Porém para seu uso, muitas vezes se faz necessário obter um modelo linear de plantas não lineares que representam os sistemas reais, sofrendo assim com perturbações e erros de modelagem e os processos acabam sendo controlados de forma insatisfatória (FIGUEIREDO; JOTA, 2004).

Os controladores *fuzzy* trabalham com informações imprecisas e dinâmicas, utilizam a lógica *fuzzy* introduzida por Zadeh (1965). A grande desvantagem de um controlador desse tipo pode ser a sua sintonização, uma vez que mesmo um controlador com uma estratégia simples pode possuir um grande número de parâmetros a serem ajustados e não existe um método sistemático eficaz para esse trabalho.

Sendo assim, o trabalho propõe sintonizar um controlador desse tipo usando um Algoritmo Genético (AG), que é uma das mais difundidas e estudadas dentre as técnicas de Computação Evolucionária (TANOMARU, 1995), devido a uma relativa simplicidade de implementação e sua eficácia em busca global de ambientes diversos. O AG é um método de

otimização metaheurística baseado na Teoria da Evolução de Darwin, e foi difundido por Holland (1975).

2 Metodologia

2.1 Modelo da Planta

O controle de nível de tanques é problema fundamental na indústria. Os processos industriais necessitam, freqüentemente, que líquido sejam bombeados e estocados em tanques, e oportunamente re-bombeados para outros tanques. Muitas vezes estes líquidos sofrerão processos químicos ou de mistura, de modo que será sempre necessário o controle do nível e do fluxo entre tanques.

Portanto, o controle de níveis de tanques é requisito básico na indústria química, setor essencial na economia, englobando a petroquímica, tratamento de água, indústria de produção do papel, dentre outros.

Neste contexto, mostra-se necessária a compreensão matemática do comportamento de líquidos em um sistema de tanques, de modo que a modelagem do mesmo é figura importante nos processos de controle. Abordar-se-á o controle e modelagem de um sistema de tanques acoplados. A união de dois ou mais tanques forma um sistema de tanques acoplados. Devido à natureza deste problema, a união de tanques deve ser tratada como um único sistema. Contudo, é necessário que se defina qual o foco da modelagem deste sistema: o nível do primeiro tanque, o nível do segundo tanque, a vazão de entrada

ou de saída do sistema ou a vazão entre os tanques. Ter-se-á como foco o controle do nível do segundo tanque o qual recebe como fluxo de entrada o fluxo de saída do primeiro tanque.

A planta sobre análise é a planta didática da Quanser (Figura1), esta possui dois tanques acoplados, reservatório, e bomba hidráulica acionada por um motor DC, onde os dados são coletados por uma placa de aquisição de dados e enviados para um computador.



Figura 1. Sistema de tanque

Os sensores de níveis de cada tanque enviam sinais elétricos à placa de aquisição de dados esta fornece os dados ao controlador e recebe do mesmo o sinal de controle para o acionamento da bomba. A bomba hidráulica fornece ao tanque 1, tanque mais alto, uma vazão diretamente proporcional a tensão aplicada ao seu motor. O líquido contido no tanque 1 flui por gravidade através de um orifício para o tanque 2. Do mesmo modo o líquido contido no tanque 2 flui para o reservatório, sendo possível o ajuste da vazão dos orifícios pela troca de peças.

A planta em questão pode ser modelada pelas equações (1) e (2).

$$h_1(k) = h_1(k-1) + T \left(\frac{K_m V_p}{A_2} - \frac{a_1 \sqrt{2gV_p h_1(k-1)}}{A_1} \right) \quad (1)$$

$$h_2(k) = h_2(k-1) + T \left(\frac{a_1 \sqrt{2g h_1(k)}}{A_2} - \frac{a_2 \sqrt{2g h_2(k-1)}}{A_1} \right) \quad (2)$$

Com os parâmetros descritos na Tabela 1.

Tabela 1. Parâmetros do modelo da planta

Parâmetros	Descrição
L_1 e L_2	Níveis dos tanques 1 e 2
A_1 e A_2	Áreas das bases dos tanques 1 e 2
a_1 e a_2	Orifícios de saída dos tanques 1 e 2
K_m	Constante da bomba
V_p	Tensão aplicada na bomba
g	Aceleração da gravidade

2.2 Controle Fuzzy

Com o objetivo do controle de níveis, foi adotado um sistema de controle em malha fechada, utilizando método *fuzzy*. O controle *fuzzy*, é um método inserido no contexto da inteligência artificial, visto que permite codificar o conhecimento e a experiência de operadores humanos e lidar com incertezas. A lógica *fuzzy* é baseada na teoria dos conjuntos nebulosos de Zadeh (1965). Esta teoria permite que um elemento tenha pertinência ou não-pertinência parcial a um conjunto, este fato dá uma maior flexibilidade a conjuntos de regras e sistemas de inferências. Isto permite ao controlador trabalhar com incertezas e imprecisões, simulando a forma de raciocínio humana, tornando-se capaz de lidar com problemas complexos de controle linear e não linear, com a rapidez, segurança e robustez.

Projetar um controlador *fuzzy* envolve, usualmente, a codificação da experiência adquirida por operadores humanos por meio da criação de funções de pertinência, que atribui a uma variável sua pertinência a um dado conjunto e a elaboração de uma base de regras responsável por tomar as decisões de controle de acordo com a pertinência das variáveis.

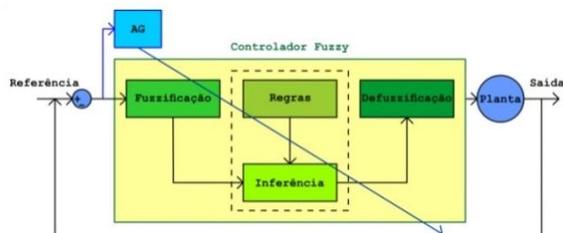


Figura 2. Diagrama de um controlador Fuzzy

Neste contexto, é necessária a fuzzificação do sinal de entrada que consiste na tradução da entrada nos conjuntos *fuzzy*, atribuindo-a e avaliando o grau de pertinência às funções de pertinência predefinidas no projeto do controlador. Os dados resultantes da fuzzificação são submetidos à base de regras do controlador *fuzzy*, processo e inferência. Esta contém a lista das combinações de entrada possíveis fornecendo regras para o processo de controle sem contradições entre si. Este conjunto de regras possui o formato SE-ENTÃO, quando o resultado da fuzzificação ativa as regras estas irão ativar as correspondentes ações de controle. A soma das regras ativadas, forma conjuntos intermediários de saída. O resultado deste processo precisa, portanto, ser convertido em um sinal de controle capaz de atuar na planta, no processo denominado defuzzificação.

No projeto foram utilizadas duas funções de entrada, codificadas como Erro e Derivada do Erro. Cada uma destas possui três funções de pertinência triangulares de acordo com a intensidade. O controlador é do tipo *fuzzy* Takagi-Sugeno, logo com funções de saída na forma linear, apresentando uma única função de saída, a Tensão, com cinco funções lineares, cada uma com três parâmetros a ajustáveis. Para o ajuste de parâmetros tanto das curvas triangu-

lares de pertinência das entradas, quanto das funções lineares de saída foram utilizados Algoritmo Genético. O controle ótimo necessita o ajuste do total de 33 parâmetros e o uso do Algoritmo Genético buscando a obtenção destes parâmetros de modo ótimo para o controle do sistema.

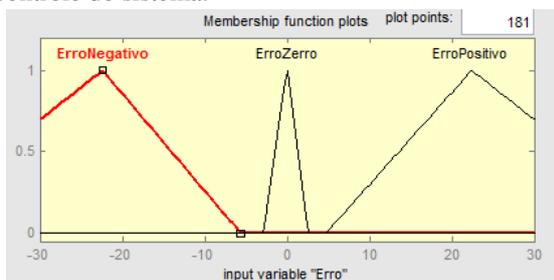


Figura 3. Função Erro

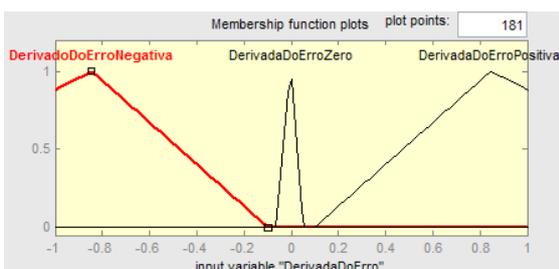


Figura 4. Função Derivada do erro

O controlador possui inferência com 9 regras lingüísticas, mostradas na Tabela 2.

Tabela 2: Base de Regras do Controlador Fuzzy

		Derivada do Erro		
		Derivada do Erro Negativa	Derivada do Erro Zero	Derivada do Erro Positiva
Erro	Erro Negativo	Tensão Negativa Pequena	Tensão Positiva Pequena	Tensão Negativa Grande
	Erro Zero	Tensão Zero	Tensão Zero	Tensão Zero
	Erro Positivo	Tensão Positiva Pequena	Tensão Negativa Pequena	Tensão Positiva Grande

2.3 Método de Otimização Algoritmo Genético

Métodos de otimização são processos matemáticos usados em diversos problemas de maximização ou minimização de funções, ou seja, busca de um melhor resultado baseado em uma função de avaliação (ou objetivo) de acordo com o problema.

Existem vários métodos de otimização, que podem ser classificados em métodos determinísticos, caso se possa prever todos os seus passos conhecendo-se seu ponto de partida, ou estocásticos, baseados em processos aleatórios, executando-se repetições para achar a melhor solução.

Há também os métodos que se utilizam de técnicas heurísticas, definida por uma regra derivada da experiência, onde se procura sempre o melhor cami-

nho ou a melhor solução baseado em suas regras, porém suas soluções podem ser consideradas boas, mas nem sempre ótimas. O algoritmo genético (AG) é um método meta-heurístico de otimização, onde se usa técnicas de heurísticas e procedimentos probabilísticos combinados como guia na busca em todo espaço de pesquisa e sua vizinhança, evitando paradas prematuras em soluções boas, porém não ótimas.

O AG também é classificado como método evolutivo, uma vez que se baseia na teoria da evolução de Darwin, e usa conceitos da Genética, tendo como vantagens no uso o fato de existir uma população de valores a serem testados, e não apenas um único ponto, tornando mais fácil a busca por todo espaço de pesquisa, além de técnicas usadas em sua programação, como a técnica da mutação, que nos garante que o AG não estacionar em pontos locais.

O funcionamento geral de um AG é bastante simples. Primeiramente cria-se uma população de indivíduos, onde cada indivíduo é um valor a ser testado no problema, logo após, essa população é avaliada de acordo com uma função objetivo, definida de acordo com o problema. Após avaliar a população selecionam-se dois indivíduos, por meio de probabilidade, aquele com melhor avaliação tem mais chance de ser escolhido, para realizarem o *crossover* ou cruzamento, o que será feito até ser gerada uma nova população, durante o cruzamento pode ser implementada a técnica de mutação, onde o indivíduo gerado pode sofrer ou não, dependendo de um parâmetro do AG. Após a geração da nova população é feito novamente uma avaliação, e novamente a fase do *crossover*, repetindo-se até atingir um critério de parada pré-definido. Logo abaixo a Figura 5 apresenta um fluxograma de um AG.

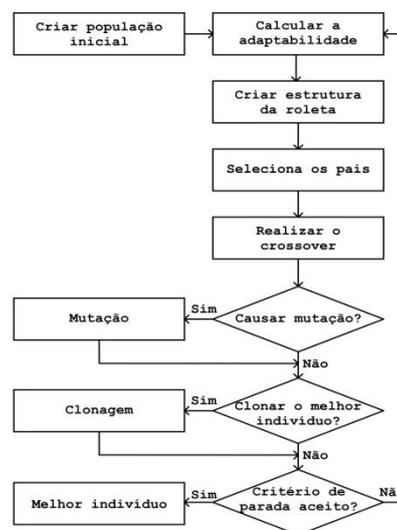


Figura 5. Fluxograma Algoritmo Genético

2.4 O Algoritmo Genético Atuando como Sintonizador do Controlador Fuzzy

Com o objetivo de encontrar os parâmetros ótimos, sintonizando o controlador fuzzy apresentado na seção 4.1 de modo eficiente, buscou-se o uso do Al-

goritmo Genético (AG). Inicialmente criou-se uma população de indivíduos, em que cada indivíduo é um conjunto de números organizados em cromossomos, que são os parâmetros de cada função de entrada e saída do controlador *fuzzy*.

Para cada indivíduo da população é realizada uma simulação, podendo-se avaliar por meio de índices, o desempenho de cada sintonia do controlador. Essa é talvez seja uma das partes mais importantes do AG, a definição do índice de avaliação. No projeto foram usados três índices diferentes para avaliação. Foram utilizados o Índice de Goodhart, o Valor Absoluto do Erro (IAE – *Integrated Absolute-Error*) e a Integral do Tempo multiplicado pelo Erro Absoluto (ITAE – *Integrated of the Time multiplied by Absolute Error*).

O Índice de Goodhart, que foi proposto por Goodhart et al.(1994), leva em consideração o esforço de controle, a variância do sinal de controle e os desvios com relação à referência. São calculadas de acordo com as Equações (3), (4) e (5) abaixo, que são respectivamente o esforço de controle médio, a variância do sinal de controle e a média do erro quadrático.

$$\varepsilon_1 = \frac{1}{N} \sum_{k=1}^N u(k) \quad (3)$$

$$\varepsilon_2 = \frac{1}{N} \sum_{k=1}^N (u(k) - \varepsilon_1)^2 \quad (4)$$

$$\varepsilon_3 = \frac{1}{N} \sum_{k=1}^N (r(k) - y(k))^2 \quad (5)$$

Somando-se esses três resultados obtemos o índice, como se vê na Equação (6). Sendo os parâmetros α_1 , α_2 e α_3 os pesos de ponderação.

$$\varepsilon = \alpha_1 \varepsilon_1 + \alpha_2 \varepsilon_2 + \alpha_3 \varepsilon_3 \quad (6)$$

O IAE avalia a precisão do resultado, vê-se na Equação (7).

$$IAE = \sum_{k=1}^N |e(k)| \quad (7)$$

Por fim, tem-se o ITAE que introduz ao IAE a ponderação do tempo. Segue na Equação (8):

$$ITAE = \sum_{k=1}^N t|e(k)| \quad (8)$$

Após calcular a adaptabilidade de toda população baseado nos índices escolhidos, é formada a estrutura de roleta, assim os pais serão selecionados para o cruzamento através dela, dando maior chance aos indivíduos que possuem maior adaptabilidade.

O cruzamento é realizado entre os cromossomos correspondentes dos indivíduos selecionados e, após isso, implementou-se as técnicas de mutação e clonagem. A mutação pode ocorrer ou não, o que irá depender de um processo aleatório e da taxa de mu-

tação escolhida. A clonagem tem por função perpetuar o melhor indivíduo de uma geração na seguinte, porém também poderá ou não ocorrer, dependendo da quantidade de indivíduos na população.

Definidos esse passos o algoritmo repete-se até atingir o critério de parada. No caso, foi utilizado como critério de parada um número máximo de gerações ou uma possível estagnação do melhor indivíduo, ou da média da população.

Ao final, o AG retornará o melhor indivíduo, ou seja, o melhor conjunto de parâmetros encontrados e escritos no controlador *fuzzy* para a planta dos tanques acoplados.

2.5 Resultados e Discussão

Após a sucessiva realização de testes com o AG, mudando-se os parâmetros de entrada foi alcançado um controlador com os parâmetros mostrados na Tabela 3, sendo as entradas funções de pertinência triangulares e saídas definidas por funções sugeno de primeira ordem com o termo independente, ou offset nulo.

Tabela 3. Parâmetros do controlador *fuzzy* otimizado.

ENTRADA		SAÍDA	
Função de pertinência triangular	Parâmetros	Função de pertinência linear	Parâmetros
EM	[-30000 -18,969 1,071]	TNG	[0,015 0,383 0]
EZ	[-0,123 3,529 15,820]	TNM	[0,022 0,425 0]
EP	[14,950 26,779 30000]	TNP	[0,020 0,531 0]
DEN	[-1000 -0,207 -0,041]	TZ	[0,027 0,539 0]
DEZ	[-0,193 0,358 0,710]	TPP	[0,031 0,434 0]
DEP	[0,410 0,870 1000]	TPM	[0,076 0,449 0]
		TPG	[0,108 0,464 0]

Com o objetivo de comparar os resultados encontrados com o uso do AG e os encontrados por sintonia manual, um controlador *fuzzy* de mesma estrutura, foi sintonizado manualmente, utilizando-se de dispendiosas horas na busca da sintonia mas adequada. Na Figura 6 observam-se as respostas da planta com o controlador *fuzzy* otimizado pelo AG e Na Figura 7 daquele sintonizado manualmente, sendo o nível do tanque controlado representado pelas curvas contínuas e a referência pelas curvas tracejadas.

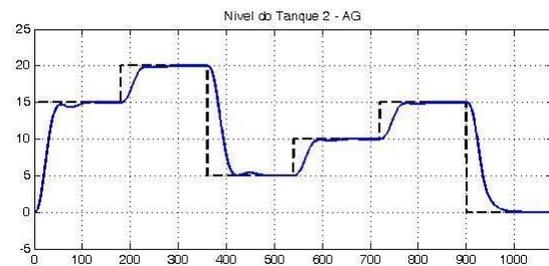


Figura 6. Resposta ao controlador *fuzzy* AG

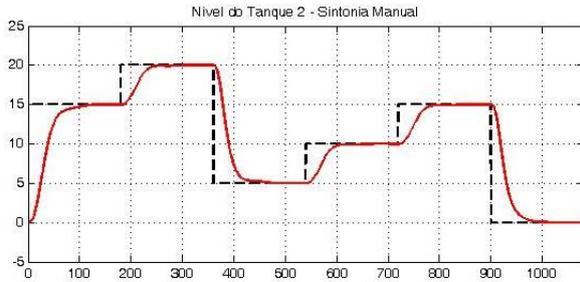


Figura 7. Resposta ao controlador *fuzzy* de sintonia manual

Na Figura 8 os sinais de controle gerados pelo controlador *fuzzy* otimizado pelo AG e o sintonizado manualmente.

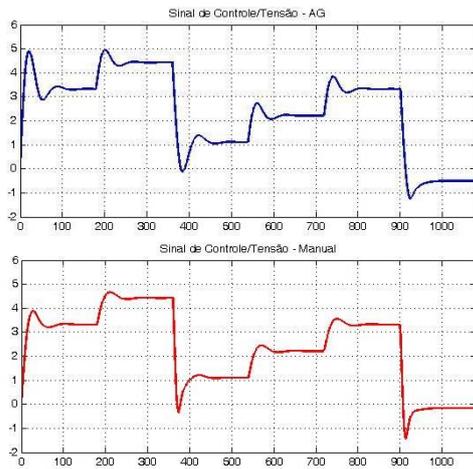


Figura 8. Sinais de controle gerados pelo controlador *fuzzy* AG e de sintonia manual respectivamente.

A partir da análise visual das curvas com controlador de sintonia manual e o sintonizado com o auxílio do AG percebe-se uma ligeira diferença em benefício deste último. As respostas não apresentam *overshoot* e os tempos de acomodação diferem em menos de 10%. Ao analisar-se os sinais de controle gerados pelos controladores notam-se curvas suaves, sem grandes variações e que não atingem os níveis de saturação (± 15 volts) durante todo o período de teste.

Na Tabela 4 mostra-se os índices do controlador *fuzzy* de sintonia AG e o de sintonia manual.

Tabela 4: Índices e tempos de acomodação do controlador *fuzzy* otimizado e de sintonia manual

OTIMIZADO POR AG		SINTONIA MANUAL	
Índice	Valor	Índice	Valor
IG	23,8435	IG	22,3448
IEA	117054,9574	IEA	117060,1194
IEAT 1º degrau	43,7475	IEAT 1º degrau	66,9258
IEAT 2º degrau	106,9299	IEAT 2º degrau	131,3648
IEAT 3º degrau	932,1556	IEAT 3º degrau	846,8302
IEAT 4º degrau	428,6938	IEAT 4º degrau	514,6209
IEAT 5º degrau	566,7959	IEAT 5º degrau	679,8827
IEAT 6º	2373,8449	IEAT 6º	2085,6252

degrau	IA	degrau	IA
tda 1º degrau	46,3	tda 1º degrau	71,1
tda 2º degrau	226,4	tda 2º degrau	239,6
tda 3º degrau	410,0	tda 3º degrau	414,0
tda 4º degrau	586,4	tda 4º degrau	599,3
tda 5º degrau	766,4	tda 5º degrau	779,3
tda 6º degrau	963,5	tda 6º degrau	959,5

Os índices mostram um leve melhora no controlador *fuzzy* otimizado. Para que tais índices fossem encontrados foram utilizados $\alpha_1 = 1$; $\alpha_2 = 6$; $\alpha_3 = 3$; e o percentual de mutação = 2%, como parâmetros no AG. Utilizou-se como peso para os índices na avaliação no AG, 4 para o IG, 3 para o IEA, e 3 para IEAT.

Percebe-se, comparando as curvas das figuras 6 e 7, um menor tempo de resposta com o uso do controlador *fuzzy* otimizado, o que se comprova com o menor IEA e com os menores IEATs para a maior parte dos degraus, como mostrado na tabela 4. Embora o Sinal de controle oscile um pouco mais no *fuzzy* otimizado que no de sintonia manual, como é observado pelo maior valor de IG visto na tabela 4, ambos os sinais de controles são adequados e não ultrapassam os valores de saturação.

5 Conclusão

Após analisar dos resultados, conclui-se que o AG demonstrou ser uma técnica eficiente na busca de uma sintonia ótima para controladores *fuzzy* produzindo um controle mais favorável e com menor tempo de resposta, de acordo com os índices desejados, e permitindo, ainda, a automatização do processo de sintonia usando um menor esforço humano em sua obtenção que possibilita um menor tempo necessário, em sacrifício de um maior esforço computacional. Como foi utilizado um *fuzzy* PD, sendo uma estratégia de controle bastante simples, os resultados foram satisfatórios, tendo o algoritmo convergido para um resultado esperado. Entretanto, esses resultados ainda podem ser melhorados, visto que dependem da função de avaliação escolhida. O teste de novos parâmetros de entradas no AG e de diferentes pesos de ponderação utilizados para os três índices podem resultar em um controle mais eficiente. Pode-se, modificar o controlador *fuzzy* para que se comporte como um PI (Proporcional Integral) e não como um PD, adotando-se uma estratégia de estratégia de controle mais adequada.

Agradecimentos

ANP, MCT, FINEP e CNPq pelo apoio financeiro por meio dos projetos PFRH e PIBIC.

Referências Bibliográficas

FERREIRA, C. Estudo comparativo entre as técnicas de controle Fuzzy, PI e Adaptativo aplicado ao

- processo de fabricação de papel reciclado utilizando a ferramenta Delta Tune. 2009. 91 f. Dissertação(Mestrado em Engenharia Elétrica)-Universidade Estadual de Londrina, Londrina, 2009.
- TAKAGI, T. e SUGENO, M. (1985). Fuzzy Identification of Systems and Its Applications to Modeling and Control.IEEE Transactions on Systems, Man and Cybernetic.v.15, n.1, p 116-132, 1985.
- SHAW, IAN S. e SIMÕES, M. G. Controle e Modelagem Fuzzy. FAPESP, Editora Edgard Blücher LTDA, 1999.
- MANDANI, E. H. (1974). Application of fuzzy algorithms for simple dynamic plant.Proceedings of Institute of Electrical Engineering.v.121, p 1585-1588.
- ZADEH, L. A. (1965). Fuzzy Sets.Information and Control. v. 8, n. 3, p 338-353, 1965.
- GOODHART, S. G., BURNHAM, K. J. e JAMES, D. J. (1991).Bilinear self-tuning control of a high temperature heat treatment plant.IEEE Proceedings – Control Theory and Applications.v. 141, n. 1, p 13-18, 1991.
- SILVA, G., DATTA, A. e BHATTACHARYYA, S. (2002). New results on the synthesis of PID controllers.IEEETransactionsonAutomaticControls. v. 47, n. 2, p 241-252, 2002.
- FIGUEIREDO, L. e JOTA, F. (2004). Implementação de técnicas de controle adaptativo ao resfriamento de tiras a quente. In Anais do XV Congresso Brasileiro de Automática. p 1-6, 2004.
- HORIUCHI, J. I. e KISHIMOTO, M. (2004). Application of fuzzy control to industrial bioprocess in Japan.Fuzzy Sets and Systems.v. 128, n. 1, p 117-124. 2004.
- BONISSONE, P. P., BADAMI, V., CHIANG, K. H., KHEDKAR, P. S., MARCELLE, K. W. e SCHUTTEN,M. J. (1995). Industrial applications of fuzzy logic at General Eletric.Proceedings of theIEEE.v.38, n. 3, p 450-465, 1995.
- ONOFRE FILHO, M. P. Lógica Fuzzy para Controle de Ph em um Processo Petrolífero. 2011. 67 f. Dissertação(Mestrado em Ciências de Engenharia Elétrica e Computação)-Universidade Federal do Rio Grande do Norte, Natal. 2011.
- TANOMARU, J. (1995). Motivação, fundamentos e aplicações de Algoritmos Genéticos. II Congresso Brasileiro de Redes Neurais, 1995.