

OTIMIZAÇÃO DA ESTRATÉGIA DE CONTROLE VIA COMPUTAÇÃO EVOLUTIVA

Joselmo Sangi Tomaz

joselmo@ufsj.edu.br

Valceres Vieira Rocha e Silva

vrslva@ufsj.edu.br

Laboratório de Sistemas e Sinais

Departamento de Engenharia Elétrica

Universidade Federal de São João del Rei

Resumo

O processo químico Continuous Stirred Temperature Reactor (CSTR), é uma planta não linear e apresenta três pontos de operação, sendo um deles instável. Foi submetido a duas estratégias de controle, uma proporcional, integral e derivativa (PID) e outra H^∞ . O algoritmo genético (AG) foi responsável por sintonizar e otimizar os parâmetros dos controladores e pela escolha da estratégia de controle que melhor atendeu às especificações de desempenho do processo. O AG é uma técnica de computação evolutiva que tem se mostrado eficiente na busca de ótimos globais em sistemas complexos.

Palavras-Chave: CSTR, PID, H^∞ , algoritmo genético, otimização.

Abstract

The Continuous Stirred Temperature Reactor (CSTR) is a chemical non linear process that has three operating points; one of them unstable. Two different strategies were applied to control this plant: proportional, integral and derivative (PID) and H-infinity strategies. The controller parameters for the two controllers were tuned and optimized on-line with the working plant by a genetic algorithm. The control strategy that obtained best solution for each one of the operating points was chosen for that operating point. The genetic algorithm is an evolutionary computing technique that has shown to be efficient on global optimal search of controller designs for complex systems.

Key words: CSTR, PID, H-infinity, genetic algorithm, optimization.

I. INTRODUÇÃO

Tem havido um crescimento considerável na engenharia pela evolução tecnológica, e tal evolução tem levado profissionais a procurarem processos melhores e mais eficientes. Nessa procura, a ferramenta conhecida por modelagem de sistemas possui uma especial importância, pois é através dos modelos matemáticos que se analisa e prevê comportamentos de um sistema.

O modelo deve ser capaz de refletir o comportamento do sistema original da melhor maneira possível, pois, em caso contrário, todos os esforços aplicados no modelo serão desperdiçados. Os bons modelos para a representação do sistema em estudo são aqueles que descrevem os fenômenos reais com uma considerável exatidão. Aliado a essa procura, os sistemas industriais têm buscado sistemas de controle capazes de proporcionar pontos de operação ótimos, ou seja, sistemas mais eficazes, autônomos e robustos.

Uma grande quantidade de técnicas é disponível para projetar sistemas de controle modernos. Entretanto, apesar desta grande variedade de técnicas e também de ferramentas computacionais disponíveis para dar suporte ao projeto, a habilidade de selecionar a técnica mais apropriada para um problema particular, e também aplicá-la de forma eficaz, é ainda um trabalho árduo, mesmo para problemas relativamente simples (SILVA, 1999).

Como determinar a melhor configuração e estrutura do sistema de controle para uma determinada aplicação, e como resolver a natureza multiobjetiva das especificações dos sistemas de engenharia de controle reais são problemas do projeto de sistemas de controle que motivam o desenvolvimento de estruturas de projeto baseadas em otimização para procurar por soluções com carga computacional menor (SKOGESTAD e POSTLETHWAITE, 1996). Dos anos 70 em diante, a progressiva implementação destas técnicas vem ao encontro de uma tentativa de eliminar ao máximo possível as incertezas geradas na modelagem das plantas ou dos processos industriais, o que tem melhorado o projeto de sistemas de controle baseados tanto em técnicas modernas como em técnicas do controle clássico (CAVALCANTI *et al.*, 1999; COELHO e COELHO, 1999).

O sistema utilizado para este estudo foi um processo químico CSTR diabático, não linear, com uma reação irreversível de primeira ordem exotérmica. Este processo tem um comportamento dinâmico em malha aberta, muito variável devido à sensibilidade paramétrica,

vários pontos de operação e oscilações sustentadas. O processo foi submetido a duas estratégias de controle *on-line*, o controle proporcional, integral e derivativo (PID) e um controle robusto H^∞ .

Atualmente mais da metade dos controladores industriais em uso utilizam a estratégia de controle PID. O controle PID possui uma realimentação que proporciona ao sistema uma medida do sinal de erro; esse sinal é enviado para o atuador, e este atua na planta de forma a corrigir a saída para que esta siga exatamente a entrada de referência.

Do ponto de vista do controle H^∞ , a robustez pode ser associada com estabilidade robusta e/ou performance. Estabilidade robusta está relacionada com a preservação da estabilidade na presença de erros de modelagem e variações de parâmetros. Robustez de performance está relacionada com a preservação do desempenho, mesmo com erros de modelagem e variações de parâmetros.

Uma medida de robustez seria o *tamanho* máximo da perturbação que pode ser tolerado pela planta, ainda que garantindo estabilidade. Técnicas de controle robusto tais como H^∞ permitem inclusão de incertezas.

Uma abordagem interessante para o problema de otimizar um sistema de controle é a computação evolutiva (EC) (FONSECA e FLEMING, 1995). As técnicas EC são métodos de pesquisa estocásticos e inspirados no princípio da seleção natural. Algoritmos evolutivos atuais incluem Programação Evolutiva, Estratégia de Evolução, Algoritmos Genéticos e Programação Genética. Comparando-se com métodos tradicionais de otimização, tais como os baseados em cálculos e estratégias enumerativas, os AG's são robustos, globais e geralmente mais simples de serem aplicados em situações onde exista pouco ou nenhum conhecimento *a priori* do processo a ser controlado.

O algoritmo genético é um método global de procura estocástica, que se baseia na evolução natural da teoria de Darwin. Os AGs operam em uma população de possíveis soluções aplicando o princípio da sobrevivência dos mais fortes nos testes de adaptação dos indivíduos para produzir melhores soluções a cada geração.

AG tem sido aplicado em várias formas de engenharia de controle (SILVA, 1999). Aplicações *off-line* de GA têm sido empregadas para selecionar leis de controle convenientes para satisfazer critérios de desempenho dados, ou procurar por parâmetros ótimos para controladores em motores. Aplicações *on-line* de AG têm sido tais como mecanismos de aprendizado para identificar características de sistemas desconhecidos ou não estacionários, ou para sintonia de controladores adaptativos de plantas conhecidas ou não.

Algumas aplicações de AG em controle são: projeto de sistemas de controle, controle robusto, otimização multiobjetiva, identificação de sistemas, integração de sistemas e controle adaptativo e de tempo real (por exemplo: JONES e LIN, 1998; CHIPPERFIELD e FLEMING, 1995; LINKENS e NYONGESA, 1996).

II. ALGORITMO GENÉTICO

O mecanismo básico de um AG é uma procura paralela em que soluções em uma iteração ou geração sofrem um número de transformações de forma a obter soluções melhores na próxima geração. O AG normalmente trabalha com uma população de pontos ou soluções e leva esta população a um melhoramento, encorajando a reprodução e repartindo os bons atributos entre os vários membros da população. Tende a ser conveniente como uma metodologia de pesquisa e otimização para problemas que são difíceis para algoritmos tradicionais baseados em derivadas e outros métodos.

Os AG's são robustos e eficientes na busca e otimização em espaços de soluções irregulares, multidimensionais, complexos e multimodais. De um modo geral, os AG's apresentam as seguintes características (GOLDBERG, 1989):

- Atuam num espaço de busca de soluções codificadas e não no espaço de busca diretamente.
- Operam em uma população de pontos e não em um ponto isolado. Isso reduz a possibilidade de se encontrarem falsos pontos ótimos.
- Usam informações de otimização do problema baseada numa função objetivo.
- Não requerem derivações do sistema ou qualquer outro conhecimento auxiliar; necessitam apenas da função objetivo.

Um AG começa pela criação de uma população de possíveis soluções que é composta de um conjunto de indivíduos de tamanho estabelecido. Os indivíduos desta população são codificados em uma cadeia, os quais são referidos como genótipos ou cromossomos. A representação mais comumente utilizada desta cadeia cromossômica é a representação binária {0,1}. Porém, são usuais outras representações como, por exemplo, representação inteira, real,

etc. Independente da representação cromossômica utilizada no AG, o procedimento básico para otimização será o mesmo em cada iteração. Os indivíduos são escolhidos com base na habilidade de adaptação dos progenitores e seus descendentes, os quais constituirão a nova geração de indivíduos da população. Seja esta uma representação binária ou real, ambos utilizarão os mesmos operadores básicos: criação da população inicial, avaliação da função objetivo, seleção, recombinação e mutação.

III. O PROCESSO CSTR

O processo em estudo é um reator químico CSTR diabático, não linear, com uma reação irreversível de primeira ordem exotérmico. Este processo tem um comportamento dinâmico em malha aberta muito variável devido à sensibilidade paramétrica, possui vários pontos de operação e oscilações sustentadas. O equilíbrio de massa e energia gera as equações para o problema, na forma adimensional (DERMICAN *et al.*, 1999; RUSSO, 1996).

$$\frac{d}{d\tau} x_1 = -\phi x_1 k(x_2) + q(x_{1f} - x_1)$$

$$\frac{d}{d\tau} x_2 = \beta \phi x_1 k(x_2) - (q + \delta)x_2 + \delta m + q x_{2f}$$

$$k(x_2) = \exp\left(\frac{x_2}{1 + \frac{x_2}{\gamma}}\right)$$

Onde:

x_1 é a concentração adimensional,

x_2 é a temperatura adimensional (variável controlada),

m é a temperatura do invólucro de resfriamento adimensional (variável manipulada),

$k(x_2)$ é uma função adimensional e os valores dos parâmetros são apresentados na tabela 1.

A tabela 2 traz os valores das variáveis x_1 e x_2 em regime estacionário.

Tabela 1: Valores dos parâmetros nominais para o processo

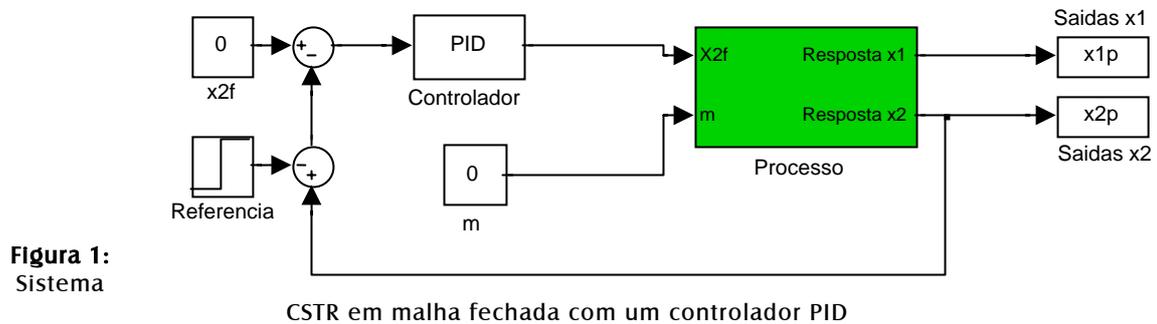
β	ϕ	δ	γ	q	x_{1f}	x_{2f}
8,0	0,072	0,3	20,0	1,0	1,0	0,0

Tabela 2 - Pontos de operação

	1°	2°	3°
x_{1s}	0,8560	0,5528	0,2354
x_{2s}	0,8859	2,7517	4,7050
m	0	0	0

Baseado na dinâmica e nas equações que modelam o sistema, foi implementado um modelo em malha aberta utilizando o *software* SIMULINK do MATLAB™ de programação visual, tornando fácil tanto o entendimento quanto a manipulação das variáveis. Também torna possível observar os resultados da simulação do processo em tempo real.

Uma vez modelada em malha aberta, a variável controlada foi realimentada e as características do sistema em malha fechada sem o controlador foram obtidas. No sistema realimentado, foram inseridos os controladores (Figura 1), o sistema se comportou de maneira diferente para os dois tipos de controladores.



O mesmo modelo foi utilizado para o controlador H_∞ no intuito de assegurar que o modelo do sistema controlado apresentasse a mesma dinâmica (THOMAZ e SILVA, 2000).

IV. DEFINIÇÃO DA ESTRATÉGIA DE CONTROLE

Como os algoritmos genéticos não requerem informação de derivadas ou uma estimativa inicial da região de soluções, e também devido à natureza estocástica do mecanismo de busca, são capazes de pesquisar por todo o espaço de soluções com uma grande possibilidade de achar um ótimo global em lugar de uma solução local.

O algoritmo genético foi utilizado na determinação da estratégia ótima de controle e na otimização dos parâmetros de cada controlador para os três pontos de operação do sistema, utilizando os resultados já obtidos de análises dos limites físicos, das condições de operação da planta e da identificação das especificações de desempenho, que definiram os objetivos e restrições a serem impostos ao problema.

A estrutura empregada neste trabalho para o algoritmo genético tem as seguintes finalidades: otimizar as funções de peso do pré e pós-compensador de um controlador H_∞ e otimizar os parâmetros dos controladores PID, penalizar os indivíduos de ambas as estratégias de controle que não atenderem às especificações de desempenho do sistema e, por fim, escolher a melhor estratégia de controle para cada ponto de operação.

V. RESULTADOS

O algoritmo genético penaliza os indivíduos de cada uma das estratégias de controle, no intuito de encontrar o indivíduo que atende aos seguintes requisitos: minimizar o erro em regime permanente, minimizar sobressinal, minimizar tempo de acomodação e minimizar o tempo de subida.

A função penalidade é descrita como segue:

```
if tx_ovs > txovs
    ovsh = 800*(exp(tx_ovs) + punição);
end
if tx_sett > txsett
    sett = (25*exp(tx_sett) + punição);
end
if tx_riset > txriset
    riset = (exp(tx_riset) + punição);
```

Se o indivíduo obtiver taxas de sobressinal, tempo de subida e tempo de acomodação menores que a estabelecida no processo, o algoritmo genético penalizará o indivíduo, piorando, assim, sua classificação. A proporção de penalização para cada especificação não é igual, devido à importância de determinadas variáveis.

A tabela 3 mostra os parâmetros do AG elaborados para escolha e otimização dos controladores.

Tabela 3 - Parâmetros do AG para projeto do controlador

Parâmetros do AG	
Número de alelos por variável a ser otimizada	32
Número de indivíduos	20
Número de gerações	10
Método de seleção	SUS
Método de recombinação	<i>Single-point</i>
Taxa de recombinação	90%
Taxa de mutação	1%

As figuras 3-5 mostram as respostas do sistema quando sujeito às duas estratégias de controle, com os parâmetros dos controladores já otimizados.

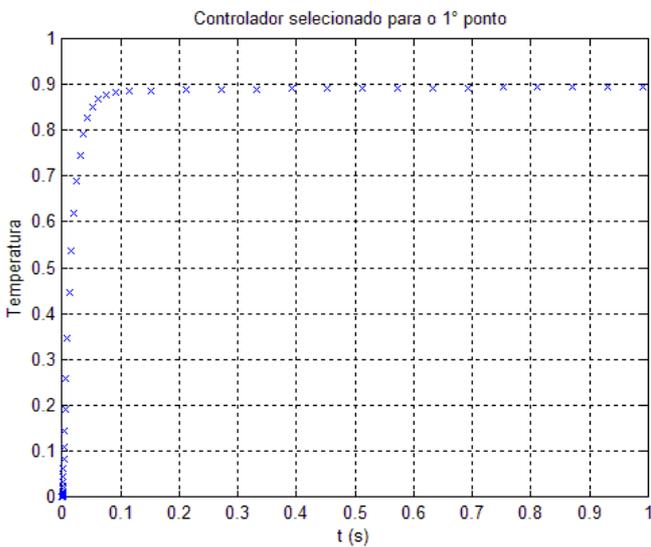
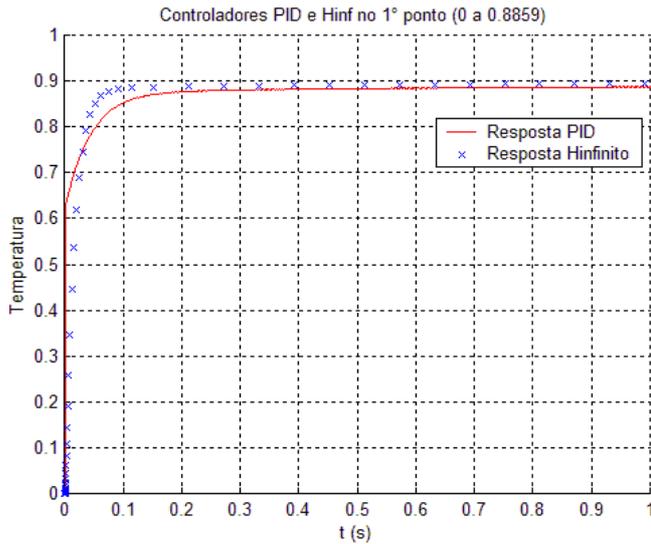
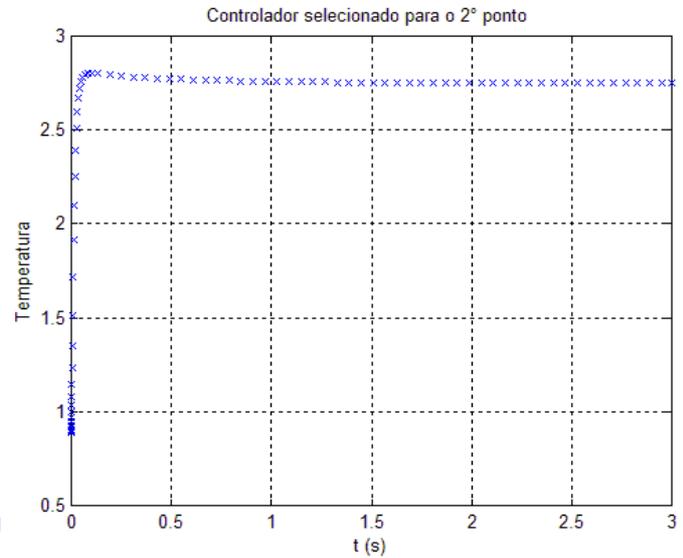
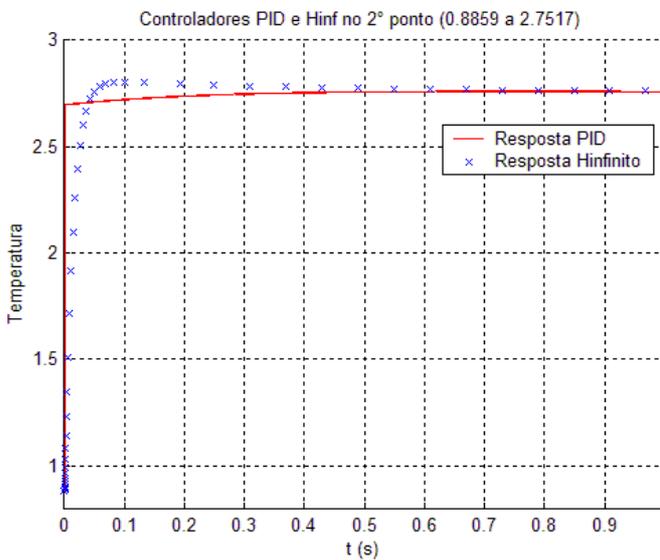


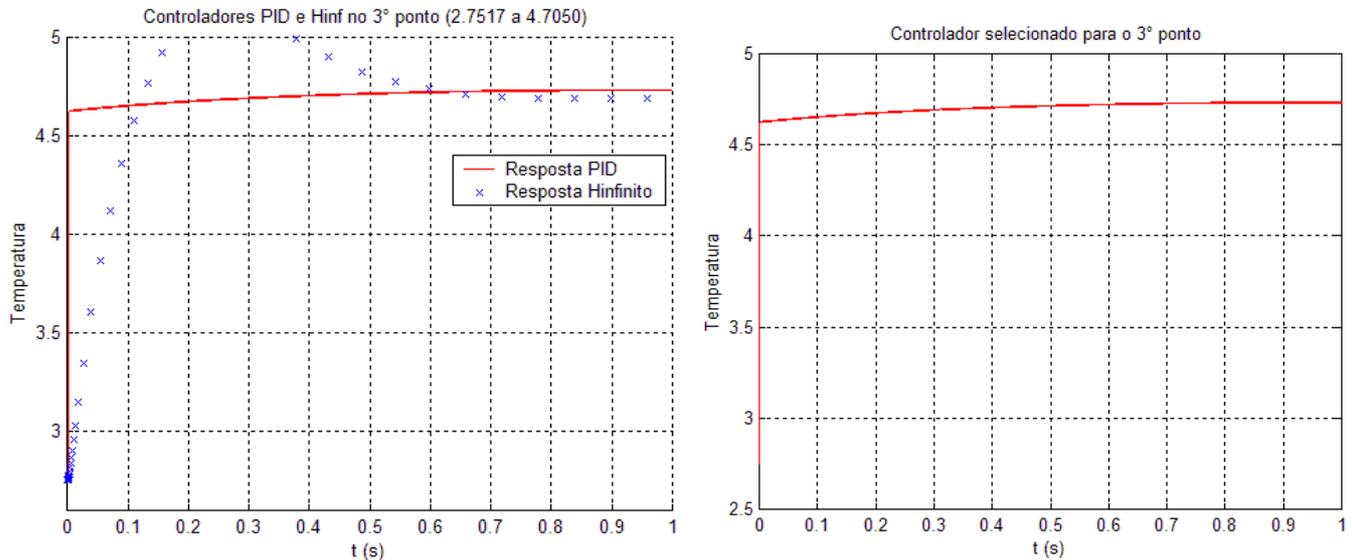
Figura 3(a) e 3(b): (a)Resposta do sistema para o 1º ponto de operação (b)Controlador selecionado.

Pode-se observar que o modelo com o controlador H^∞ obteve um melhor desempenho para este primeiro ponto de operação, já que o PID obteve um alto tempo de acomodação.



Figuras 4(a) e 4(b): (a)Resposta do sistema para o 2º ponto de operação (b)controlador selecionado.

Para o 2º ponto de operação, o modelo com controlador H^∞ mostrou-se mais eficaz do que para o controlador PID.



Figuras 5(a) e 5(b): (a)Resposta do sistema para o 3º ponto de operação (b)Controlador selecionado.

Para o 3º ponto de operação, pode-se observar que o modelo com o controlador H^∞ obteve um sobressinal mais elevado e foi, então, pior classificado que o controlador PID.

VI. CONCLUSÃO

O AG mostrou-se uma poderosa ferramenta na determinação e otimização dos parâmetros de controladores devido a sua facilidade de implementação e robustez no tratamento do espaço de busca. Neste trabalho, o sistema utilizado é não linear e instável em um de seus pontos de operação.

Observando as respostas do processo obtidas com os dois controladores, pode-se concluir que as especificações de desempenho foram atendidas. Porém, este estudo foi feito considerando-se um sistema em condições ideais e isento de ruídos, o que não é uma realidade em sistemas reais. A escolha da estratégia de controle que continha o indivíduo que melhor atendeu às especificações foi realizada com sucesso pelo algoritmo de penalização.

A determinação de parâmetros do controlador, tais como taxas de mutação e de reprodução, é feita através de um processo puramente heurístico de tentativa e erro. Também a elaboração de uma função de penalização para quebra de objetivo e restrições pode ser facilitada à medida que um maior conhecimento do problema for adquirido.

A escolha da estratégia de controle PID foi devida a sua simplicidade de implementação. A outra estratégia empregada, denominada H^∞ , foi utilizada com o objetivo de minimizar incertezas paramétricas do modelo e gerar um controle robusto para o sistema, além de permitir ao processo a possibilidade de operar o mais próximo possível do ponto ótimo.

X. REFERÊNCIAS

CAVALCANTI, J. H. F.; ALSINA P. J.; FERNEDA, E. Posicionamento de um pêndulo invertido usando Algoritmos Genéticos. **SBA**, v. 10, p. 31-38, Jan./Fev./Abril, 1999.

CHIPPERFIELD, A. J.; FLEMING, P. J. Gas turbine engine controller design using multiobjective genetic algorithms. In: IEE/IEEE - INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS IN ENGINEERING SYSTEMS: INNOVATIONS AND APPLICATIONS (GALESIA' 95), 1st, 1995. Sheffield, UK. **Proceedings...** Sheffield, UK, 1995. p. 214-219.

COELHO, L. S.; COELHO, A. A. R. Algoritmos evolutivos em identificação e controle de processos: uma visão integrada e perspectivas. **SBA**, v. 10, pp. 13-30 Jan./Fev./Abril, 1999.

DERMICAN, M.; ÇARMUDAN, M. C.; POSTLETHWAITE, B. E. On-line learning fuzzy relational model based dynamic matrix control of an openloop unstable process. **Trans. IchenE**, 77 (part. A), pp. 421-428, 1999.

FONSECA, C. M.; FLEMING, P. J. An overview of evolutionary algorithms in multiobjective optimization. **Evolutionary Computing**. v. 3, n. 1, p. 1-16, 1995.

GOLDBERG, D.E. **Genetic algorithms in search**, optimisation and machine learning. Reading. Massachusetts: Addison-Wesley, 1989.

JONES, A. H.; LIN, Y. C. MIMO robustness analysis of digital control systems using genetic algorithms. In: INTERNATIONAL CONFERENCE ON CONTROL' 98 (UKACC' 98) **Proceedings...** Swansea, UK, IEE Conference Publication N°. 455, Vol. 2, pp. 263-268, 1998.

LINKENS, D. A.; NYONGESA, H. O. Real-time acquisition of fuzzy rules using genetic algorithms. In: INTERNATIONAL SYMPOSIUM ON ARTIFICIAL INTELLIGENCE IN REAL-TIME CONTROL (AIRTC' 92) Verbruggen, H. B. and Rood, M. G., Delft, The Netherlands, 1992. p. 335-339.

RUSSO JR, L. P. **Bifurcation behavior of an exothermic CSTR**. PhD thesis, Rensselaer Polytechnical Institute, Troy, New York, Estados Unidos da América, 1996.

SILVA, V. V. R. **Multivariable control systems design using evolutionary computing**. 1999. Tese de PhD. Inglaterra: University of Sheffield, 1999.

SKOGESTAD, S.; POSTLETHWAITE, I. **Multivariable feedback control analysis and design**. Chichester, UK: John Wiley & Sons Ltd., 1996.

THOMAZ, V. O.; SILVA, V. V. R. Projeto de um controlador para um processo químico não linear. In: SEMINÁRIO DE INICIAÇÃO CIENTÍFICA, 8., 2000. **Local? Anais... Local: entidade organizadora**, (2000). p. 69.