

DESENVOLVIMENTO DE UM MODELO DE INFERÊNCIA UTILIZANDO PROGRAMAÇÃO GENÉTICA

MARCOS A. E. VANGELISTA, F. LÁVIO NEVES JR., H. EITOR S. L. OPES

CPGEI, CEFET - PR

Av. Sete de Setembro, 3165, 80230 - 901, Curitiba, PR, BRASIL

E-mails: { evange, neves, hslopes }@cpgei.cefetpr.br

Resumo—Em processos químicos, variáveis inferenciais são usadas no lugar de medidas de variáveis controladas principalmente em processos onde a mediada direta representa custos elevados, falta de confiabilidade e atrasos significantes. O presente trabalho investiga o desenvolvimento de um modelo de inferência do tipo GLP (gás líquido feito de petróleo) baseado no paradigma de programação genética. Os resultados mostram que o modelo inferencial obtido fornece melhores resultados quando comparado com modelos lineares ou racionais.

Abstract—Inferential variables are often used in chemical process industries in place of direct measurements of controlled variables. They are mainly used in processes where direct measurements are expensive, unreliable and add significant delay. This work investigates the development of an inferential model based on the Genetic Programming Paradigm (GP). Genetic Programming performs symbolic regression, determining both the structure and the complexity of the model during its evolution. The results show that the obtained model gives a good estimation capacity when compared to linear and rational models, and it also has the advantage that no prior modeling assumptions are necessary.

Keywords—Inferential Models, Genetic Algorithms, Chemical Processes, Distillation Column.

1 Introdução

A obtenção de medidas confiáveis da composição dos produtos de uma coluna de destilação constitui-se na principal dificuldade para o controle e otimização de este tipo de equipamento. Muitos analistas de produto, como os cromatógrafos gasosos, apresentam atrasos notáveis de resposta além do alto custo de manutenção e dos grandes investimentos necessários para sua instalação. O atraso global não tem poder de resposta de uma medida situada tipicamente entre 10 e 20 minutos (Mejdelle Skogestad, 1991). Este fato impõe severas limitações ao desempenho do sistema de controle e otimização associados ao equipamento. Entretanto, a confiabilidade das análises é talvez o ponto mais crítico.

Para se obter um resultado confiável nas análises de composição feitas neste tipo de equipamento, faz-se necessário um grande dispêndio de recursos, em termos de força de trabalho e na obtenção e manutenção de uma base de dados conveniente para o sistema. A utilização de um modelo inferencial do processo apresenta-se como uma ferramenta importante para a solução de este tipo de problema (Easterday, 1973).

Nos últimos anos, a literatura tem registrado a presença de muitos modelos para a inferência de variáveis importantes de processos a partir de variáveis facilmente mensuráveis.

Como propósito de melhorar o desempenho dos modelos baseados em uma única temperatura, Tolliver e McCune (1980) propuseram um método baseado na sensibilidade da temperatura dos pratos frente a variação da composição da alimentação, ou do calor de refluência ou do refluxo. O critério utilizado para a escolha tem como princípio a seleção do prato

no qual a temperatura apresenta a mais forte correlação com a composição do produto para as diversas perturbações na coluna.

Moore et al (1986) apresentaram um método baseado na aplicação da análise de componentes principais (PCA). Este método seleciona a temperatura do prato com maior variância para um conjunto particular de dados. Perturbações no calor de refluência ou do refluxo foram utilizadas para o levantamento do conjunto apropriado de dados.

A escolha da temperatura do prato com maior variância produziu bons resultados na estimativa da composição dos produtos. Porém, esta heurística, escolhida a temperatura do prato de maior variância, pode resultar em modelos adequados em alguns casos.

Brosilow e colaboradores (Webber e Brosilow, 1972; Joseph e Brosilow, 1976, 1978) foram os primeiros pesquisadores a sugerir o uso de modelos inferenciais empíricos com múltiplas variáveis para inferir a composição dos produtos em colunas de destilação. O modelo proposto baseia-se na combinação linear de diferentes variáveis de processo e inclui uma técnica para a seleção das temperaturas dos pratos com melhor poder preditivo. A utilização de este modelo na simulação do controle de uma coluna de destilação multicomponte mostrou que o controle produzido com um modelo inferencial deste tipo é comparável ao produzido com a mediada direta da composição. Seguindo este raciocínio, diversos trabalhos sugerindo o desenvolvimento de modelos inferenciais empíricos utilizando múltiplas variáveis foram publicados.

Choo e Saxena (1987) desenvolveram um modelo inferencial empírico para a estimativa da composição de topo e de fundo de uma coluna de destilação extrativa. O modelo desenvolvido baseou-se na regressão linear dos dados históricos do processo. As variáveis inferenciais mais utilizadas no modelo

foram pressão e temperatura em quatro diferentes pratos. As temperaturas dos pratos mais convenientes para o modelo foram obtidas através da análise de sensibilidade para variação no perfil de composição.

Mejdelle Skogestad (1991) foram pioneiros na utilização dos métodos da Regressão do Componente Principal (PCR) e da Projeção de Estruturas Latentes (PLS) no desenvolvimento de modelos empíricos para colunas de destilação. Eles propuseram o uso de transformações logarítmicas nas composições e temperaturas para representar a não linearidade do processo.

Kresta e McGregor (1994) aprofundaram os estudos feitos por Mejdelle Skogestad na aplicação do método PLS no desenvolvimento de modelos inferenciais para colunas de destilação. Neste trabalho eles enfatizam as habilidades do método em lidar com problemas típicos do desenvolvimento de modelos inferenciais como, por exemplo, o ajuste causado pela utilização de variáveis fortemente correlacionadas.

Uma questão importante a ser observada em relação aos modelos multivariáveis anteriormente relatados é que todos eles são modelos lineares. Uma vez que o processo de destilação apresenta relação não-linear entre suas variáveis, fazem-se necessárias transformações convenientes nas variáveis como intuito de melhorar o desempenho destes modelos. Destemodo, o sucesso na aplicação de um modelo deste tipo está intimamente relacionado à experiência adquirida com o relacionamento específico do processo estudado, não podendo, portanto, ser facilmente aplicada por um profissional menos experimentado.

A maior parte dos modelos propostos baseia-se na representação linear das relações entre diversas variáveis do processo. Estes modelos podem produzir resultados imprecisos, em alguns casos, principalmente pelo fato de a relação entre as variáveis nestes processos ser altamente não-linear. Por outro lado, modelos baseados na representação não-linear das relações entre as diferentes variáveis do processo apresentam um sério inconveniente: a dificuldade associada à determinação dos parâmetros do modelo. Como exemplo podem ser citados os modelos baseados em funções polinômiais multivariáveis e redes neurais.

Atualmente a literatura aponta para os promissores resultados obtidos com a utilização de Algoritmos Evolutivos na modelagem de processos não lineares (McKaye Willis, 1997; Coelho e Coelho, 1999). Esta contribuição descreve um novo método de aproximação que oferece uma alternativa útil para metodologias de modelagem baseadas em dados populares.

Está nova metodologia utiliza técnicas de Programação Genética (Koza, 1994) para realizar:

- Seleção de entradas do modelo de processo.
- Seleção da estrutura do modelo de processo.
- Identificação de parâmetros.

2 Programação Genética

A performance de um organismo individual no seu ambiente determina a probabilidade de passar o seu material genético para futuras gerações. Este princípio biológico básico é conhecido como o processo de Darwin, e inspirou uma classe de algoritmos conhecidos como algoritmos genéticos (AG). Os AGs tentam encontrar a melhor solução para um problema imitando o processo evolutivo da natureza. Assim, um algoritmo típico reproduzirá uma população de indivíduos que representam possíveis soluções para um problema particular. Infelizmente, enquanto os AGs têm provado ser uma técnica útil para a solução de um vasto domínio de problemas, eles não são apropriados para problemas de regressão simbólica onde a estrutura e os parâmetros do modelo são determinados simultaneamente. Claramente este método é inadequado para regressão simbólica, onde a estrutura do modelo varia durante a evolução. Entretanto, Programação Genética (PG) utiliza o desenvolvimento eficiente de estruturas de dados para a geração de expressões simbólicas direcionando a determinação simultânea da estrutura e complexidade requerida pelo modelo durante o processo evolutivo (McKaye Willis, 1997; Coelho e Coelho, 1999). Programação Genética difere de Algoritmos Genéticos pela utilização das seguintes estruturas:

1. Estrutura de árvore cromossomos de comprimento variável.
2. Cromossomos codificados de acordo com a maneira do problema ao invés de string binário, por exemplo.
3. Operadores genéticos que preservam a *syntax* da estrutura de árvore durante a reprodução.

Um número de resultados recentes tem demonstrado o potencial de aplicabilidade da Programação Genética no campo de engenharia de processos. Por exemplo, PG tem sido adotada para aproximar a resposta a impulso de um sistema linear invariante no tempo (Koza, 1993). Em outra aplicação, Iba et al (1993) usou PG para aproximar uma série de predições para um sistema caótico. Zang & Muhlenbein (1993) usaram PG para otimizar os pesos e arquitetura de uma rede neural tipo *feedforward*. Os resultados indicaram que fornecidos recursos suficientes, a metodologia pôde determinar redes com complexidade minimizada. Porém, ao invés de manipular estruturas de redes neurais, existe o potencial para descobrir mais informações sobre as características de processos pelo uso direto de regressão simbólica.

2.1 Descrição do Algoritmo

O primeiro passo na implementação da PG é a definição de um conjunto de determinais. Em outras palavras, quando se envolve um modelo matemático de processo é necessário fornecer as variáveis de entrada que se acreditam ter relação com a saída. Em adição, o algoritmo de vetera

habilidade para gerar constantes, pois geralmente a combinação de valores de entrada e constantes numéricas é que produz o modelo de regressão requerido. É também necessário definir um conjunto de funcionais. Este é o conjunto de operadores aritméticos e funções matemáticas que o algoritmo pode usar quando estiver construindo a solução potencial para o problema proposto. Tipicamente, o conjunto de funcionais inclui operadores aritméticos tais como adição, multiplicação, e funções matemáticas comuns como, por exemplo, raiz quadrada, funções logarítmicas, trigonométricas e exponenciais. É importante assegurar que cada funcional tenha a propriedade de fechamento. Isto é, tem que ser apto a retornar um valor numérico quando submetido a um valor de entrada. A função raiz quadrada não possui esta propriedade se submetida a um valor negativo. Desta forma, para assegurar a propriedade de fechamento, o valor absoluto da entrada deve ser tirado antes da avaliação.

2.2 Avaliação da Função de Fitness

O Fitness é um valor numérico que é avaliado em cada membro da população fornecendo uma medida de adequação da solução do problema em questão. A função de fitness (Koza, 1992) é geralmente baseada sobre o erro entre a solução atual e a predita. Conforme demonstra a Equação 3, o fitness é a soma realizada sobre o conjunto de pontos fornecidos, do valor absoluto da diferença entre o valor da variável dependente produzida pelo algoritmo e o valor real da variável dependente. Uma vez a função de fitness de cada indivíduo tem sido determinada, a mesma é usada como base para a seleção de membros para a próxima população. Neste trabalho foi utilizado o fitness ajustado para a avaliação dos indivíduos conforme Equação 1.

$$a(i, t) = \frac{1}{1 + s(i, t)} \quad (1)$$

sendo $s(i, t)$ o fitness padronizado,

$$s(i, t) = r_{\max} - r(i, t) \quad (2)$$

e $r(i, t)$ o raw fitness,

$$r(i, t) = \sum_{j=1}^{N_c} |S(i, j) - C(j)| \quad (3)$$

onde, $S(i, j)$ é o valor retornado pela expressão i para o fitness case j (a partir de N_c cases) e $C(j)$ é o valor correto para o fitness case j .

2.3 Estratégias de Seleção

Um número de métodos de seleção tem sido sugerido na literatura. Estes incluem estratégia elitista, torneio e fitness proporcional. No esquema elitista, a população é classificada em ordem decrescente de acordo com o valor de fitness individual. Um número M de melhores indivíduos da população atual (sendo $M \leq N_c$) irá ser reproduzido para gerar a próxima. A seleção por torneio envolve amostras randômicas

(com substituição) de um número fixo de indivíduos da população atual para formar uma subpopulação. Os melhores indivíduos desta subpopulação (relativamente pequeno) são então escolhidos para reprodução, e o processo repete-se conforme solicitado. Com a seleção usando fitness proporcional, um indivíduo é amostrado a partir da população atual (novamente com substituição) com uma probabilidade proporcional ao seu fitness de ser escolhido para aplicação de operadores genéticos. Não se sabe ao certo qual das estratégias de seleção é considerada ótima.

2.4 Aplicação de Operadores Genéticos

Umavez o indivíduo tem sido selecionado a partir da população atual, três operadores genéticos básicos (reprodução direta, crossover e mutação) podem ser aplicados. O operador de reprodução direta copia um membro da população atual para a próxima geração. O operador genético de crossover pega dois membros da população, realiza uma combinação entre eles para criar um novo indivíduo. O operador de mutação cria um novo indivíduo através de alteração randômica de um único membro da população. Não há necessidade de futuras explicações para o operador de reprodução direta. Entretanto, uma discussão mais detalhada sobre os operadores de mutação e crossover são apresentadas a seguir.

O papel do operador de crossover é permitir a construção de novos indivíduos a partir de outros já existentes, desta forma permitindo novas regiões do espaço de busca serem procuradas. Durante o crossover duas expressões matemáticas (membros da população existente) são randômicamente escolhidas usando uma das estratégias de seleção mencionadas anteriormente. Uma sub-árvore randômicamente selecionada a partir de um indivíduo é então permutada com outra sub-árvore escolhida randômicamente de um segundo indivíduo. Os dois novos indivíduos criados são então usados para formar a próxima geração. Em programação genética o operador de crossover não é homólogo. Em outras palavras, o ponto de crossover nas duas expressões é escolhido independentemente, diferentemente dos algoritmos genéticos onde a posição de crossover é idêntica para os cromossomos. Uma simples aplicação do tradicional crossover poderia produzir indivíduos inválidos. Desta forma, é requerido que o operador de crossover preserve a *syntax* das expressões matemáticas originais. Os indivíduos produzidos são diferentes dos pais que os originaram (dois indivíduos da geração atual). Contudo, eles são criados inteiramente a partir do material genético dos pais. Intuitivamente, se um pai representa uma solução razoável do problema, então pode ser esperado que sub-árvores contendo informações relevantes a uma solução aceitável.

O papel do operador de mutação é manter a diversidade da população, portanto reduzindo o risco de convergência prematura (porém pobre). Este operador permite a introdução de elementos na

população a partir de conjuntos de funcionais e terminais que tenham sido perdidos através da evolução, ou quando não existiam na população inicial. Mutações consistem em mudanças randômicas de um funcional, entrada ou constante em algumas expressões matemáticas, repondo a presente população. Uma vez que um membro da população tenha sido selecionado para mutação, uma das entradas, constante ou funcional presente na expressão escolhida é alterada randômicamente.

3 Inferência do Intemperismo do GLP

O objetivo deste trabalho foi desenvolver um modelo que pudesse inferir o intemperismo do gás liquefeito de petróleo (GLP) de uma coluna de debutanizadora. Nas colunas de debutanizadoras há variáveis que controlam a qualidade dos produtos de topo e de fundo são, respectivamente, o intemperismo do GLP e a pressão de vapor da nafta. Desta forma, uma coluna de debutanizadora deve operar de modo a manter o intemperismo do GLP e a pressão de vapor da nafta em quadras normais existentes. No entanto, a operação deste tipo de coluna tem mostrado que a pressão de vapor da nafta sempre satisfaz sua especificação quando o intemperismo do GLP também se encontra em quadra. Assim sendo, o simples enquadramento do intemperismo do GLP na sua especificação garante o cumprimento das especificações da pressão de vapor da nafta. Logo, o conhecimento do intemperismo do GLP é de fundamental importância na operação deste tipo de equipamento.

O intemperismo é definido como a temperatura na qual 95% em volume do produto estão volatilizados à pressão atmosférica. Os sais do intemperismo temporário têm o objetivo de controlar o teor de hidrocarbonetos mais pesados que o butano (C₅₊), que podem estar presentes no GLP. Isto se deve à necessidade de se ter um produto de fácil vaporização à pressão atmosférica.

3.1 Descrição do Processo

A coluna considerada possui 31 estágios reais e um condensador total, sendo que os estágios 1 e 31 representam respectivamente o condensador e o refeedor. A alimentação é feita no estágio 16, contando a partir do topo da coluna de debutanizadora. A carga da coluna de debutanizadora é uma mistura de GLP e nafta. O GLP é rotineiramente analisado por cromatografia. A nafta é rotineiramente analisada por destilação ASTM D-86, uma vez que análises cromatográficas das naftas são esporádicas e difíceis de se fazer. A corrente de vapor no topo é resfriada para formar um líquido (no condensado) e subsequente mente depositado num tanque de refluxo para ser bombeado para o topo da coluna. A parte remanescente é removida da coluna como produto destilado. O produto destilado é rico no componente mais volátil, no caso o GLP. Na base

da coluna, a corrente de líquido é rica no componente menos volátil, no caso a nafta. Uma corrente de líquido também é tirada do fundo da coluna, aquecida com vapor (no refeedor) e retornada à base da coluna com vapor. A Figura 1 mostra um esquema genérico de uma debutanizadora. O objetivo do controle é manter a qualidade de tanto a corrente de topo quanto a corrente de base da coluna.

Analísadores de composição podem ser usados para medir a qualidade dos produtos, porém o custo relacionado com investimento e manutenção frequentemente restringe seu uso. Entretanto, um estimador confiável pode fornecer uma alternativa barata para medidas diretas e permitir um controle consistente da qualidade dos produtos.

As especificações de projeto da coluna e as condições operacionais típicas são apresentadas na Tabela 1. Num caso de destilação, as composições dos produtos podem ser estimadas baseadas no perfil de temperatura da coluna. Entretanto, neste caso, os sensores necessários são instalados somente nos pratos 8 e 31. Como resultado a estimativa da composição pode ser apenas obtida usando-se os dois pratos.

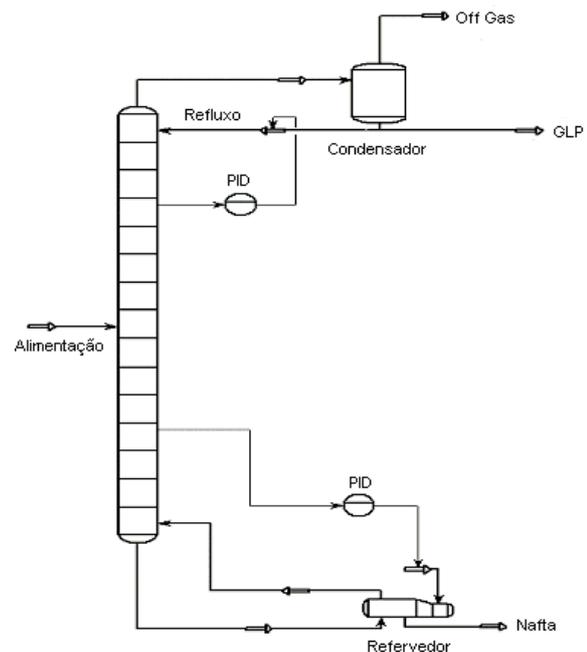


Figura 1. Esquema da Coluna Debutanizadora.

Tabela 1. Dados de Operação da Debutanizadora.

Variável	Valor	Unidade
Vazão de alimentação	1567	Kgmol/h
Temperatura de alimentação	120	°C
Vazão de destilado	600	Kgmol/h
Razão de refluxo	1.5	-
Eficiência dos pratos	0.75	-
Pressão em todos os pratos	12.0	Kgf/cm ²
Calor no refeedor	16.8	GJ/h
Temperatura de topo	47.5	°C
Temperatura de fundo	155.0	°C
Calor do condensador	24.941	GJ/h
Número de pratos	31	-
Prato de alimentação	16	-

4 Implementação

O algoritmo proposto neste trabalho foi implementado no software *LILGP versão 2* (Free Software Foundation, Inc., 1991), com interface em Java, proporcionando uma interação rápida com os dados relevantes do algoritmo, uma visualização gráfica da função de fitness durante o processo de evolução, bem como uma representação na forma de árvore da expressão matemática de melhor fitness a cada geração. Para rodar o programa, uma certa quantidade de parâmetros deve ser especificada. Contudo, durante os estudos de avaliação foi descoberto que o algoritmo é bastante robusto. Os parâmetros heurísticos usados neste trabalho e que obtiveram os melhores resultados são apresentados na Tabela 2.

Tabela 2. Aspectos de Implementação do Algoritmo.

Parâmetro	Valor
Tamanho da população	400
Probabilidade de crossover	80.0
Probabilidade de reprodução	10.0
Probabilidade de mutação	20.0
Método de geração	Ramped and random
Método de seleção	Fitness Proporcional
Conjunto de funcionais	+ - * % exp sen
Conjunto de determinais	T média(x)/Constrand
Número máximo de gerações	120
Número de simulações	100
Tempo médio por simulação	10 min

5 Resultados

O objetivo deste trabalho foi obter um modelo de inferência do tipo GLP de uma coluna de butanizador usando programação genética. Para desenvolver e validar o modelo de inferência foram gerados dados experimentais para as temperaturas de 31 e 38°C onde os sensores estavam localizados para o tipo GLP (Cavalcante, 1995). A média das duas temperaturas foi então utilizada como entrada do sistema visando obter um modelo que diluísse as perturbações localizadas ao longo da coluna. Os parâmetros de implementação podem ser encontrados na Tabela 2. O modelo final que obteve o menor erro quadrático é mostrado na Equação 4. Devido à tendência do algoritmo P-Gen gerar estruturas muito complexas para descrever a não-linearidade do processo conforme a evolução do algoritmo, o número máximo de gerações foi fixado em 120.

$$y = \frac{(1 - 0,84 \cdot \text{sen}(e^{x_e}))(-0,22 \cdot \text{sen}(-0,71x^x) - 1,13)}{e^x + 0,84 \cdot \text{sen}(e^{2x})} \quad (4)$$

onde y é o tipo GLP e x é a média da temperatura dos pratos 31 e 38°C.

O critério utilizado na avaliação do desempenho dos estimadores obtidos a partir das três metodologias foi o erro quadrático médio das previsões conforme a Equação 5.

$$MSEP = \frac{1}{40} \sum_{i=1}^{40} (y_{i_{real}} - y_{i_{est}})^2 \quad (5)$$

A Figura 2 demonstra um comparativo entre os valores do erro quadrático obtidos usando programação genética, funções racionais e mínimos quadrados para as mesmas bases de dados.

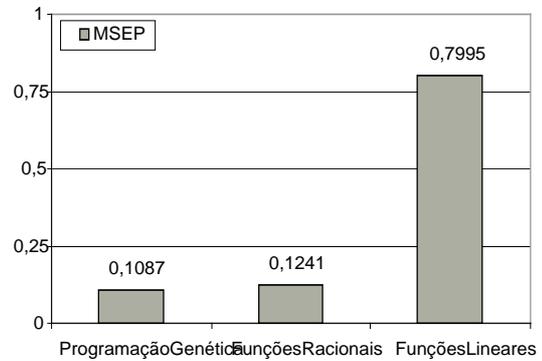


Figura 2. Erro Quadrático Obtido (MSEP).

6 Conclusão

A aplicação de programação genética para o desenvolvimento de modelos de inferência de processos químicos não-lineares foi considerada. Uma coluna de butanizador foi usada como exemplo para avaliar a capacidade de aproximação desta metodologia.

Os resultados revelam que a programação genética pode gerar um modelo de entrada-saída baseado somente na observação dos dados. Uma possível vantagem dos modelos de entrada-saída é que a identificação da estrutura do modelo não fornece detalhes fenomenológicos sobre o sistema que está sendo modelado (caixa preta). Entretanto, o modelo obtido indica claramente a relativa contribuição da entrada, médias das temperaturas, para o modo de saída, tipo GLP. Isto permite que mudanças nos valores de entrada possam ser julgadas com relativa facilidade.

O modelo de programação genética também demonstrou superioridade em relação aos modelos obtidos por funções lineares e racionais, sendo estas metodologias largamente utilizadas na obtenção de modelos de inferência. Isto demonstra que a aplicação de programação genética para obtenção de modelos de inferência é viável e com resultados bastante promissores.

Um dos maiores problemas de variáveis de entrada é fornecer resultados ainda melhores devido à adição de variância entre as variáveis de entrada e saída, fazendo com que as não-linearidades inerentes do processo possam ser representadas de forma mais íntegra.

Agradecimentos

Os autores agradecem o apoio financeiro da Agência Nacional do Petróleo do CT Petro/Financiadora de Estudos e Projetos (PRH - 10CEFET -PR).

Referências Bibliográficas

- Cavalcante, A.P. (1995). Inferência na Otimização e Controle de Colunas de Destilação via Funções Racionais. *Tese de Mestrado*, Unicamp, São Paulo.
- Choo, K.P. e Saxena, A.C. (1987). Inferential Composition Control of an Extractive Distillation tower. *Ind. Eng. Chem. Res.*, 26(12):2442 - 2444.
- Coelho, L.S. e Coelho, A.R. (1999). Algoritmos Evolutivos em Identificação e Controle de Processos: Uma Visão Integrada e Perspectivas. *SBA Controle e Automação.*, Vol.10(1):13 -30.
- Easterday, D.E. (1973) The Use of Secondary Measurements in Estimating Unmeasurable Process Outputs. *PhD. Thesis*, Case Western Reserve University.
- Iba, H. e Kurita, T. (1993). System Identification Using Structured Genetic Algorithms. *Proc. Of the 5th Int. Conf. On Genetic Algorithms*. Urbana-Champaign, USA, pp.276 -286.
- Joseph, B. e Brosilow, C.B. (1978). Inferential Control of Process. *AICHE Journal*, 24(3):485 - 509.
- Joseph, B. e Brosilow, C.B. (1976). Multi-Temps Give Better Control. *Hydrocarbon Processes*, march.
- Koza, J.R. (1993). Finding an Impulse Response Function Using Genetic Programming. *Proc. Of the ACC*, pp.2345 -2350, San Francisco, USA.
- Koza, J.R. (1992). Genetic Programming I. MIT Press.
- Koza, J.R. (1994) Genetic Programming II. MIT Press.
- Kresta, J.V., Marlin, T.E. e Macgregor, J.F. (1994). Development of Inferential Process Model Using PLS. *Computers Chem. Engng.*, 18(7) :597 - 611.
- Mckay, B. e Willis, M. (1997). Steady -state Modelling of Chemical Process Systems Using Genetic Programming. *Computers Chem. Engng.*, Vol.21(9):981 -986.
- Mejdell, T. e Skogestad, S. (1991). Estimation of Distillation Composition from Multiple Temperature Measurements Using Partial -Least-Square Regression. *Ind. Eng. Chem. Res.*, 30 (12):2543 -2555.
- Moore, C.; Hackney, J. e Canter, D. (1986). Selecting Sensor Location and Type for Multivariate Processes. *Shell Process Control Workshop*, Butterworths, Toronto.
- Tolliver, T.L. e McCune, L.C. (1980). Finding the Optimum Temperature Control Trays for Distillation Columns. *InTech.*, 75-80.
- Weber, R. e Brosilow, C.B. (1972). The Use of Secondary Measurements to Improve Control. *AICHE Journal*, 18(3):614 -623.
- Zhang, B. e Muhlenbein, H. (1993). Genetic Programming of Minimal Neural Nets Using Occam's Razor. *Proc. Of the 5th Int. Conf. On Genetic Algorithms*. Urbana -Champaign, USA, pp.342 -349.