

PROGRAMAÇÃO GENÉTICA COMBINADA COM ALGORITMO DOS MÍNIMOS QUADRADOS ORTOGONAIS APLICADA À IDENTIFICAÇÃO DE UM AQUECEDOR ELÉTRICO

Leandro dos Santos Coelho

Laboratório de Automação e Sistemas, LAS
Programa de Graduação em Engenharia de Produção e Sistemas, PPGEPS
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
leandro.coelho@pucpr.br

Resumo. A Programação Genética (GP, Genetic Programming), uma técnica heurística de otimização baseada na teoria de algoritmos genéticos, é um método bem sucedido usado para identificação de estruturas de modelos não-lineares pela análise dos sinais medidos do sistema. O problema de determinar um modelo para um sinal medido do sistema, isto é, a descoberta de relações matemáticas entre as variáveis observadas empiricamente medidas de um sistema é um importante problema em ciências térmicas. A GP habilita a identificação simultânea de modelos e parâmetros. Este artigo apresenta uma abordagem de GP combinada com algoritmo dos mínimos quadrados ortogonais para identificação de um aquecedor elétrico. O modelo matemático resultante e a análise do valor obtido para o coeficiente de correlação múltipla de Pearson entre a saída estimada e a saída real mostram a eficiência da abordagem de GP apresentada.

Palavras chave: sistema térmico, programação genética, aquecedor elétrico, identificação não-linear.

1. Introdução

A modelagem matemática, como ferramenta para reprodução do comportamento aproximado de fenômenos físicos, vem se destacando nas últimas décadas, seja para analisar as relações de causa e efeito em dados observados (Aguirre, 2004), seja para o desenvolvimento de controladores (Barroso, 2001).

Justificado pela complexidade dos modelos matemáticos não-lineares (Billings, 1980), os modelos lineares foram muito utilizados para representar o comportamento de sistemas em uma faixa restrita de operação. Os modelos lineares foram importantes para o desenvolvimento da modelagem, pois permitiram o entendimento local dos fenômenos. Entretanto, com o desenvolvimento tecnológico na área da computação, foi possível o desenvolvimento de técnicas de modelagem não lineares (Barroso, 2001), como, por exemplo, o método de Wiener, as séries de Volterra, os modelos bilineares (Haber e Unbehauen, 1990), as redes neurais artificiais (Haykin, 1996), os sistemas nebulosos (Harris *et al.*, 1993), os modelos polinomiais NARMAX (*Nonlinear AutoRegressive Moving Average with eXogenous inputs*) (Aguirre, 2004) usando o algoritmo dos mínimos quadrados ortogonais, entre outros (Ljung, 2001).

Muitos destes métodos são utilizados para estimar os parâmetros de um sistema desconhecido a partir de medidas de entrada e saída do sistema dinâmico sob análise, no entanto a mais importante questão é a identificação da estrutura do modelo. Uma abordagem frequente, neste caso, envolvendo a combinação do conhecimento do especialista (projetista ou engenheiro) e investigação experimental, é através de tentativa e erro selecionar a estrutura correta e a ordem do modelo desconhecido de um conjunto de modelos candidatos. As possíveis estruturas são deduzidas do conhecimento existente *a priori* do sistema, e a estimação dos valores dos parâmetros destes modelos é baseada em medidas disponíveis dos dados experimentais. Este procedimento consome tempo e leva, na maioria das vezes, à soluções sub-ótimas (Beligiannis *et al.*, 2005). Entretanto, é importante conhecer as potencialidades e limitações das diversas abordagens disponíveis na literatura, de forma a obter-se projetos eficientes em identificação de sistemas. Neste contexto, uma das mais importantes abordagens é a automação da seleção da estrutura do modelo, o que significa que uma gama extensa de estruturas de modelos seja mais rapidamente e facilmente investigada.

Este trabalho contribui com a apresentação de uma abordagem de programação genética (*Genetic Programming*, GP) para gerar modelos matemáticos de sistemas dinâmicos representados em uma estrutura em árvore. Na literatura tem sido propostas para aplicar GP em problemas de identificação de sistemas (Gray *et al.*, 1996, 1998; Dracopoulos e Kent, 1997; Rodríguez-Vázquez e Fleming, 1998; Hoffman e Nelles, 2001; Beligiannis *et al.*, 2005; Guo *et al.*, 2005; Yang, 2006). A idéia principal deste trabalho é aplicar o algoritmo dos mínimos quadrados ortogonais (*Orthogonal Least-Squares*, OLS) (Korenberg *et al.*, 1988) em conjunto a GP para estimar a contribuição de cada ramo da árvore na precisão do modelo. A estrutura de modelo testada pela GP em conjunto com o OLS foi a NARX (*Nonlinear AutoRegressive with eXogenous inputs*) para identificação de um forno elétrico.

O artigo é organizado da seguinte forma. Os fundamentos de identificação de sistemas são apresentados na seção 2. Os conceitos básicos e o procedimento de identificação usando GP são detalhados na seção 3. Uma breve descrição do

forno elétrico estudado e a análise dos resultados obtidos na identificação usando GP são comentadas na seção 4. Finalizando, a conclusão e comentários sobre futura pesquisa são apresentados na seção 5.

2. Identificação de sistemas

A tentativa de explicar ou reproduzir os comportamentos dos sistemas físicos é algo que há tempo desperta o interesse de pesquisadores. Com o desenvolvimento dos processos industriais e a necessidade de controlá-los, é preciso desenvolver modelos que reproduzam suas características estáticas e dinâmicas. A identificação de processos tem relevância, pois pode-se prever o que acontece a um processo, conhecendo a(s) entrada(s) e a(s) saídas anteriores, disponíveis do processo.

Os modelos matemáticos podem ser de dois tipos: físicos e empíricos (Pearson e Ogunnaike, 1997, Haber e Unbehauen, 1990). Os modelos físicos são decorrentes do conhecimento das características químicas e físicas do processo. Devido à complexidade e às incertezas do processo, os modelos físicos precisos são, freqüentemente, complexos e custosos de se desenvolver. No entanto, são capazes de representar com fidelidade o processo analisado. O custo pago pela fidelidade é a complexidade do modelo, e os modelos físicos, freqüentemente, não são adequados para o controle de processos, devido a dificuldades computacionais e matemáticas.

Os modelos empíricos, por outro lado, são estruturados pelos dados de entrada(s) e saída(s). Os modelos empíricos podem ser tão simples quanto desejados e podem ser projetados para auxiliar o projeto da estratégia de controle. Infelizmente, os modelos empíricos são, geralmente, menos precisos que os melhores modelos físicos, pois aproveitam a informação física. Evidentemente, muitas combinações de modelos físicos e empíricos existem, assim os dois grupos de modelos não são exclusivos.

O conhecimento matemático da dinâmica do processo é necessário na maioria dos esquemas de controle. O problema principal em identificação de processos é encontrar uma estrutura apropriada para o modelo do processo. A regra básica em estimação é “não estimar o que se conhece”. Em outras palavras, pode-se utilizar o conhecimento *a priori* do processo e suas características físicas, quando seleciona-se a estrutura do modelo. O conhecimento do processo pode ser classificado e codificado em (Sjöberg, 1995):

- (i) *modelo caixa-branca (white-box)*: o modelo é perfeitamente conhecido, sendo possível construí-lo a partir do conhecimento *a priori* das características físicas do sistema;
- (ii) *modelo caixa-cinza (grey-box)*: alguns conhecimentos das características físicas são avaliadas, mas diversos parâmetros necessitam ser determinados a partir dos dados observados. As duas modelagens consideradas para obtenção do modelo matemático são:
 - *modelagem física*: a estrutura do modelo é construída com base física, apresentando parâmetros a serem estimados a partir dos dados.
 - *modelagem semi-física*: o conhecimento das características físicas são utilizados para sugerir certas combinações de sinais de dados medidos.
- (iii) *modelo caixa-preta (black-box)*: o conhecimento das características físicas não é avaliado (ou utilizado), mas a escolha da estrutura do modelo apresenta flexibilidade.

A análise de modelos caixa-preta é uma tarefa complexa. O motivo é que nada é excluído, e um espectro amplo das possíveis descrições do modelo é manipulado. Os estudos em identificação caixa-preta de processos não-lineares é diversificada e abrange tópicos de estimação e regressão não-paramétrica. Entre os algoritmos desta área estão os *wavelets*, modelos de sistemas nebulosos e as redes neurais artificiais.

A identificação de processos é, muitas vezes, abordada como um problema de otimização, envolvendo algumas medidas para a adequação dos modelos candidatos a representar um processo. A escolha dos modelos matemáticos e o ajuste dos parâmetros são influenciados por fatores, entre os quais: (i) o conhecimento *a priori* do sistema (linearidade, grau de não-linearidade e atraso de transporte); (ii) as propriedades do modelo do sistema identificado (complexidade); (iii) a escolha da medida de erro a ser minimizada; e (iv) a presença de ruídos.

Um procedimento eficiente de identificação de sistemas envolve, muitas vezes, múltiplos e conflitantes objetivos, tipicamente a complexidade do modelo, o(s) critério(s) de desempenho e a validação que influenciam a seleção da estrutura do modelo matemático. Existem diversas razões para manter a ordem do modelo tão baixa quanto possível. Os critérios de informação podem ser introduzidos para combinar a adequação e os princípios fundamentais de construção de modelos, tais como: (i) *princípio da redução de dados*: o menor número de variáveis deve ser utilizado para explicar uma quantidade máxima de informação, e (ii) *princípio da parcimônia* (ou *razão de Occam*): os melhores modelos são obtidos utilizando-se as estruturas aceitáveis simples, contendo o menor número de parâmetros.

Entre os critérios utilizados destacam-se: informação Bayesiana, Akaike ou *minimum description length*, que combinam a variância residual e a ordem do modelo. O objetivo do algoritmo de otimização é a minimização de um critério de desempenho. Se todas as restrições e as condições forem atendidas, o modelo encontrado é aceito. Caso contrário, se uma das condições impostas é violada, o procedimento de determinação do modelo, de estimação de parâmetros e diagnóstico do modelo deve ser repetido até que seja encontrado um modelo apropriado.

A seguir são descritos os fundamentos da GP combinada com OLS para identificação de modelos NARX.

3. Fundamentos da computação evolutiva, programação genética e OLS

Os métodos de busca e otimização, usualmente, são classificados em técnicas baseadas em cálculo, procura randômica e enumerativas. As técnicas baseadas em cálculo utilizam um conjunto de condições necessárias e suficientes a serem satisfeitas pelas soluções ótimas de um problema de otimização, sendo estas técnicas subdivididas em métodos diretos (exemplo: Fibonacci, Newton) e indiretos (exemplo: gradiente conjugado, Gauss-Seidel, Jacobi). Os métodos enumerativos (exemplo: programação dinâmica) caracterizam-se pela procura de cada ponto relatado de um domínio do espaço através de uma função objetivo. Os métodos guiados por procura randômica são baseados em técnicas enumerativas, contudo utilizam-se de informação adicional para guiar a procura, e suas maiores classes são os paradigmas de *simulated annealing* e da computação evolutiva.

Atualmente, a Computação Evolutiva (CE) constitui-se numa alternativa as técnicas convencionais em busca e otimização. A CE engloba um número crescente de metodologias, das quais as mais importantes são (i) algoritmos genéticos, desenvolvidos principalmente por A.S. Fraser, H.J. Bremermann, J. Reed e J. Holland entre a década de 50 e 70, com refinamentos posteriores por K. De Jong, J. Grefenstette e D. Goldberg; (ii) estratégias evolutivas, desenvolvidas na Alemanha, por I. Rechenberg e H.P. Schwefel; (iii) programação evolucionária, desenvolvidas por L.J. Fogel, A.J. Owens e M. J. Walsh, nos Estados Unidos, na década de 60, refinada recentemente por D.B. Fogel; (iv) programação genética, tratadas por pesquisadores como J.R. Koza, J.P. Rice, P.J. Angeline e K.E. Kinnear; e (v) sistemas classificadores, abordados na literatura por G.E. Goldberg, S.W. Wilson e J.H. Holland. O paradigma CE atualmente tende a interagir de modo a dar origem aos denominados algoritmos evolutivos ou evolucionários (AEs). Na figura 1 é apresentado um pseudocódigo básico de um algoritmo evolutivo.

```

geração ← 0
inicialização (P(t))
avaliação da aptidão da população (P(t))
enquanto o critério de parada para P(t) não for atingido
{
    geração ← geração + 1
    P(t) = seleção (P(t-1))
    recombinação (P(t))
    mutação (P(t))
    avaliação da aptidão da população(P(t))
}
    
```

Figura 1 - Pseudocódigo básico de um AE.

3.1. Programação genética

A metodologia da computação evolutiva denominada programação genética é uma extensão dos algoritmos genéticos no tratamento da complexidade de estruturas computacionais, visando a obtenção de soluções potenciais em um ambiente que imite o processo de Darwin. A GP é uma abordagem para a geração automática de programas de computador desenvolvida por John Koza (Koza, 1992; Koza, 1994). A GP utiliza um desenvolvimento eficiente à geração de expressões simbólicas e executa regressões simbólicas direcionando a determinação simultânea da estrutura e complexidade requerida pelo modelo durante o processo evolutivo.

A resolução de um problema por GP pode ser abordado como uma busca através de possíveis combinações de expressões simbólicas definidas pelo projetista. Cada expressão é codificada como uma estrutura em árvore, apresentando um comprimento variável e subdividida em nós. Os elementos da população são um alfabeto funcional, por exemplo, o conjunto $\{+, -, *, /, \sqrt{\quad}, \log, \exp\}$, e um alfabeto terminal, por exemplo, uma variável, valor constante ou número, por exemplo, o conjunto $\{2, x, y, z, 2,67\}$. Os elementos são tipicamente conjuntos fixos de símbolos selecionados no tratamento da solução de problemas em domínio de interesse, permitindo a otimização de uma estrutura em árvore de maneira mais apropriada que apenas por parâmetros numéricos.

Para garantir a viabilidade das árvores de sintaxe abstrata, John Koza definiu a propriedade de fechamento (*closure*) (Koza, 1992). Para satisfazê-la, cada função do conjunto F deve aceitar, como seus argumentos, qualquer valor que possa ser retornado por qualquer função ou terminal. Esta imposição garante que qualquer árvore gerada pode ser avaliada corretamente (Rodrigues, 2002).

Um caso típico de problema de Fechamento é a operação de divisão. Matematicamente, não é possível dividir um valor por zero. Uma abordagem possível é definir uma função alternativa que permita um valor para a divisão por zero. É o caso da função de divisão protegida (*protected division*) % proposta por (Koza, 1992). A função % recebe dois argumentos e retorna o valor 1 (um) caso seja feita uma divisão por zero e, caso contrário, o seu quociente (Rodrigues, 2002).

Para garantir a convergência para uma solução, John Koza definiu a propriedade de suficiência (*sufficiency*) onde os conjuntos de funções F e o de terminais T devem ser capazes de representar uma solução para o problema (Koza 1992). Isto implica que deve existir uma forte evidência de que alguma composição de funções e terminais possa produzir uma solução. Dependendo do problema, esta propriedade pode ser óbvia ou exigir algum conhecimento prévio de como deverá ser a solução (Rodrigues, 2002).

O espaço de busca é um hiper-espaço de todas as possíveis composições de funções que podem ser recursivamente compostas pelo alfabeto funcional e terminal. As expressões simbólicas (*S-expressions*) de uma linguagem de programação *LISP* (*List Processing*) são maneiras especialmente convenientes de criar e manipular as composições de funções e terminais. Estas expressões simbólicas em *LISP* correspondem diretamente a uma *parse tree* que é internamente criada por muitos compiladores (Koza, 1992; Koza, 1994). A figura 1 apresenta um diagrama de blocos típico de uma árvore de GP. Na figura 1, $u(t)$ representa um sinal de entrada e $y(t)$ é um sinal de saída em um sistema dinâmico.

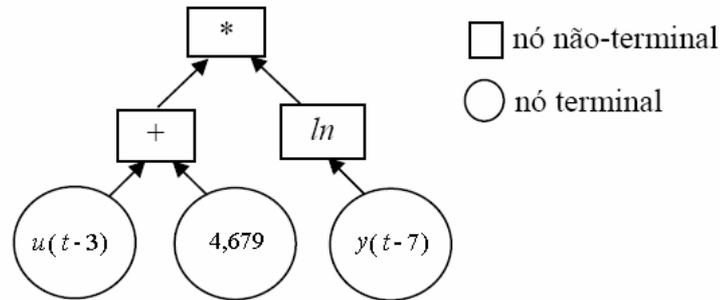


Figura 1 - Representação de um diagrama de blocos típico da GP.

O ciclo básico de otimização na programação genética pode ser resumido em um fluxograma, conforme apresentado na figura 2.

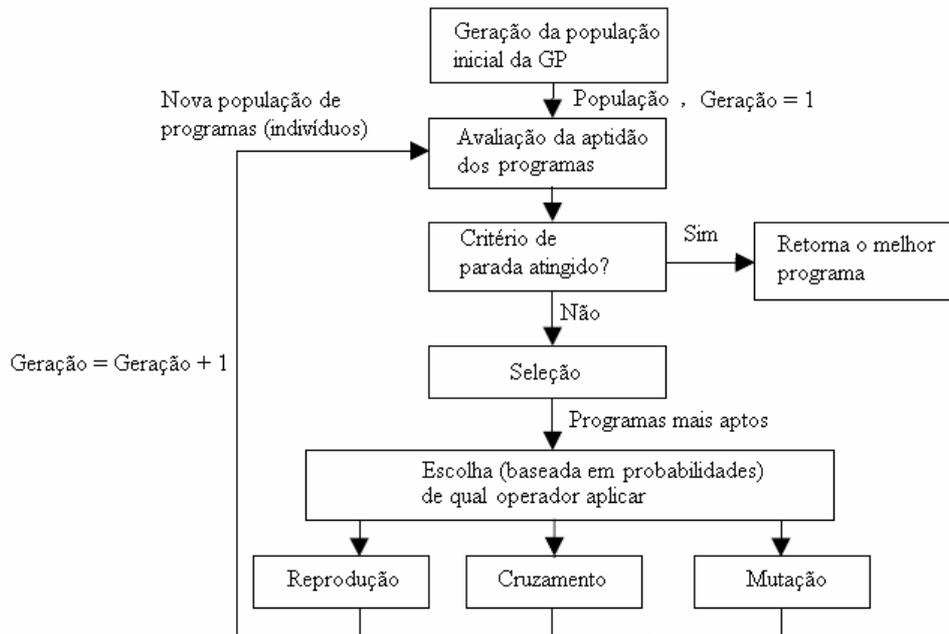


Figura 2 – Ciclo básico de otimização da GP.

3.1.1. Operadores utilizados na programação genética

Cruzamento: O *crossover* (ou cruzamento) é o operador responsável pela recombinação de características dos indivíduos, seria a reprodução sexuada da biologia. Consiste basicamente em trocar um segmento de um indivíduo por um segmento de outro e vice-versa.

A operação de cruzamento é implementada por meio de sub-árvores de indivíduos aleatoriamente selecionados e pela execução de permutações de termos entre estas. As operações de mutação, mais usuais, consistem da troca de

genes com imposição de restrições pelo projetista (McKay *et al.*, 1996; Gray *et al.*, 1996). Neste trabalho, é adotado o cruzamento com um ponto de corte. Um exemplo de operação de cruzamento é apresentado na figura 3.

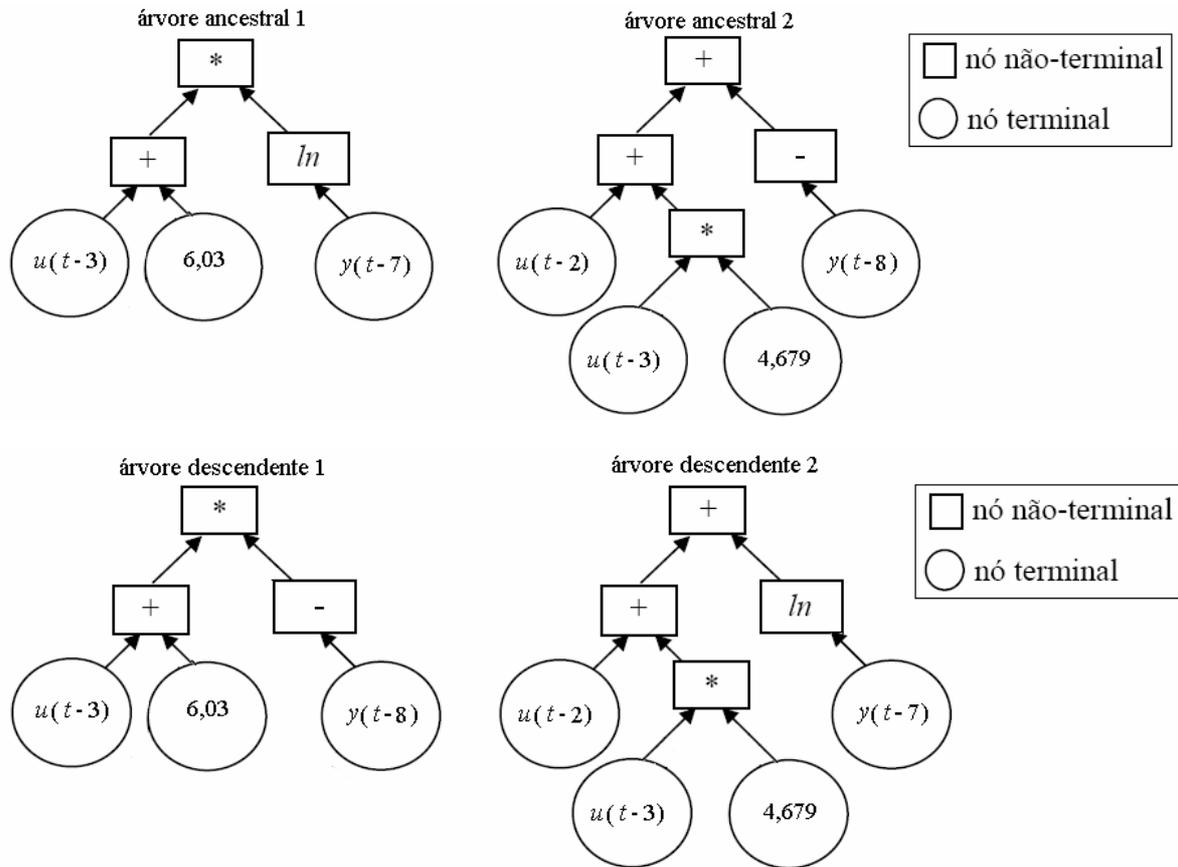


Figura 3 - Exemplo de uma operação de cruzamento com um ponto de corte.

Mutação: Na GP, a mutação consiste em selecionar aleatoriamente um ponto da árvore, a qual representa um indivíduo, e gerar aleatoriamente uma nova sub-árvore para ser colocada neste ponto. Nas figuras 4 e 5 são apresentados exemplos de operações de mutação.

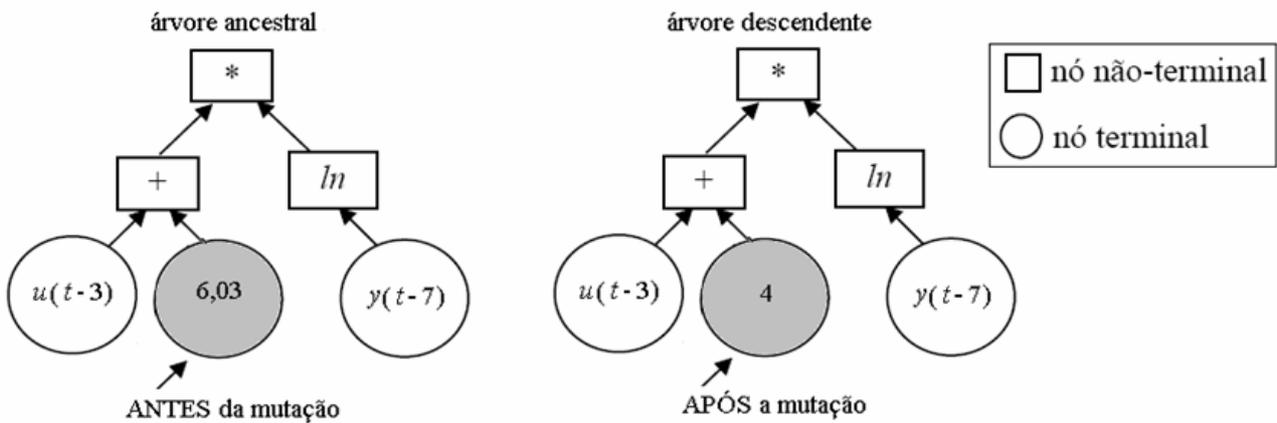


Figura 4 – Exemplo de uma operação de mutação.

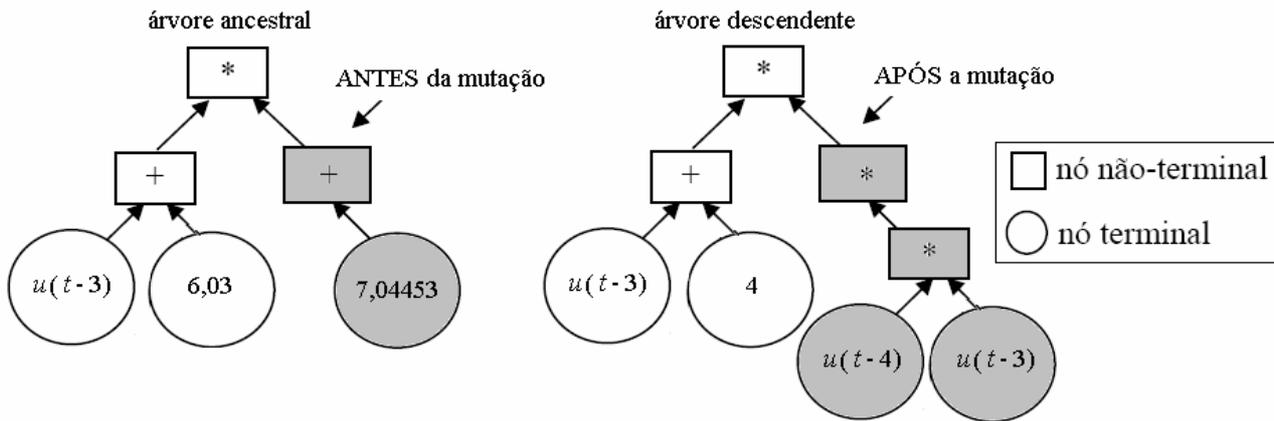


Figura 5 - Exemplo de outra operação de mutação.

Reprodução e Seleção: A reprodução assexuada simplesmente copia os indivíduos para a próxima população, ou seja, não é realizada nenhuma mudança. No entanto, a seleção é responsável pela escolha de n indivíduos (árvores no caso da GP) que sofrerão a aplicação dos operadores genéticos, gerando N novos indivíduos que irão participar da próxima população. É importante observar que, no caso específico em que se deseja manter constante o número de indivíduos em cada nova população gerada, a seleção escolhe n indivíduos de uma população de n indivíduos, mas isso não quer dizer que todos os indivíduos da população serão selecionados. Um indivíduo pode ser selecionado mais de uma vez, pois a seleção de cada indivíduo é feita a partir da população inteira (incluindo indivíduos já selecionados). Existem vários métodos de seleção. Entre eles, o método da roleta (*roulette-wheel*) e a seleção por torneio. Neste trabalho é adotado o método da roleta com elitismo.

3.1.2. Identificação de sistemas usando programação genética

Os modelos lineares nos parâmetros podem ser formulados como:

$$y(t) = \sum_{i=1}^M p_i F_i(x(t)), \quad (1)$$

onde F_1, \dots, F_M são funções não-lineares e p_1, \dots, p_M são os parâmetros do modelo. O problema de seleção da estrutura para modelos lineares nos parâmetros é o de determinar um conjunto apropriado de funções não lineares. Para lidar com este problema, duas abordagens podem ser adotadas: (i) gerar todas as possíveis estruturas de modelos e selecionar a melhor, e (ii) transformar o problema em um problema de otimização e resolvê-lo baseado em um algoritmo (heurístico) de busca.

O problema da primeira abordagem é que existe um vasto número de estruturas possíveis o que torna impossível na prática avaliar todas elas. A segunda abordagem é então adotada neste trabalho, sendo esta baseada em GP.

O algoritmo OLS é aplicado a GP no intuito de transformar as árvores em árvores mais simples (algoritmo de poda) e que sejam mais transparentes, mas também tão precisas quanto às árvores originais. O algoritmo OLS para isto é baseado em uma taxa de redução de erro (*Error Ratio Reduction, ERR*). O *ERR* indica o quanto cada termo inserido no modelo pode melhorar a representação do sistema. Um termo que diminua muito os erros de modelagem é, a princípio, melhor para a qualidade do modelo que um outro que não os reduza tanto assim. É importante ressaltar que o cálculo do *ERR* exige a estimação dos parâmetros do modelo usando a GP. O *ERR* é portanto uma medida da “importância” individual de cada termo na modelagem. Essa medida permite ordenar um conjunto de termos candidatos a serem incluídos num modelo em ordem decrescente de “importância”. Esta é a base da detecção de estrutura utilizando o critério *ERR* (Freitas, 2001). Detalhes sobre o OLS são encontrados em Korenberg *et al.* (1988), Kukreja (2003) e Aguirre (2004).

Durante o procedimento de identificação, o conjunto de funções F da GP foi selecionado para conter as operações aritméticas $F = \{+, -\}$ e o conjunto terminal T contendo os seguintes argumentos $T = \{u(t-1), \dots, u(t-n_u), y(t-1), \dots, y(t-n_y)\}$, onde n_u e n_y são as ordens de atrasos das entradas $u(t)$ e saída $y(t)$ do sistema dinâmico, respectivamente, no instante de tempo t . Baseado no algoritmo OLS, os termos de cada modelo são ordenados pelos valores de *ERR*.

4. Identificação de sistemas

Na natureza os seres vivos são selecionados naturalmente com base no seu grau de adaptabilidade ao meio ambiente. Em GP, isto é expresso pela função de aptidão (*fitness*). Os programas que melhor resolverem o problema recebem os melhores valores de aptidão e, conseqüentemente, têm maior chance de serem selecionados para reproduzir (Rodrigues, 2002).

A identificação de sistemas trata do problema de construção de modelos baseados em dados medidos do sistema. O procedimento de identificação exige o envolvimento do modelador, e consiste em: (i) projeto e execução de testes para a obtenção dos dados e determinação da taxa de amostragem; (ii) detecção de não-linearidades no sistema; (iv) escolha da representação; (v) detecção da estrutura do modelo; (vi) estimação dos parâmetros do modelo; e (vii) validação do modelo (Coelho, 2002).

Neste caso, a etapa de estimação dos parâmetros e também validação do modelo deve possuir um índice de avaliação quantitativa do desempenho do modelo baseado na saída predita do modelo em relação a saída do sistema. No contexto da identificação do forno térmico será considerada apropriada se um critério de erro definido previamente pelo projetista está entre valores admissíveis às necessidades do projeto. O critério escolhido neste estudo (função *fitness* a ser maximizada pela GP) foi o coeficiente de correlação múltipla regido pela equação

$$R^2 = 1 - \frac{\sum_{t=1}^N (y(t) - \hat{y}(t))^2}{\sum_{t=1}^{Na} (y(t) - \bar{y})^2}, \quad (2)$$

onde N é o número de amostras avaliado, $y(t)$ é a saída do sistema térmico, $\hat{y}(t)$ é a saída estimada pela GP, \bar{y} é a média das medidas do sistema térmico. Quando o valor de R^2 é igual a 1,0 indica uma aproximação exata do modelo aos dados medidos do processo. O valor de R^2 entre 0,9 e 1,0 é considerado suficiente para aplicações práticas, principalmente em projetos de identificação e sistemas de controle baseados em modelo.

4.1. Estudo de caso: Aquecedor elétrico

Este forno elétrico encontra-se no Laboratório de Controle de Processos Industriais (LCPI) do Centro de Pesquisa e Desenvolvimento em Engenharia Elétrica (CPDEE) da Universidade Federal de Minas Gerais (UFMG) (Aguirre *et al.*, 2005). O forno é uma caixa metálica com dimensões 15 x 10 x 31 cm, construído a partir de uma chapa de alumínio com espessura igual a 2 mm. O elemento de aquecimento interno é uma lâmpada elétrica de 200 W. O forno não é isolado termicamente, de modo que variações na temperatura ambiente afetam seu comportamento dinâmico. O sensor utilizado para medição da temperatura é um resistor de coeficiente de temperatura negativo (NTC) ligado em ponto de Wheatstone, a qual encontra-se equilibrada a temperatura ambiente (Côrrea, 1997, Rodrigues, 1996). Devido ao mecanismo interno de transferência de calor, o processo é não-linear e dependente da condição de operação. Além disso, ele apresenta diferentes constantes de tempo de aquecimento e resfriamento, caracterizando uma dinâmica bilinear (Abreu, 1993). Estes fenômenos não-lineares não podem ser reproduzidos por modelos lineares convencionais (Aguirre *et al.*, 1998). Os sinais de entrada e saída são mostrados na figura 6.

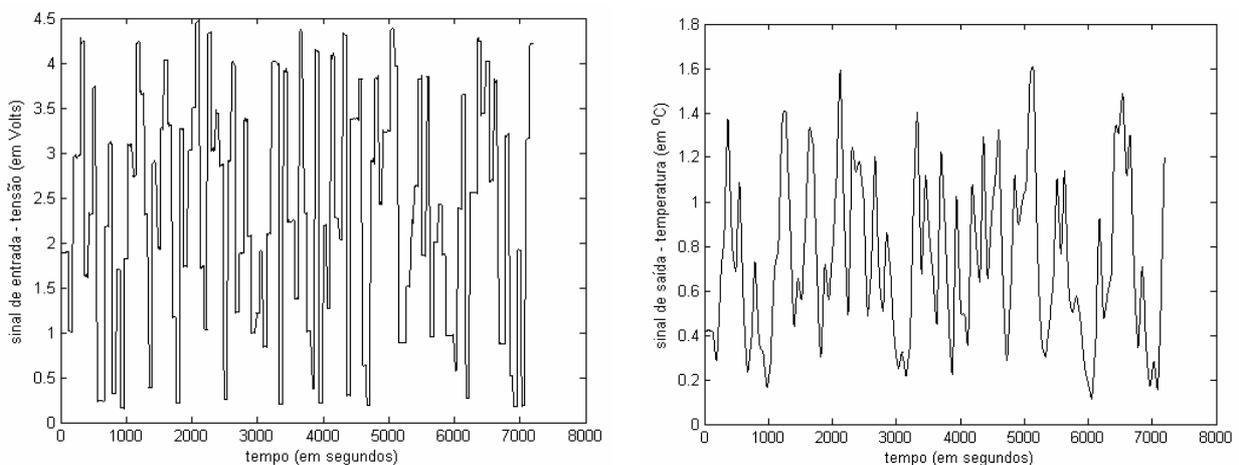


Figura 6 - Dados de entrada e saída do forno elétrico.

Adota-se, neste artigo, uma GP com tamanho de população de 40 indivíduos (vetores solução), probabilidade de cruzamento de 0,90, probabilidade de mutação de 0,50 e critério de parada de 20 gerações.

Tradicionalmente, a população na GP é composta por árvores geradas aleatoriamente a partir dos conjuntos de funções F e de terminais T . Usualmente se especifica um limite máximo para a profundidade da árvore para se evitar árvores muito grandes. Neste trabalho adotou-se uma profundidade máxima de 5.

O valor de polarização (*bias*) ERR adotado no OLS foi 0,01. Foram testadas várias configurações de projeto usando diferentes ordens para n_y e n_u , sendo estas limitadas a sistemas de terceira ordem. Neste caso o melhor resultado (melhor média harmônica para R^2 e também MSE) obtido foi no teste 8 (ver tabela 1 e a melhor representação na figura 7) com um modelo NARX de 5 parâmetros para representar o forno elétrico. Neste caso houve a presença de um termo regressor não linear $\{u(t-2)u(t-1)\}$. A equação para representar o sistema obtida pela GP, visando a predição de infinitos passos à frente, foi

$$y(t) = -0,286494y(t-3) + 0,235753y(t-2) + 0,004042u(t-1) + 0,004315u(t-2)u(t-1) - 0,001186 \quad (3)$$

Tabela 1. Resultados das simulações na identificação NARX do forno elétrico usando GP.

teste realizado	n_y (máximo)	n_u (máximo)	R^2 (estimação)	R^2 (validação)	R^2 (média harmônica)	MSE (estimação)	MSE (validação)	MSE (média harmônica)
1	1	1	0,6593	0	0	0,0419	0,2596	0,0722
2	2	1	0,9965	0,9455	0,9703	$4,2670 \cdot 10^{-4}$	0,0068	$8,0295 \cdot 10^{-4}$
3	1	2	0,8276	0	0	0,0212	0,2301	0,0388
4	2	2	0,9934	0,9650	0,9790	$8,1477 \cdot 10^{-4}$	0,0040	0,0014
5	1	3	0	0	0	0,6064	6,1096	1,1033
6	3	1	0,1822	0	0	0,1004	0,5486	0,1698
7	2	3	0,9923	0,9707	0,9814	$9,4407 \cdot 10^{-4}$	0,0036	0,0015
8	3	2	0,9837	0,9806	0,9822	0,0020	0,0024	0,0022
9	3	3	0,8423	0,3655	0,5098	0,0194	0,0789	0,0311

Notação: MSE é a sigla adotada para *Mean Squared Error*

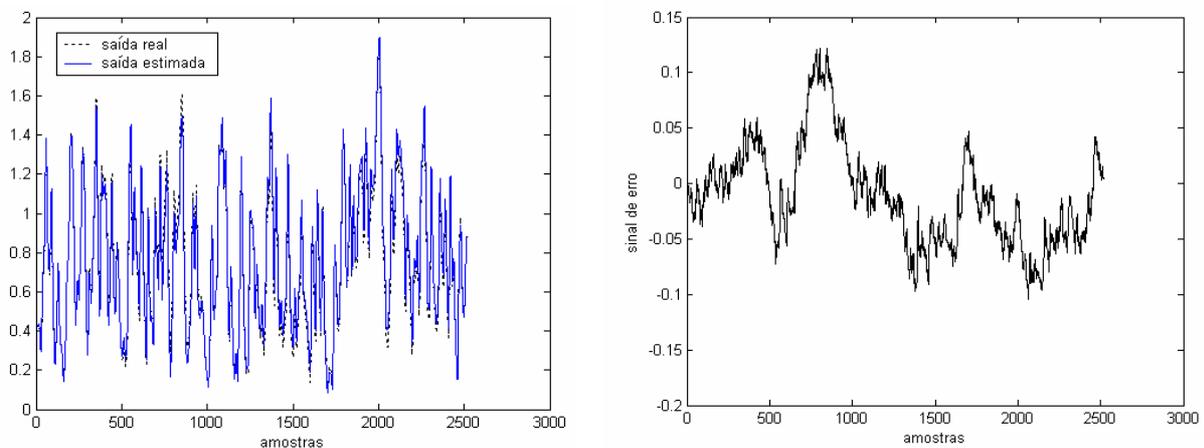


Figura 7 - Melhor estimativa na identificação do forno elétrico (teste 8 da tabela 1) usando GP.

Os resultados obtidos quando as ordens máximas $n_y = n_u = 1$ foram adotadas foram insatisfatórios baseando-se no índice R^2 apresentado na tabela 1. Neste contexto, nota-se pelos resultados apresentados na tabela 1, que quando $n_y \geq 2$ foi utilizado no projeto da GP, os resultados de R^2 foram promissores. Entretanto, todas as estimativas quando o n_y proposto era unitário foram inadequadas.

5. Conclusão e futura pesquisa

A idéia da identificação de sistemas é permitir a elaboração do modelo matemático de um sistema dinâmico baseado em medidas coletadas pelo ajuste de parâmetros e/ou do modelo matemático, até que a saída do sistema aproxime, de forma adequada, os valores de saída desejada (Johansson, 1993). Neste caso, a identificação de sistemas

pode ser aplicada sempre que se procura obter modelo matemático para um sistema que possui grandezas mensuráveis e para o qual, por qualquer motivo, não tenha sido possível derivar um modelo pela física do processo por ser muito complexa ou devido à inexistência de conhecimento a respeito do sistema em questão.

A representação dos programas em GP tradicionalmente se baseia em árvore de sintaxe abstrata, isto é, os programas são formados pela livre combinação de funções e terminais adequados ao domínio do problema. Este tipo de representação é adequada para o desenvolvimento de procedimentos de identificação de sistemas. Neste contexto, existem várias alternativas de identificação de modelos lineares ou mesmo não lineares.

Este trabalho contribuiu com a apresentação de uma abordagem de GP aliada ao algoritmo dos mínimos quadrados ortogonais para a identificação de modelos NARX para representar o comportamento dinâmico de um forno elétrico.

Um resumo dos resultados obtidos com a GP foi apresentado na tabela 1 para predição de infinitos passos à frente do comportamento da variável de saída do forno elétrico. Observou-se pelos resultados da tabela 1, que em termos da média harmônica do coeficiente de correlação múltipla (R^2), os resultados da GP usando ordens máximas de atraso com valores $(n_y, n_u) = (2,1), (2,1), (2,2), (2,3), (3,2)$ obtiveram boa aproximação para a saída do forno elétrico.

Em futura pesquisa, deseja-se implementar métodos de otimização não-linear para aprimorar o projeto da GP em termos de precisão quando aplicada em problemas de identificação não-linear.

6. Referências

- Abreu, S.D.G., 1993, “Avaliação de Desempenho de Controladores Auto-Ajustáveis”, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, MG.
- Aguirre, L.A., 2004, “Introdução à Identificação de Sistemas: Técnicas Lineares e Não Lineares Aplicadas a Sistemas Reais”, Editora da UFMG, Belo Horizonte, MG.
- Aguirre, L.A., Coelho, M.C.S., Corrêa, M.V., 2005, “On the Interpretation and Practice of Dynamical Differences Between Hammerstein and Wiener Models”, IEE Proceedings, Part D: Control Theory and Applications, Vol. 152, No. 4, pp. 349-356.
- Aguirre, L.A., Rodrigues, G.G., Jácome, C.R.F., 1998, “Identificação de Sistemas Não-Lineares Utilizando Modelos NARMAX Polinomiais – Uma Revisão e Novos Resultados”, SBA Controle & Automação, Vol. 9, No. 2, pp. 90-106.
- Barroso, M. F. S., 2001, “Métodos de Otimização Mono-Objetivo Aplicados à Identificação Caixa-Cinza de Sistemas Não-Lineares”, Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, MG.
- Beliagiannis, G.N., Skarlas, L.V., Likothanassis, S. D., Perdikouri, K. G., 2005, “Nonlinear Model Structure Identification of Complex Biomedical Data Using a Genetic-Programming-Based Technique”, IEEE Transactions on Instrumentation and Measurement, Vol. 54, No. 6, pp. 2184-2190.
- Coelho, M.C.S., 2002, “Modelos de Hammerstein e de Wiener: Conexões com Modelos NARX e sua Aplicação em Identificação de Sistemas Não-lineares”, Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, MG.
- Corrêa, M.V., 1997, “Identificação de Sistemas Dinâmicos Não Lineares Utilizando Modelos NARMAX Racionais - Aplicação a Sistemas Reais”, Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, MG.
- Daisy, Database for the Identification of Systems, <http://www.esat.kuleuven.ac.be/sista/daisy/> [Acesso 16/02/2006], 2006.
- Dracopoulos, D.C., Kent, S., 1995, “Genetic Programming for Prediction and Control”, Neural Computing & Applications, Vol. 6, No. 4, pp. 214-228.
- Dullerud, G., Smith, R., 1996, “Sampled Data Model Validation: an Algorithm and Experimental Application”, International Journal of Robust and Nonlinear Control, Vol. 6, No. 9/10, pp. 1065-1078.
- Freitas, U.S., 2001, “Uso de Técnicas de Detecção de Estrutura na Identificação de Modelos Dinâmicos Contínuos Não Lineares Polinomiais”, Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, MG.
- Gray, G.J., Li, Y., Murray-Smith, D.J., Sharman, K.C., 1996, “Structural System Identification using Genetic Programming and a Block Diagram Oriented Simulation Tool”, Electronic Letters, Vol. 32, No. 15, pp.1423-1424.
- Gray, G.J., Murray-Smith, D.J., Li, Y., Sharman, K.C., Weinbrenner, T., 1998, “Nonlinear Model Structure Identification Using Genetic Programming”, Control Engineering Practice, Vol. 6, pp. 1341-1352.
- Guo, H., Jack, L.B., Nandi, A.K., 2005, “Feature Generation Using Genetic Programming with Application to Fault Classification”, IEEE Transactions on Systems, Man, and Cybernetics – Part B; Cybernetics, Vol. 35, No. 1, pp. 89-99.
- Haber, R., Unbehauen, H., 1990, “Structure Identification of Nonlinear Dynamic Systems — a Survey on Input/Output Approaches”, Automatica, Vol. 26, No. 4, pp. 651-677.
- Harris, C.J., Moore, C.G., Brown, M., 1993, “Intelligent Control: Aspects of Fuzzy Logic and Neural Nets”, World Scientific.
- Haykin, S., 1996, “Neural Networks”, 2nd edition, Prentice-Hall, Upper Saddle River, NJ, USA.

- Hoffmann, F., Nelles, O., 2001, "Genetic Programming for Model Selection of TSK-fuzzy systems", *Information Sciences*, Vol. 136, pp. 7-28.
- Johansson, R., 1993, "System Modeling and Identification", Prentice-Hall, Englewood Cliffs, USA.
- Korenberg, M., Billings, S.A., Liu, Y.P., McIlroy, P.J., 1988, "Orthogonal Parameter Estimation Algorithm for Non-Linear Stochastic Systems", *International Journal of Control*, Vol. 48, No. 1, pp. 193-210.
- Koza, J.R., 1992, "Genetic Programming: on the Programming of Computers by Means of Natural Selection", MIT Press, Cambridge, MA.
- Koza, J.R., 1994, "Genetic Programming II: Automatic Discovery of Reusable Programs", MIT Press, Cambridge, MA.
- Kukreja, S.L., Galiana, H.L., Kearney, R.E., 2003, "NARMAX Representation and Identification of Ankle Dynamics", *IEEE Transactions on Biomedical Engineering*, Vol. 50, No. 1, pp. 70-81.
- Ljung, L., 2001, "Black-box Models from Input-output Measurements", *Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference*, Budapest, Hungary, pp. 138-146.
- McKay, B., Willis, M.J., Hiden, H.G., Montague, G.A., Barton, G.W., 1996, "Identification of Industrial Processes Using Genetic Programming", *International Conference on Identification in Engineering Systems*, Swansea, UK.
- Pearson, R.K., Ogunnaike, B.A., 1997, "Nonlinear Process Identification", In: Henson, M. A., Seborg, D. E. (eds.). *Nonlinear Process Control*, Prentice Hall PTR, Upper Saddle River: NJ, USA. Chapter 2, pp. 11-110.
- Rodrigues, G.G., 1996, "Identificação de Sistemas Dinâmicos Não Lineares Utilizando Modelos NARMAX Polinomiais - Aplicação a Sistemas Reais", *Dissertação de Mestrado do PPGE, Universidade Federal de Minas Gerais*, Belo Horizonte, MG.
- Rodrigues, E.L.M., 2002, "Evolução de Funções em Programação Genética Orientada a Gramáticas", *Dissertação de Mestrado do PPGI, Universidade Federal do Paraná, Curitiba, PR*.
- Rodríguez-Vásquez, K., Fleming, P.J., 1998, "Multi-objective Genetic Programming for Nonlinear System Identification", *Electronics Letters*, Vol. 34, No. 9, pp. 930-931.
- Sjöberg, J., 1995, "Non-Linear System Identification with Neural Networks", *PhD. Thesis, Department of Electrical Engineering, Linköping University, Linköping, Sweden*.
- Yang, W.-X., 2006, "Establishment of the Mathematical Model for Diagnosing the Engine Valve Faults by Genetic Programming", *Journal of Sound and Vibration*, Vol. 293, pp. 213-226.

GENETIC PROGRAMMING COMBINED WITH ORTHOGONAL LEAST-SQUARES APPLIED TO ELECTRICAL HEATER IDENTIFICATION

Leandro dos Santos Coelho
Laboratório de Automação e Sistemas, LAS
Programa de Graduação em Engenharia de Produção e Sistemas, PPGEPS
Pontifícia Universidade Católica do Paraná – PUCPR
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil
leandro.coelho@pucpr.br

Abstract

Genetic Programming (GP), a heuristic optimization technique based on the theory of genetic algorithms, is a method successfully used to identify nonlinear model structures by analyzing a system's measured signals. The problem of finding a model for a system's measured signal, i.e. discovering the mathematical relationship between empirically observed variables measuring a system, is an important problem in thermal sciences. The GP enables the identification of models and parameters simultaneously. This paper presents a GP approach combined with an Orthogonal Least Squares (OLS) algorithm for identification of an electrical heater. The resulting mathematical models and the analysis of Pearson's multiple correlation coefficient show the efficiency of GP approach presented.

Keywords: heating system, genetic programming, electrical heater, orthogonal least-squares, nonlinear identification.