

MECANISMOS DE AJUSTE DO PARÂMETRO PESO DE INERCIA DO ALGORITMO PSOGSA NA IDENTIFICAÇÃO DE UM SISTEMA MULTIVARIÁVEL NÃO LINEAR

ALLAN CHRISTIAN KRAINSKI FERRARI

Depto. de Engenharia Elétrica, Faculdade Educacional Araucária (FACEAR)
Caixa Postal Av. das Araucárias, 3803, 83707-067, Araucária, PR, Brasil
E-mails: allanckferrari87@gmail.com

GIDEON VILLAR LEANDRO, GUSTAVO OLIVEIRA

Laboratório de Sistemas, Controle e Otimização (LaSICO), Depto. de Engenharia Elétrica, UFPR
Caixa Postal 19011, 81531-980, Curitiba, PR, Brasil
E-mails: gede@eletrica.ufpr.br, gustavo@eletrica.ufpr.br

Abstract— The hybrid PSO algorithm GSA is an upgrade of GSA algorithm that uses the updating equation of PSO algorithm agents. This paper applies adjustment mechanisms of inertia weight parameter developed from the PSO algorithm in PSOGSA algorithm in order to reduce the computational effort and to improve the convergence of the estimated parameters. The linear, no linear and adaptive are applied adjustment of the inertia weight parameter. The modified algorithms are applied in the identification of a multivariable non-linear physical system. The results are compared with classic GSA algorithms and PSOGSA algorithm with constant inertia weight parameter. The results show the advantages of the adjustment mechanisms of the inertia weight parameter applied in PSOGSA algorithm.

Keywords— GSA Algorithm, PSO Algorithm, adjustable inertia weight, identification, multivariable system.

Resumo— O algoritmo híbrido PSOGSA é uma versão melhorada do algoritmo GSA que usa a equação de atualização de agentes do algoritmo PSO. Este trabalho aplica os mecanismos de ajuste do parâmetro peso de inércia desenvolvidos para o algoritmo PSO no algoritmo PSOGSA, visando diminuir o esforço computacional e melhorar a convergência dos parâmetros estimados. São aplicadas técnicas de ajuste linear, não linear e adaptativo no parâmetro de peso de inércia. Os algoritmos modificados são aplicados na identificação de um sistema físico multivariável não linear. Os resultados são comparados com os dos algoritmos GSA clássico e PSOGSA com parâmetro de peso de inércia constante. Os resultados mostram as vantagens dos mecanismos de ajuste do parâmetro peso de inércia aplicados no algoritmo PSOGSA.

Palavras-chave— Algoritmo GSA, Algoritmo PSO, peso de inércia ajustável, identificação, sistema multivariável.

1 Introdução

O algoritmo de busca gravitacional GSA (*Gravitational Search Algorithm*) é uma meta-heurística que se baseia na lei da gravitação universal de Newton e leis dos movimentos. Desde que foi introduzido em 2009 por Rashedi *et al.* (2009), encontram-se na literatura várias modificações que visam melhorar propriedades da versão original (Sabri *et al.* 2013).

Estas modificações são aplicadas nos parâmetros da constante gravitacional e no tamanho do conjunto dos agentes mais influentes no sistema de interação entre massas. Também é encontrado na literatura o algoritmo GSA combinado com outras técnicas como a lógica nebulosa e algoritmos baseados na otimização enxame de partículas PSO (*Particle Swarm Optimization*). A seguir alguns desses trabalhos são brevemente relatados.

Jiang e Zeng (2014) apresentaram um método modificado para previsão de deslocamento provocado por deslizamento de terra. O método é baseado na rede neural nebulosa T-S FNN (*Takagi-Sugeno fuzzy neural network*). Os algoritmos GSA e PSO são aplicados em conjunto, formando o algoritmo híbrido PSOGSA, na otimização dos parâmetros do T-S FNN. O desempenho do modelo obtido é verificado nos estudos de casos dos deslizamentos de terra em Baishuihe e Liangshuijing no reservatório Três Gar-

gantas da China. O desempenho do método PSOGSA é superior quando comparado com os métodos de função de base radial e máquina de vetores suporte.

Gu e Pan (2013) propõem uma modificação no algoritmo GSA visando à busca de melhores soluções em funções com muitas dimensões. O algoritmo GSA modificado (MGSA) tem a habilidade de partícula de memória que consiste adotar os conceitos de solução ótima local e global do algoritmo PSO. O algoritmo MGSA e o GSA clássico são aplicados em 12 funções de otimização de referência, onde o algoritmo MGSA se mostra superior.

Pfeifer e Lobato (2013) fazem a aplicação dos algoritmos GSA, Levenberg-Marquardt no Problema de Controle Ótimo Chaveado PCOC. Depois é aplicado um algoritmo híbrido envolvendo as duas técnicas. Nos resultados, o algoritmo GSA se mostrou como uma interessante alternativa quando comparado ao algoritmo Levenberg-Marquardt apesar de necessitar de mais esforço computacional. O algoritmo híbrido se mostrou mais robusto.

Nos trabalhos relatados uma das deficiências do algoritmo GSA clássico é a convergência prematura na identificação ou otimização de funções multidimensionais. Uma das formas de melhorar essa deficiência é combinar o algoritmo PSO com o GSA formando o híbrido PSOGSA, consistindo em substituir a equação de atualização da velocidade do GSA pelo do algoritmo PSO. A equação de atualização de

velocidade de agentes do algoritmo PSO consiste em utilizar os agentes ótimos locais e globais.

Por sua vez, o algoritmo PSO é uma técnica de otimização bem conceituada, onde existem várias modificações que visam melhorar seu tempo de convergência. Parte dessas modificações é usada para a adaptação dos parâmetros da equação de velocidade de forma *online*. Essas modificações podem ser aplicadas no algoritmo PSO-GSA.

Este trabalho tem como objetivo aplicar mecanismos de atualização do parâmetro peso de inércia na equação da velocidade do algoritmo PSO-GSA. Esses mecanismos são aplicados na identificação de em um sistema multivariável não linear real, visando melhorar o tempo de processamento e a convergência dos parâmetros estimados.

Este artigo está estruturado em três partes: métodos, resultados e conclusão. Nos métodos são apresentadas as modificações aplicadas no algoritmo PSO-GSA. Nos resultados é mostrado o desempenho dos algoritmos aplicados e em seguida é feita uma análise dos mesmos. Finalmente na conclusão são apresentados as restrições e os desdobramentos para trabalhos futuros.

2 Métodos

2.1 Algoritmo PSO-GSA

O algoritmo híbrido PSO-GSA foi proposto por Mirjalili e Hashim (2010). A ideia do algoritmo PSO-GSA consiste em combinar a habilidade de pensamento social *gbest* (a melhor solução global) do algoritmo PSO com a capacidade de pesquisa local do GSA, formando a seguinte equação de atualização da velocidade:

$$v_i^d(t+1) = w \cdot v_i^d(t) + c_1 \cdot \text{rand} \cdot a_i^d(t) + c_2 \cdot \text{rand} \cdot (gbest - x_i^d(t)), \quad (1)$$

onde w é o parâmetro peso de inércia, c_1 e c_2 são respectivamente os parâmetros cognitivo e social do algoritmo PSO. A posição, a velocidade e aceleração da i -ésima partícula com dimensão d em função do tempo t são representadas respectivamente por $x_i^d(t)$, $v_i^d(t)$ e $a_i^d(t)$. A equação (1) substitui a equação de atualização da velocidade do algoritmo GSA representada por

$$v_i^d(t+1) = \text{rand}_i \cdot v_i^d(t) + a_i^d(t). \quad (2)$$

2.2 Técnicas de ajuste do parâmetro peso de inércia do algoritmo PSO-GSA

Nesta seção serão apresentados alguns dos métodos de ajuste do parâmetro peso de inércia do algoritmo PSO que foram implementados no algoritmo híbrido PSO-GSA.

Desde que o PSO foi desenvolvido, surgiram várias variantes propostas por pesquisadores que visavam melhorar o algoritmo, uma forma era através da mudança do valor do parâmetro peso de inércia.

Existem três classes de estratégias que alteram o valor w . A primeira classe o valor de w é constante ou determinado aleatoriamente durante o processo de busca, nenhum deste método usa valores de entrada como tempo ou desempenho. Na segunda classe o valor de w é ajustado em função do tempo ou do número de iterações, o ajuste pode ser linear ou não linear. A terceira classe compreende os métodos adaptativos, estas técnicas usam um parâmetro de realimentação que avalia o estado do algoritmo e ajusta o valor w (Nickbadi et al. 2011).

Das três classes, serão apresentadas algumas das estratégias de ajuste do parâmetro peso de inércia que foram aplicadas no algoritmo PSO-GSA.

2.2.1 Peso de Inércia Constante

O estudo do parâmetro de peso de inércia começou com Shi e Eberhart (1998). Eles sugeriam que w deveria ser escolhido para valores do intervalo $[0,8 \ 1,2]$. Para valores $w < 0,8$ o algoritmo PSO tendia ao ótimo local e para valores $w > 1,2$ o algoritmo apresentava fraca exploração. Neste trabalho, o algoritmo PSO-GSA utiliza $w = 0,9$.

2.2.2 Peso de Inércia Variante no Tempo

Muitas das técnicas que usa w variante no tempo são determinadas em função do número de iterações. Estes métodos podem incrementar ou decrementar o valor de w de forma linear ou não linear.

Uma das técnicas foi introduzida por Shi e Eberhart (1998). Neste método, o valor w é linearmente decrescente em função do número de iteração atual *iter*. O valor w começa com o valor máximo (w_{max}) e termina o processo com o valor mínimo (w_{min}) de acordo com a equação (3).

$$w(ite) = \frac{iter_{max} - iter}{iter_{max}} \cdot (w_{max} - w_{min}) + w_{min} \quad (3)$$

Sendo que $iter_{max}$ é o número máximo de iterações. Os valores de w_{min} e w_{max} usados neste trabalho são respectivamente 0,4 e 0,9.

Outra técnica foi proposta por Chatterjee and Siarry (2006). Esta técnica faz o valor w decrescer de forma não linear como segue

$$w(ite) = \frac{(iter_{max} - iter)^n}{(iter_{max})^n} \cdot (w_{max} - w_{min}) + w_{min}, \quad (4)$$

onde n é o índice de modulação não linear, neste trabalho foi usado $n = 2$.

2.2.3 Peso de Inércia Adaptativo

Nesta classe o valor do parâmetro w é ajustado de acordo com a situação de busca, dependendo de alguns valores de realimentação (Nickbadi et al. 2011). Uma destas técnicas foi proposta por Panigrahi et al. (2008), diferentes valores w são atualizados

de acordo com o $rank$ e o valor da função objetivo. As soluções (partículas) com valores com melhores $fitness$ se movem mais lentamente que soluções com piores valores de $fitness$. A equação de adaptação por $rank$ é representada por:

$$w_i = w_{min} + (w_{max} - w_{min}) \frac{Rank_i}{População_{Total}}, \quad (5)$$

onde $Rank_i$ é a posição da partícula i quando são ordenadas em função das melhores funções e $População_{Total}$ é o número de partículas.

Outras técnicas de adaptação do parâmetro w são baseadas em lógica nebulosa. Uma das técnicas nebulosa mais recente foi proposta por Nafar *et al.* (2012), composta por nove regras, onde cada regra é composta por duas entradas e uma saída. As entradas são representadas pelo valor peso de inercia w e o desempenho mensurado por valor de $fitness$ normalizado NFV (*Normalized Fitness Value*). A saída representa a variação do peso de inercia. O valor de saída desse sistema nebuloso é representado pela variação do peso de inercia Δw . O valor de entrada do NFV varia entre 0 e 1, calculado pela seguinte função:

$$NFV = \frac{fitness - fitness_{min}}{fitness_{max} - fitness_{min}} \quad (6).$$

A equação que atualiza o valor w fica:

$$w^{t+1} = w^t + \Delta w \quad (7)$$

O sistema nebuloso utiliza o modelo Mamdani, funções de pertinência triangular, operador de agregação de antecedentes mínimo, operador de agregação de regras máximo e defuzzificação por centro do máximo. Esta técnica foi implementada no algoritmo PSO-GSA.

Os termos linguísticos das funções de pertinências, utilizados para descrever os valores semânticos das variáveis de entrada w e NFV são declarados como: PQ (pequeno); MD (médio) e GD (Grande). Os valores semânticos para a variável de saída Δw é declarado como: NE (Negativo); ZE (Zero) e PO (Positivo). As regras são mesmas usadas no trabalho de Nafar *et al.* (2012) e estão representadas na tabela 1.

Tabela 1 - Conjunto de regras.

Inferência para Δw .	
Se (w é PQ e NFV é PQ)	Então (Δw é ZE)
Se (w é PQ e NFV é MD)	Então (Δw é PO)
Se (w é PQ e NFV é GD)	Então (Δw é PO)
Se (w é MD e NFV é PQ)	Então (Δw é NE)
Se (w é MD e NFV é MD)	Então (Δw é ZE)
Se (w é MD e NFV é GD)	Então (Δw é ZE)
Se (w é GD e NFV é PQ)	Então (Δw é NE)
Se (w é GD e NFV é MD)	Então (Δw é NE)
Se (w é GD e NFV é GD)	Então (Δw é NE)

A configuração da função de pertinência de saída foi ajustada de acordo com o conhecimento do especialista. A configuração das funções de pertinências está representada na tabela 2.

Tabela 2: Funções de pertinências de entrada e saída, do algoritmo PSO-GSA com adaptação do parâmetro w por lógica fuzzy.

Função de pertinência da entrada w			
Funções de Pertinência	Limite Inferior	Valor de Pico	Limite Superior
PQ	0,4	0,4	0,7
MD	0,4	0,7	1,0
GD	0,7	1,0	1,0
Função de pertinência da saída NFV			
Funções de Pertinência	Limite Inferior	Valor de Pico	Limite Superior
PQ	0	0	0,5
MD	0	0,5	1,0
GD	0,5	1,0	1,0
Função de pertinência da saída Δw			
Funções de Pertinência	Limite Inferior	Valor de Pico	Limite Superior
NE	-0,005	-0,005	0
ZE	-0,005	0	0,005
PO	0	0,005	0,005

3 Resultados

Para avaliar as modificações no algoritmo PSO-GSA foi utilizado para modelagem matemática um sistema físico real multivariável constituído de seis entradas e uma saída (Figura 1). As variáveis de entrada são valores de corrente controladas por PWM (Pulse Width Modulation) que controlam as bombas que alimentam o sistema de um reservatório. A variável de saída é fornecida pelo sensor de vazão.

Este sistema multivariável é denominado de sistema MISO (*multiple inputs and single output*). Os sistemas multivariáveis são considerados desafiadores para a identificação, pois seu comportamento depende da interação simultânea de várias variáveis (Goodwin *et al.* 2000).

Os dados foram fornecidos pela companhia paranaense de saneamento (SANEPAR 2014) e tem tempo de amostragem igual à uma hora.




Figura 1: Dados do sistema MISO: (a) estimação e (b) validação.

Para identificação é usado o modelo matemático não linear de Hammerstein que está representado no modelo polinomial em tempo discreto, equação (8). Este modelo é utilizado porque consegue representar de forma eficaz as não linearidades estáticas presente em atuadores como motores (Santos 2003).

$$\begin{aligned}
 u_{1h}[k] &= x_{11} \cdot u[k] + x_{12} \cdot u[k]^2 + x_{13} \cdot u[k]^3 + x_{14} \cdot u[k]^4 + x_{15} \cdot u[k]^5 \\
 u_{2h}[k] &= x_{21} \cdot u[k] + x_{22} \cdot u[k]^2 + x_{23} \cdot u[k]^3 + x_{24} \cdot u[k]^4 + x_{25} \cdot u[k]^5 \\
 u_{3h}[k] &= x_{31} \cdot u[k] + x_{32} \cdot u[k]^2 + x_{33} \cdot u[k]^3 + x_{34} \cdot u[k]^4 + x_{35} \cdot u[k]^5 \\
 u_{4h}[k] &= x_{41} \cdot u[k] + x_{42} \cdot u[k]^2 + x_{43} \cdot u[k]^3 + x_{44} \cdot u[k]^4 + x_{45} \cdot u[k]^5 \\
 u_{5h}[k] &= x_{51} \cdot u[k] + x_{52} \cdot u[k]^2 + x_{53} \cdot u[k]^3 + x_{54} \cdot u[k]^4 + x_{55} \cdot u[k]^5 \\
 u_{6h}[k] &= x_{61} \cdot u[k] + x_{62} \cdot u[k]^2 + x_{63} \cdot u[k]^3 + x_{64} \cdot u[k]^4 + x_{65} \cdot u[k]^5 \\
 y[k] &= -a_1 \cdot y[k-1] - a_2 \cdot y[k-2] - a_3 \cdot y[k-3] + b_{01} u_{1h}[k] \\
 &+ b_{11} u_{1h}[k-1] + b_{21} u_{1h}[k-2] + b_{31} u_{1h}[k-3] + b_{02} u_{2h}[k] \\
 &+ b_{12} u_{2h}[k-1] + b_{22} u_{2h}[k-2] + b_{32} u_{2h}[k-3] + b_{03} u_{3h}[k] \\
 &+ b_{13} u_{3h}[k-1] + b_{23} u_{3h}[k-2] + b_{33} u_{3h}[k-3] + b_{04} u_{4h}[k] \\
 &+ b_{14} u_{4h}[k-1] + b_{24} u_{4h}[k-2] + b_{34} u_{4h}[k-3] + b_{05} u_{5h}[k] \\
 &+ b_{15} u_{5h}[k-1] + b_{25} u_{5h}[k-2] + b_{35} u_{5h}[k-3] + b_{06} u_{6h}[k] \\
 &+ b_{16} u_{6h}[k-1] + b_{26} u_{6h}[k-2] + b_{36} u_{6h}[k-3]
 \end{aligned} \quad (8)$$

A ordem da não linearidade e número de atrasos das entradas e saídas foram determinados de forma empírica. O termo $u[k]$ é utilizado no modelo pois as bombas que alimentam o sistema são motores elétricos, logo seu comportamento apresenta tempo morto (Santos 2003).

Nas simulações foram avaliados o número de iterações, o tempo de convergência e a validação dos parâmetros estimados. Para critério de parada dos algoritmos foi usado coeficiente de correlação R^2 igual a 0,92 e número de iterações máxima igual a 200. Para avaliação da estimação dos modelos matemáticos, o MSE (*Mean of Squared Error*) e o coe-

ficiente de correlação múltipla R^2 são os critérios de desempenho utilizados para simulação livre. Estes valores e os valores estimados do sistema MISO estão representados por média $\bar{\mu}$ e desvio padrão σ .

Para comparação dos resultados do tempo de convergência do algoritmo PSOGSA e suas modificações, foi aplicado o teste de hipóteses como método estatístico. O teste de hipótese consiste em comparar o valor de z_t que está associado à hipótese alternativa (H_1) e o valor da estatística do erro de confiança z_α que está associado à hipótese nula (H_0). Para esta comparação é usada a curva de distribuição normal para o cálculo da probabilidade (Montgomery et al. 2012).

O teste de hipóteses é aplicado para duas amostras populacionais diferentes com valores de média e desvio padrão conhecidos, com nível de confiança de 99%. O valor estatístico teste z_t a ser usada:

$$z_t = \frac{(\bar{x}_1 - \bar{x}_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}, \quad (9)$$

onde $\bar{x}_1$, σ_1 e n_1 são respectivamente a média, o desvio-padrão e o número de elementos da 1ª amostra. Enquanto $\bar{x}_2$, σ_2 e n_2 são respectivamente a média, o desvio-padrão e o número de elementos da 2ª amostra (Montgomery et al. 2012).

O teste de hipóteses é realizado com 99% de confiabilidade, logo: $z_\alpha = -2,37$. Para esta condição o teste de hipóteses terá direção unidirecional à esquerda ($z_t < z_\alpha$). Se o valor de z_t for menor que z_α , H_1 é aceita. Se z_t for maior que z_α , H_0 é aceita.

O teste de hipóteses compara dois algoritmos por vez, para H_0 foi considerado o algoritmo com o maior valor médio de tempo de estimação (o mais lento) e para H_1 o algoritmo supostamente que converge mais rápido com o menor valor médio de tempo de estimação (o mais rápido). Se H_1 é aceito, significa que o algoritmo com menor tempo médio converge mais depressa que o algoritmo com maior tempo médio representado por H_0 , para uma confiabilidade de 99%. Caso contrário, o algoritmo representado por H_1 não converge mais rápido o suficiente que H_0 .

Para esta pesquisa foi utilizado como materiais: um computador com processador *intel i3* e 4 Giga bytes de memória; *software* Matlab®.

3.1 Resultados dos Mecanismos de ajuste do parâmetro peso de inercia

Tabela 3: Desempenho dos algoritmos PSOGSA modificados para 100 estimativas do modelo MISO de Hammerstein.

Dados obtidos		Algoritmos					
		GSA clássico	PSOGSA com w constante	PSOGSA com ajuste w linear	PSOGSA com ajuste w não linear	PSOGSA com ajuste w adaptativo por Rank	PSOGSA com ajuste w adaptativo por lógica Fuzzy
Número de iterações	$\bar{\mu}$	200	121,82	75,96	58,96	65,85	74,39
	σ	0	38,77	16,74	15,95	35,27	15,18
Tempo (s)	$\bar{\mu}$	734,85	401,01	262,34	197,98	221,05	271,98
	σ	667,88	130,43	67,66	55,30	125,71	73,51
MSE (Estimação)	$\bar{\mu}$	9,03e4	1,12e4	1,12e4	1,11e4	1,12e4	1,11e4
	σ	1,58e4	202,84	187,99	374,68	106,13	252,81

MSE (Validação)	$\bar{\mu}$	2,43e5	1,82e6	6,61e4	3,60e4	2,69e4	3,27e4
	σ	1,23e5	1,17e7	3,03e5	4,61e4	1,20e4	3,48e4
R^2 (Estimação)	$\bar{\mu}$	0,3640	0,9185	0,9148	0,9162	0,9136	0,9170
	σ	0,1118	0,0096	0,0311	0,0164	0,0150	0,0170
R^2 (Validação)	$\bar{\mu}$	0,4033	0,7716	0,8846	0,8958	0,9138	0,8950
	σ	0,2481	0,2230	0,1250	0,0975	0,0387	0,1116
MSE (Melhor Modelo da Validação)		4,65e4	8,06e3	9,51e3	9,15e3	6,31e3	8,04e3
Número de Convergências Prematuras		100	14	11	17	29	13

O algoritmo GSA não foi aplicado no teste hipóteses porque teve baixo desempenho, nenhuma de suas simulações atingiu R^2 igual ou superior a 0,92. Pelo mesmo motivo o melhor resultado do algoritmo não está representado na tabela 5 e na figura 2.

Tabela 4: Teste de Hipóteses para o tempo de estimação para 100 estimativas do modelo MISO de Hammerstein.

Se: $z_t \geq z_{\alpha}$ logo aceita (A) H_0 e rejeita(R), H_1 .				
Se: $z_t < z_{\alpha}$ logo aceita (A) H_1 e rejeita(R), H_0 .				
Comparação entre algoritmos	z_t	H_0 :	H_1 :	
H_0 : PSOGSA com w constante. H_1 : PSOGSA com ajuste w linear.	-8,783	R	A	
H_0 : PSOGSA com w constante. H_1 : PSOGSA com ajuste w não linear.	-13,254	R	A	
H_0 : PSOGSA com w constante. H_1 : PSOGSA com ajuste w adaptativo por Rank.	-8,777	R	A	
H_0 : PSOGSA com w constante. H_1 : PSOGSA com ajuste w adaptativo por lógica Fuzzy.	-8,003	R	A	
H_0 : PSOGSA com ajuste w linear. H_1 : PSOGSA com ajuste w não linear.	-6,849	R	A	
H_0 : PSOGSA com ajuste w linear. H_1 : PSOGSA com ajuste w adaptativo por Rank.	-2,494	R	A	
H_0 : PSOGSA com ajuste w adaptativo por lógica Fuzzy. H_1 : PSOGSA com ajuste w linear.	-0,9047	A	R	
H_0 : PSOGSA com ajuste w adaptativo por lógica Fuzzy. H_1 : PSOGSA com ajuste w adaptativo por Rank.	-3,018	R	A	
H_0 : PSOGSA com ajuste w adaptativo por lógica Fuzzy. H_1 : PSOGSA com ajuste w não linear.	-7,4389	R	A	
H_0 : PSOGSA com ajuste w adaptativo por Rank. H_1 : PSOGSA com ajuste w não linear.	-1,4323	A	R	

Tabela 5: Os melhores parâmetros estimados para 100 estimativas do modelo MISO de Hammerstein.

Parâmetros Estimados	Algoritmos				
	PSOGSA com w constante	PSOGSA com ajuste w linear	PSOGSA com ajuste w não linear	PSOGSA com ajuste w adaptativo por Rank	PSOGSA com ajuste w adaptativo por lógica Fuzzy
a_{11}	-4,98e-6	-9,41e-6	-9,29e-6	-1,70e-5	1,15e-5
a_{21}	-1,89e-7	-9,53e-7	5,623e-6	-3,39e-6	9,18e-6
a_{31}	-8,35e-6	-1,05e-5	8,56e-6	8,98e-6	-9,47e-6
b_{01}	8,71e-6	1,08e-5	8,05e-6	-7,35e-6	-1,31e-5
b_{11}	-7,70e-7	5,33e-6	1,03e-5	-3,33e-5	1,43e-6
b_{21}	1,52e-6	5,61e-6	2,14e-5	-3,88e-6	2,87e-7
b_{31}	3,52e-6	-5,06e-8	8,81e-6	1,15e-5	-1,42e-5
b_{02}	-5,47e-6	-1,29e-5	1,99e-5	1,14e-5	-1,09e-5
b_{12}	5,46e-6	1,36e-6	-7,31e-6	5,88e-6	-2,56e-6
b_{22}	8,92e-6	-1,44e-5	8,14e-6	-1,16e-7	6,39e-7
b_{32}	-1,10e-6	-1,24e-5	4,09e-6	1,19e-6	-3,78e-6
b_{03}	1,10e-5	1,16e-5	-9,48e-6	-4,86e-6	7,43e-6
b_{13}	-4,35e-8	-1,49e-7	5,57e-8	1,00e-6	-8,49e-7
b_{23}	4,26e-6	-1,67e-6	2,68e-6	9,92e-7	-6,85e-7
b_{33}	-5,76e-6	-8,80e-7	3,78e-7	-6,32e-7	-1,05e-6
b_{04}	1,06e-5	8,15e-6	9,14e-6	-3,42e-5	-8,41e-6
b_{14}	-5,26e-6	-1,62e-6	-4,02e-7	-1,34e-5	-3,58e-6
b_{24}	8,97e-7	2,22e-6	2,73e-6	-6,02e-6	-4,88e-6

b_{34}	3,31e-6	-7,94e-7	-2,63e-7	4,62e-6	3,19e-6
b_{05}	6,55e-6	1,05e-5	1,03e-5	2,71e-5	7,13e-6
b_{15}	2,23e-6	1,72e-6	6,56e-6	6,74e-6	-1,39e-6
b_{25}	7,11e-7	-4,80e-7	-1,18e-6	1,72e-7	-1,21e-7
b_{35}	-7,07e-7	1,70e-6	1,39e-6	5,59e-6	2,86e-6
b_{06}	1,06e-5	-5,70e-6	9,27e-6	1,56e-5	1,25e-5
b_{16}	-3,93e-6	-2,06e-6	2,64e-6	4,08e-6	1,12e-5
b_{26}	1,04e-6	-4,74e-7	2,43e-6	1,51e-6	-4,12e-6
b_{36}	1,94e-6	6,11e-7	-2,79e-6	-3,97e-6	1,58e-6
x_{11}	-1,67e-6	-5,68e-6	4,92e-6	9,70e-7	-1,59e-6
x_{21}	1,08e-5	-4,92e-7	1,72e-6	4,32e-6	2,12e-5
x_{31}	1,01e-7	-1,02e-6	3,17e-6	-1,13e-5	-3,02e-6
x_{41}	-2,62e-6	-3,66e-6	6,23e-6	-1,55e-6	4,86e-6
x_{51}	7,73e-6	5,68e-6	2,34e-6	-2,47e-6	-4,81e-6
x_{12}	-2,72e-6	-1,05e-5	6,28e-6	1,87e-5	8,73e-6
x_{22}	-6,48e-6	4,48e-6	7,13e-6	5,85e-6	-2,03e-6
x_{32}	7,77e-6	4,63e-6	5,897e-6	1,69e-5	-6,07e-6
x_{42}	-4,81e-6	6,49e-6	6,50e-6	-3,27e-6	1,45e-5
x_{52}	-2,80e-6	-3,41e-6	5,47e-6	7,11e-6	-8,06e-6
x_{13}	2,10e-6	1,28e-5	1,50e-6	-2,01e-5	1,46e-5
x_{23}	1,17e-5	-8,42e-6	-7,33e-6	9,35e-6	3,66e-6
x_{33}	1,19e-5	1,29e-5	-1,40e-5	-3,13e-6	9,46e-6
x_{43}	-6,05e-6	-1,01e-5	-3,40e-6	-8,21e-6	-2,38e-5
x_{53}	6,48e-6	4,69e-6	-5,86e-6	-1,26e-5	7,51e-6
x_{14}	9,72e-6	-1,61e-6	1,45e-5	-1,08e-5	-7,50e-6
x_{24}	9,33e-7	1,78e-6	-8,53e-6	-1,39e-5	1,23e-5
x_{34}	2,32e-6	-2,36e-6	6,24e-6	7,13e-6	-1,48e-5
x_{44}	-4,54e-6	8,33e-6	6,65e-7	7,51e-6	7,56e-6
x_{54}	6,32e-6	5,81e-6	4,38e-6	-8,69e-7	-3,60e-6
x_{15}	-9,24e-7	-5,43e-6	-8,43e-7	-1,70e-6	-1,19e-6
x_{25}	5,80e-6	-4,13e-6	-6,90e-6	-7,11e-6	-2,12e-5
x_{35}	2,27e-6	6,40e-6	-9,14e-7	-5,74e-6	-6,25e-6
x_{45}	4,29e-6	9,33e-7	4,44e-6	8,99e-7	1,87e-5
x_{55}	4,90e-6	4,28e-6	3,64e-6	1,56e-6	7,17e-6
x_{16}	4,27e-6	5,70e-6	-3,42e-8	1,01e-5	3,56e-6
x_{26}	-4,19e-6	-1,50e-6	-1,43e-7	1,76e-5	-1,00e-5
x_{36}	3,74e-7	-7,66e-6	3,49e-6	1,69e-6	1,83e-6
x_{46}	3,08e-06	-8,31e-6	3,22e-8	1,04e-5	2,28e-6
x_{56}	5,51e-06	-7,69e-6	4,13e-6	2,33e-6	2,50e-6






Figura 2: Resultado da estimação e validação do sistema MISO a partir do melhor valor de R^2 na validação de cada algoritmo.

Todas as versões do algoritmo híbrido conseguiram representar o modelo MISO de forma adequada com exceção do algoritmo GSA nas 100 simulações. Isto pode ser confirmado no resultado da estimação e validação (Figura 2) e pelos valores de correlação obtidos na estimação e validação (Tabela 3) que são superiores ao valor de correlação mínima ($R^2 > 0,90$) para práticas de controle.

Pode ser observado na tabela 3 que os mecanismos de ajuste de w utilizados deixaram o processo de estimação do algoritmo PSOGSA mais rápido com menores números de iterações e menor tempo em relação algoritmo original, sem comprometer a convergência dos parâmetros. Isto é confirmado pelo teste de hipóteses (Tabela 4) Observa-se na tabela 5 que os valores referentes aos melhores parâmetros estimados são similares.

Os resultados do teste de hipóteses mostram que os algoritmos PSOGSA que utilizam mecanismos de ajuste do valor w (H_1) melhoram o algoritmo PSOGSA com w constante (H_0) em relação ao tempo de estimação. O teste de hipóteses também mostra que os mecanismos de ajuste w não linear e o adaptativo por *Rank* obtiveram os melhores resultados no tempo de convergência.

4 Conclusão

O algoritmo PSOGSA é uma versão aperfeiçoada do algoritmo GSA, pois nos resultados o algoritmo GSA não conseguiu convergir para os critérios de identificação desejados no processo de estimação do sistema multivariável MISO. Logo, confirma na literatura sua deficiência na aplicação na minimização de funções objetivo com vários parâmetros.

Os mecanismos de ajuste do parâmetro peso de inercia aplicados no algoritmo PSOGSA melhoram o tempo de processamento do mesmo sem comprometer a qualidade dos parâmetros estimados. A versão de ajuste não linear obteve o melhor resultado com menor número de iterações e menor tempo de processamento, isto confirmado por teste de hipóteses.

A técnica de adaptação *fuzzy* utilizada neste trabalho foi superior ao algoritmo PSOGSA sem mecanismos de ajuste, apesar de não ter obtido desempenho superior em relação a outras metodologias. Em trabalhos futuros, outras topologias baseadas em lógica *fuzzy* podem ser propostas para melhorar ainda mais o processo de estimação de sistemas multivariáveis.

Referências Bibliográficas

- Chatterjee, A. and Siarry P (2006). Nonlinear inertia weight variation for dynamic adaption in particle swarm optimization. *Computer and Operations Research*, No 33, pp. 859-871.
- Goodwin, G., Graebe, S. F. and Salgado, M. E (2000). *Control System Design*, Valparaíso, Chile.
- Gu, B. and Pan, F. (2013). Modified Gravitational Search Algorithm with Particle Memory Ability and its Application. *IJICIC*, Vol. 9, No. 11, pp. 4531-4544.
- Jiang, P and Zeng, Z (2014). A PSOGSA method to optimize the T-S fuzzy neural network for displacement prediction of landslide. *IEEE: ICSMC*, San Diego, CA, USA.
- Mirjalili, S. and Hashim, S. Z. M (2010). A New Hybrid PSOGSA Algorithm for Function Optimization. *IEEE: ICCIA*, pp. 374-377.
- Montgomery, D. C. & Runger, G. C. (2012). *Estatística Aplicada e Probabilidade para Engenheiros*. 5º ed. LTC.
- Nafar, M., Gharehpetian, G. B and Niknam, T (2012). Using Modified Fuzzy Particle Swarm Optimization Algorithm for Parameter Estimation of Surge Arresters Models. *IJICIC*, Vol.8, No.1, pp. 567-581.
- Nickbadi, A., Ebadzadeh, M. M. and Safabakhsh, R (2011). A novel particle swarm optimization algorithm with adaptive inertia weight. *Elsevier Applied Soft Computing*, No. 11, pp. 3658-3670.
- Panigrahi, B. K., Pandi, V. R. and Das, S (2008). Adaptive Particle Swarm Optimization Approach for Static and Dynamic Economic Load Dispatch, *Energy Conversion and Management*, No 49, pp. 1407-1415.
- Pfeifer, A. A. e Lobato, F. S (2013). Controle Ótimo de Sistemas Algébricos-Diferenciais Chaveados usando o Algoritmo de Busca Gravitacional. *TEMA*, Vol. 14, No. 1, pp. 81-94.
- Rashedi, E. Nezamabadi-pour, H. and Saryazdi, S (2009). "GSA: A Gravitational Search Algorithm," *Information Sciences*, Vol. 179, No. 13, pp. 2232-2248.
- Sabri, N. M., Puteh, M. and Mahmood, M. R (2013). A Review of Gravitational Search Algorithm. *SCRG, IJASCA*, Vol. 5, No. 3.
- SANEPAR. Dados dos Reservatórios Tarumã e São Braz (2014).
- Santos, J. E. S. (2003). Controle Preditivo não linear para Sistemas de Hammerstein. Tese de Doutorado. Florianópolis, UFSC, Santa Catarina.
- Shi, Y. H and Eberhart, R. C (1998). A modified particle swarm optimizer, in: *IEEE ICEC*, Anchorage Alaska, pp. 69-73.