

ESTUDO COMPARATIVO DE TÉCNICAS DE INTELIGÊNCIA DE ENXAME DE PARTÍCULAS NA IDENTIFICAÇÃO DE SISTEMAS LINEARES

EWERTON C. L. DE OLIVEIRA¹, JUAN F. VIDAL¹, ORLANDO F. SILVA², JASMINE P. L. DE ARAUJO¹

1. Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal do Pará
Caixa Postal 479, 66075-110, Belém, PA, Brasil

E-mails: ewerton.o43@gmail.com, jfvidal@ufpa.br, jasmine.araujo@gmail.com

2. Faculdade de Engenharia Elétrica e Biomédica, Instituto de Tecnologia, Universidade Federal do Pará
Rua Augusto Correa, S/N, Guamá, Belém/PA, Brasil, CEP: 66075-110
E-mail: orfosi@ufpa.br

Abstract— A great importance subject in engineering and science is how to obtain mathematical models that represent systems and that are able to simulate the dynamic and operation of them for possible analyses and controls project. This paper aims to approach the application of metaheuristic algorithms of swarm intelligence, developed and simulated in software Matlab, with the purpose of perform *off-line* identification of 1st and 2nd order linear systems involving three study cases. This paper aims to do also a statistical and comparative analysis of algorithm's results for criteria of precision, accuracy, average time processing and convergence velocity after 30 simulations of identification of analyzed plants. For the 1st order cases will be identified two plants with different parameters, one plant without noise and the other one with delay and noise. And for 2nd order will be done a study case of a plant with delay and noise. The swarm intelligences used on this paper correspond to Particle Swarm Optimization (PSO), Constricted Particle Swarm Optimization (PSO-Co) and the Adaptive Particle Swarm Optimization (APSO).

Keywords— Parameter Estimation, Performance Evaluation, PSO, PSO-Co, APSO.

Resumo— Um assunto de grande importância na engenharia e na ciência é como obter modelos matemáticos que representem sistemas e que sejam capazes de simular a dinâmica e o funcionamento dos mesmos para possíveis análises e projeto de controladores. Este trabalho tem como objetivo abordar a aplicação de algoritmos metaheurísticos de inteligência de enxame, desenvolvidos e simulados no *Software* Matlab, com o propósito de realizar a identificação *off-line* de sistemas lineares de 1^a e 2^a ordem envolvendo três estudos de caso. Também é objetivo do trabalho realizar uma análise estatística e comparativa dos resultados destes algoritmos para os critérios de precisão, acurácia, tempo médio de processamento e velocidade de convergência após 30 simulações de identificação das plantas analisadas. Para os casos de 1^a ordem serão identificadas duas plantas com parâmetros distintos, uma sem ruído e outra com atraso e ruído. E para 2^a ordem será feito um estudo de caso de uma planta com atraso e ruído. As inteligências de enxame utilizadas neste trabalho correspondem a Otimização por Enxame de Partículas ou PSO (*Particle Swarm Optimization*), o PSO com Construção ou PSO-Co (*Constricted Particle Swarm Optimization*) e o PSO Adaptativo ou APSO (*Adaptive Particle Swarm Optimization*).

Palavras-chave— Estimção Paramétrica, Avaliação de Desempenho, PSO, PSO-Co, APSO.

1 Introdução

Com o advento do avanço da ciência e da tecnologia, e de suas conseqüências na engenharia e na sociedade, novos processos cada vez mais complexos são criados, e com isso, surge a necessidade de conhecer os modelos matemáticos que regem suas dinâmicas para auxiliarem no processo de análise, e no projeto de controladores para estes sistemas (Coelho, 2004).

A identificação de sistemas abrange um amplo campo de pesquisa, onde várias metodologias são propostas para diversos tipos de sistemas: lineares, não-lineares, variantes e invariantes no tempo, mono-variáveis (uma entrada, uma saída) e multivariáveis (múltiplas entradas, múltiplas saídas). Pode-se dividir as metodologias de identificação em determinísticas e estocásticas.

Na classe de identificação determinística pode-se citar os algoritmos: Mínimos Quadrados, Mínimos Quadrados Recursivos, Métodos de Subespaço, Filtro de Kalman (Aguirre, 2015), Método da Variável Instrumental Recursiva, Método da Função Correlativa (Modares; Alfi; Sistani, 2010). Embora estes algoritmos possuam relativa eficiência no processo de iden-

tificação, em vários casos, eles recaem no mínimo local em seu método de estimação paramétrica para o modelo, podendo gerar erros de estimação significativos. Além de que a identificação por algoritmos determinísticos é um campo muito diversificado, pois dependendo da natureza do sistema existe um algoritmo diferente que melhor se enquadra à resolução do problema (Ubenhauen; Rao, 1990).

Por outro lado, algoritmos metaheurísticos de busca estocástica apresentam certas vantagens na resolução destes problemas, uma vez que a maioria deles possuem mecanismos que visam contornar o mínimo (ou máximo) local, otimizando a busca pelo valor ótimo em seu intervalo de busca, embora isso demande um tempo computacional maior. Outra vantagem no uso das metaheurísticas recai na característica genérica que elas possuem na resolução de problemas de vários ramos da ciência, da engenharia e outros campos, o que pode contornar a necessidade de se implementar um algoritmo diferente para cada natureza de sistema a ser identificado.

Metaheurísticas como Algoritmo Genético (AG), Otimização por Enxame de Partículas (PSO), PSO com Construção (PSO-Co), PSO Adaptativo (APSO) e outros, são bastante utilizadas na identifi-

cação de sistemas lineares e não lineares, além de suas respectivas aplicações em ajustes de controladores do tipo Proporcional-Integral-Derivativo (Alfi; Modares, 2011) e sintonia de Controlador Linear Quadrático (Kumar; Jerome, 2014).

Portanto, este trabalho tem por objetivo apresentar a aplicação de algoritmos PSO, PSO-Co e APSO na identificação *off-line* de sistemas de 1ª e 2ª ordem em três estudos de caso, além de abordar uma análise estatística de desempenho dos resultados de cada metaheurística utilizada neste processo.

2 Inteligências de Enxame

Descreve-se a seguir os algoritmos de Inteligência de Enxame (IE) utilizados neste trabalho no processo de identificação de sistemas.

2.1 PSO

O algoritmo PSO foi primeiramente descrito nos trabalhos de Eberhart e Kennedy em 1995, o qual trata de um algoritmo inspirado no comportamento de bandos de pássaros. Este algoritmo consiste basicamente em um conjunto de partículas, enxame, onde a posição de cada uma representa uma solução possível para um problema, e cada partícula possui uma velocidade associada, que é atualizada conforme um modelo matemático baseado nas informações compartilhadas pelas partículas (Kennedy; Eberhart, 1995).

No PSO, cada partícula do enxame é formada por: um vetor posição, $\vec{x}_i(t)$, que representa uma solução possível para o problema; um vetor velocidade, $\vec{v}_i(t)$, que pondera a velocidade que uma partícula se move no espaço de busca; um vetor de memória cognitiva da partícula, $\vec{P}_i(t)$, o qual indica a melhor posição individual já ocupada por determinada partícula e $\vec{G}(t)$ é a melhor posição global do exame. Onde: i é a i -ésima partícula do enxame de N dimensões e t é a iteração do algoritmo. As equações (1) e (2) permitem atualizar as velocidades e posições das partículas respectivamente.

$$\vec{v}_i(t+1) = w\vec{v}_i(t) + c_1R_1(t)(\vec{P}_i(t) - \vec{x}_i(t)) + c_2R_2(t)(\vec{G}(t) - \vec{x}_i(t)) \quad (1)$$

$$\vec{x}_i(t+1) = \vec{x}_i(t) + \vec{v}_i(t+1) \quad (2)$$

Na equação (1) c_1 e c_2 são o fator cognitivo e social respectivamente, também conhecidos como coeficientes de aceleração, e $R_1(t)$ e $R_2(t)$ são parâmetros aleatórios iniciados uniformemente entre 0 e 1, e w é coeficiente de inércia.

Após a atualização das posições e velocidades das partículas, avalia-se estes dois vetores se estão dentro de seus limites de busca. Em seguida, atualiza-se a memória cognitiva conforme a equação (3).

$$\vec{P}_i(t+1) = \begin{cases} \vec{x}_i(t+1), & \text{se } f(\vec{x}_i(t+1)) > f(\vec{P}_i(t)) \\ \vec{P}_i(t), & \text{se } f(\vec{x}_i(t+1)) \leq f(\vec{P}_i(t)) \end{cases} \quad (3)$$

A melhor partícula global é definida como sendo a partícula dentre as melhores posições cognitivas atualizadas que possui o melhor valor da função objetivo (f), ou seja, o maior valor para problemas de maximização, e o menor valor para problemas de minimização. Em seguida, o algoritmo finaliza seu ciclo até convergir para um valor esperado. A Figura 1 mostra de forma completa o fluxograma do algoritmo PSO.

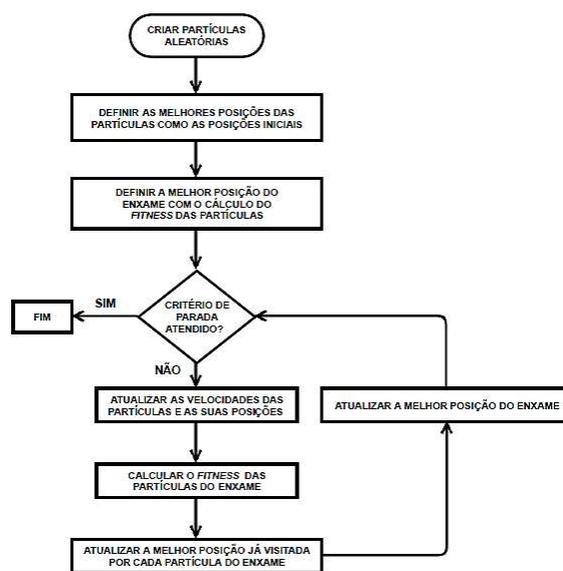


Figura 1. Fluxograma do algoritmo PSO

2.2 PSO-Co

O algoritmo PSO com constrição (PSO-Co) foi proposto primeiramente nos trabalhos de Clerc e Kenedy (2002), onde se utiliza um fator de constrição χ na equação de atualização da velocidade, capaz de diminuir o tempo de convergência do algoritmo PSO.

A única diferença entre o PSO-Co e o PSO é que o primeiro não possui o coeficiente de inércia, então a atualização da velocidade da partícula mostrada em (5), depende apenas do cálculo de χ , conforme (6).

$$\vec{v}_i(t+1) = \chi[\vec{v}_i(t) + c_1R_1(t)(\vec{P}_i(t) - \vec{x}_i(t)) + c_2R_2(t)(\vec{G}(t) - \vec{x}_i(t))] \quad (5)$$

$$\chi = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|} \quad (6)$$

Na equação (6) o coeficiente φ é definido como a soma dos coeficientes de aceleração das partículas. O restante do algoritmo PSO-Co segue a mesma estrutura do PSO, conforme mostrado na Figura 1.

2.4 APSO

A primeira proposta de PSO adaptativo (APSO) ocorreu nos trabalhos em Zhan et al. (2009), e é esta estrutura que será utilizada neste trabalho.

Tal proposta consiste em contornar a deficiência do PSO canônico que recai em sua baixa velocidade de convergência e a capacidade limitada de escapar dos ótimos locais, sendo estes dois os principais objetivos do APSO (PONTES, 2010).

Para realizar os seus objetivos, o APSO apresenta duas principais etapas. Primeiramente o algoritmo realiza uma avaliação da distribuição populacional do enxame e de seus *fitness*, pois com essa informação o algoritmo estima o coeficiente conhecido como fator evolucionário (f_{evol}), o qual é usado para definir em cada iteração em qual estado evolucionário está o enxame, cujos estados são: *exploration*, *exploitation*, *convergence* e *jumping out*. Além controlar o coeficiente de inércia conforme a equação (7).

$$w(f_{evol}) = \frac{1}{1 + 1,5e^{-2,6f_{evol}}} \quad (7)$$

O estado evolucionário é definido pelo conjunto de funções *fuzzy* mostradas na Figura 2. A tabela 1 mostra o controle dos coeficientes de aceleração, onde o incremento é uma variável aleatória entre 0,05 e 0,10.

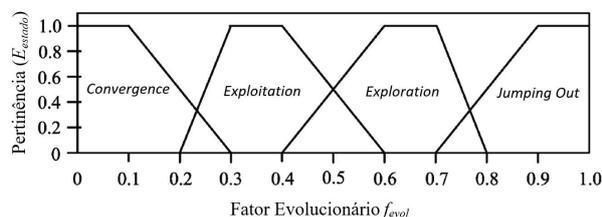


Figura 2. Funções de pertinência *fuzzy* dos estados evolucionários do APSO

Tabela 1. Atualização adaptativa dos coeficientes de aceleração.

Estado Evolucionário	c_1	c_2
<i>Exploration</i>	Incrementar	Decrementar
<i>Exploitation</i>	Incrementar levemente	Decrementar levemente
<i>Convergence</i>	Decrementar levemente	Incrementar levemente
<i>Jumping Out</i>	Decrementar	Incrementar

A segunda etapa somente ocorre quando o enxame é classificado no estado *convergence*, o que consiste em executar uma estratégia elitista sobre a melhor partícula global, de forma a alterar um de seus parâmetros aleatoriamente com uma distribuição gaussiana de média zero e variância σ^2 , de forma a aumentar o espaço de busca do algoritmo, e assim, não permitindo que este caia no mínimo (ou máximo) local. A equação (8) mostra o cálculo desta variância,

onde $\sigma_{\max} = 0,1$ e $\sigma_{\min} = 1,0$, e t_{\max} é a última iteração do algoritmo.

$$\sigma = \sigma_{\max} - (\sigma_{\max} - \sigma_{\min}) \left(\frac{t}{t_{\max}} \right) \quad (8)$$

Caso o enxame não seja classificado como *convergence*, o algoritmo apenas ajusta os coeficientes de aceleração e o fator de inércia, sem realizar a estratégia elitista, e segue com as próximas etapas conforme o fluxograma da Figura 3.

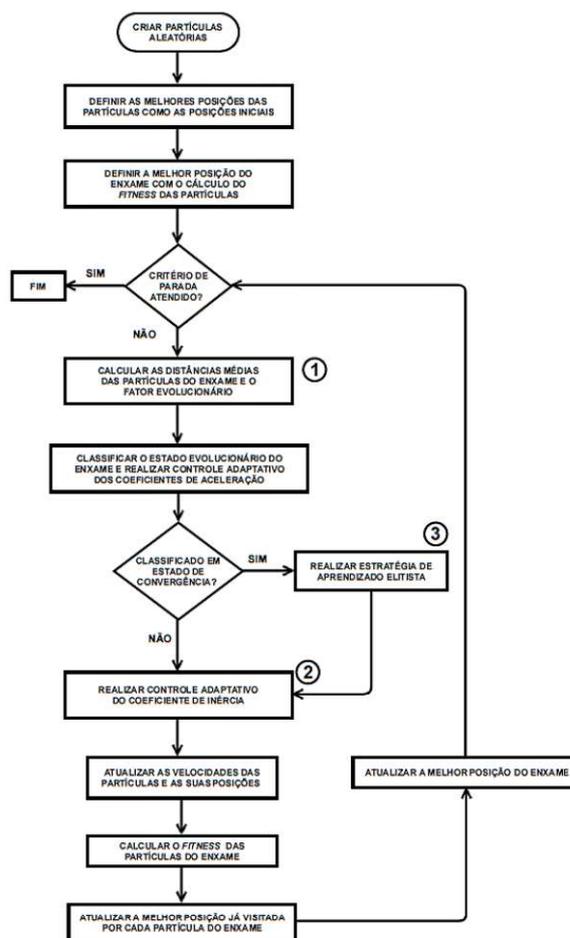


Figura 3. Fluxograma do algoritmo APSO

3 Identificação de Sistemas com Metaheurísticas Populacionais

3.1 Identificação de sistemas de 1ª e 2ª ordem

A identificação *off-line* de sistemas lineares de tempo contínuo com IE demanda das informações do sinal de entrada $u(t)$, que é definido como degrau unitário para a metodologia deste trabalho, e do sinal de saída $y(t)$ da planta a ser identificada, conforme a Figura 4.

Na Figura 4, $G(s)$ representa um sistema linear de 1ª ou 2ª ordem a ser identificado, o bloco 'pré-processamento' é responsável por extrair algumas informações da resposta da planta na identificação.

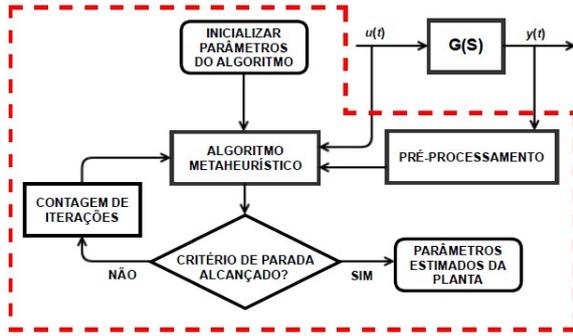


Figura 4. Processo de identificação *off-line* de sistemas com algoritmo metaheurístico

Para sistemas de 1ª ordem, equação (9), as partículas representam uma solução possível para cada um de seus parâmetros a ser identificado, equação (10). Onde K é o ganho da planta, T é a constante de tempo e θ é o atraso de resposta da planta.

$$G(s) = \frac{K}{Ts + 1} e^{-\theta s} \quad (9)$$

$$\vec{x}_i(t) = [K_i \ T_i \ \theta_i] \quad (10)$$

Os limites de busca para os parâmetros K , T e θ são mostrados nas inequações (11), (12) e (13). O tempo total de resposta da planta t_{resp} é extraído na fase de pré-processamento e os demais limites devem ser definidos antes da execução do algoritmo.

$$K_{inf} \leq L_{K1} \leq K_{sup} \quad (11)$$

$$T_{inf} \leq L_T \leq T_{sup} \quad (12)$$

$$0 \leq L_{\theta 1} \leq \frac{t_{resp}}{2} \quad (13)$$

A equação (14) mostra a função de transferência de um sistema de 2ª ordem. Onde K é o ganho, ζ é o coeficiente de amortecimento, w_n é frequência natural de oscilação e θ é o atraso de resposta da planta.

As partículas das IE que representam uma solução possível para cada um de seus parâmetros a ser identificado são mostradas na equação (15).

$$G(s) = \frac{Kw_n^2}{s^2 + 2\zeta w_n s + w_n^2} e^{-\theta s} \quad (14)$$

$$\vec{x}_i(t) = [K_i \ \zeta_i \ w_{ni} \ \theta_i] \quad (15)$$

Os limites de busca para os parâmetros K , ζ , w_n e θ são mostrados nas inequações (16), (17), (18) e (19) respectivamente. Onde: Y_{max} é o valor de pico da resposta e t'_p é o tempo que a planta leva para chegar ao valor de pico. Tais informações são colhidas no pré-processamento. Os demais limites são definidos antes da execução das IE.

$$K_{inf} \leq L_{K2} \leq Y_{max} \quad (16)$$

$$0 \leq L_{\zeta} \leq 1 \quad (17)$$

$$W_{inf} \leq L_{w_n} \leq \frac{\pi}{t_p \sqrt{1 - 0.99^2}} \quad (18)$$

$$0 \leq L_{\theta 2} \leq t'_p \quad (19)$$

3.2 Parametrização e funções de avaliação das IE

A parametrização inicial das IE (PSO, PSO-Co e APSO) depende das seguintes variáveis: número, dimensão e aceleração das partículas; limites de velocidades; fator de inércia; número de iterações e erro quadrático médio (EQM) máximo.

Cada um destes parâmetros deve ser inicializado antes da execução do algoritmo e também antes da aquisição dos dados de entrada e saída da planta que será identificada.

Neste trabalho, propõe-se o uso do Erro Quadrático Médio (EQM), equação (20), como função custo das IE e estas terão como objetivo sua minimização.

$$EQM_i = \frac{1}{S_n} \sum_{n=1}^{S_n} (y(n) - y_i(n))^2 \quad (20)$$

Onde: n é uma iteração do vetor resposta da planta ao degrau unitário $y(n)$, $y_i(n)$ é a resposta da planta estimada pela i -ésima partícula e S_n é número total de amostras do vetor $y(n)$.

4 Avaliação de Desempenho das Metaheurísticas

As métricas de avaliação são as ferramentas de avaliação de desempenho de cada algoritmo, e elas tem a importância de indicar se um algoritmo é “bom” em relação aos demais em determinado critério.

As métricas utilizadas para este trabalho são: precisão, acurácia e tempo médio de processamento. Todas essas métricas são aplicadas para avaliar o desempenho individual das metaheurísticas utilizadas para identificação de sistemas. Cada algoritmo é executado um número n_p de vezes, em geral algumas dezenas de vezes, para resolver o mesmo problema, e obter dados suficientes para uma análise global das IE.

4.1 Precisão

A precisão, P , é uma medida estatística que indica o quanto as medidas de um dado problema estão próximas ou dispersas entre si. Ela é calculada utilizando a média σ_m entre os desvios padrões, conforme as equações (22) e (23), onde N é o número de parâmetros da planta.

$$P = \frac{1}{\sigma_m} \quad (22)$$

$$\sigma_m = \frac{\sigma_1 + \sigma_2 + \dots + \sigma_N}{N} \quad (23)$$

4.2 Acurácia

A acurácia indica o quanto os dados são próximos do valor real que se deseja alcançar, quantificando a exatidão dos dados. A equação (24) mostra seu cálculo, onde o termo $bEQM_h$ indica o menor erro médio quadrático alcançado pela IE na h -ésima simulação. Numa análise geral, utiliza-se a média e o desvio padrão das acurácias para todas as n_p simulações de cada metaheurística.

$$Acuracia_h = \frac{1}{\Delta + bEQM_h} \quad (24)$$

4.3 Tempo médio de processamento (TMP)

Neste trabalho o tempo de processamento é contado a partir do momento em que cada algoritmo inicializa as partículas, e termina de ser contado quando o algoritmo interrompe a sua execução devido a algum dos critérios de parada. Como cada IE é simulada n_p vezes, calcula-se a média dos tempos de simulação.

5 Resultados

Neste tópico são aplicadas e analisadas as IE na identificação *off-line* de três casos, dois para sistema de 1ª ordem e um para sistema de 2ª ordem. Para a análise dos algoritmos na identificação dos sistemas, foram feitas 30 simulações para cada metaheurística, e cada metaheurística foi submetida aos três critérios de avaliação de desempenho. Também são mostrados os gráficos de otimização do EQM médio por iteração de cada algoritmo.

Em relação aos critérios de parada, o valor do EQM máximo utilizado é 1×10^{-5} e 3×10^{-4} para os casos sem e com ruído respectivamente. O número de iterações das IE usado é 200.

O ruído usado nas análises é o gaussiano branco de média zero e variância 2×10^{-4} , e este ruído é somado na saída da planta a ser identificada.

O parâmetro Δ é definido com o valor 0,01 para o cálculo das acurácias dos algoritmos. Deste modo, quando o $bEQM_h$ for igual a zero, condição ideal de identificação, o valor da acurácia será de 100%.

Todos os resultados são oriundos de simulações feitas no *software* Matlab (Gilat, 2006).

5.1 Sistema de 1ª ordem

Para avaliar o desempenho das IE na identificação de sistemas de 1ª ordem foram usados dois sistemas com características diferentes.

Os limites de busca de K , T e θ para os casos de planta de 1ª ordem analisados são mostrados na Tabela 2, considerando o tempo de reposta total da planta igual a 35 segundos. Estes limites são definidos para um vasto espaço de busca para as IEs, cujos valores abrangem um número grande de possibilidades de identificação paramétrica.

Tabela 2. Limites de busca paramétrica dos sistemas de 1º ordem.

Parâmetro da Planta	Limite Inferior	Limite Superior
K	0	50
T	0	50
θ	0	17,5

Para os casos de sistemas de 1ª ordem, as IEs foram parametrizadas conforme a Tabela 3.

Tabela 3. Parâmetros das IEs para sistemas de 1ª ordem.

Inteligência de Enxame	Enxame	w	$c_{1,2}$	V_{min}	V_{max}
PSO	30	0,8	2,0	-1,5	1,5
PSO-Co	20	-	2,01	-1,5	1,5
APSO	20	0,8	2,0	-1,5	1,5

• Caso 1: Sistema rápido com erro de regime permanente e com atraso

Para o caso 1 considerou-se o sistema representado pela função de transferência da equação (25), onde: $K = 0,54$; $T = 1,3$ e $\theta = 2,5$. Esse sistema apresenta contaminação por ruído em sua saída.

$$G(s) = \frac{0,54}{1,3s + 1} e^{-2,5s} \quad (25)$$

A Tabela 5 mostra os valores de média e desvio padrão dos coeficientes estimados pelos algoritmos. A Tabela 6 mostra os valores de média e desvio padrão da acurácia, e as precisões das IEs no caso 1.

Tabela 5. Médio e desvio padrão dos parâmetros estimados no caso 1.

	Média de K	Desvio Padrão de K	Média de T	Desvio Padrão de T
PSO	0,5396	0,0042	1,3841	0,2037
PSO-Co	0,5419	0,0043	1,3981	0,1583
APSO	0,5437	0,0073	1,5156	0,3972
Valores Reais	0,54	-	1,3	-
	Média de θ	Desvio Padrão de θ		
PSO	2,4315	0,1315	-	-
PSO-Co	2,4021	0,1215	-	-
APSO	2,3546	0,2955	-	-
Valores Reais	2,5	-	-	-

Conforme mostra a Tabela 6, o PSO obteve melhor acurácia pois alcançou a segunda maior média, e um dos menores desvio padrão, isto indica que esta

IE alcançou os resultados com valor médio mais próximo ao valor ótimo dos parâmetros da planta. Embora o PSO-Co tenha alcançado a melhor precisão, uma vez que seus resultados obtiveram maior proximidade entre si.

Tabela 6. Acurácia e precisão no caso 1.

	Média da Acurácia	Desvio Padrão da Acurácia	Precisão
PSO	97,4604	0,2769	8,8391
PSO-Co	97,4306	0,2755	10,5597
APSO	97,9803	0,7012	4,2857

A Tabela 7 e a Figura 5 mostram respectivamente o tempo médio de processamento e o EQM médio por iteração dos algoritmos no caso 1.

Tabela 7. TMP dos algoritmos no caso 1.

	Tempo Médio de Processamento (s)
PSO	56,0895
PSO-Co	37,9146
APSO	15,9667

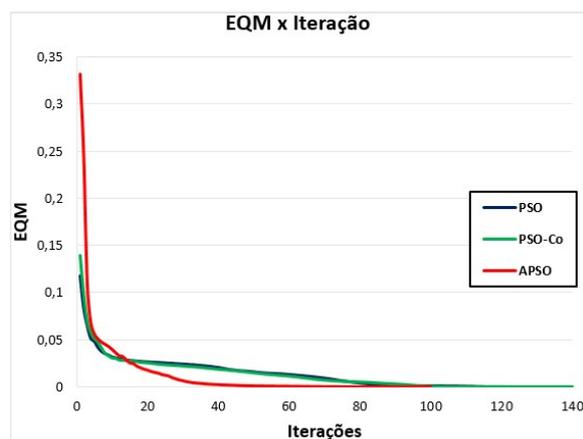


Figura 5. EQM médio por iteração dos algoritmos no caso 1

A Figura 6 mostra a resposta ao degrau unitário do sistema do caso 1 estimado pelo PSO, pois este obteve melhor acurácia.

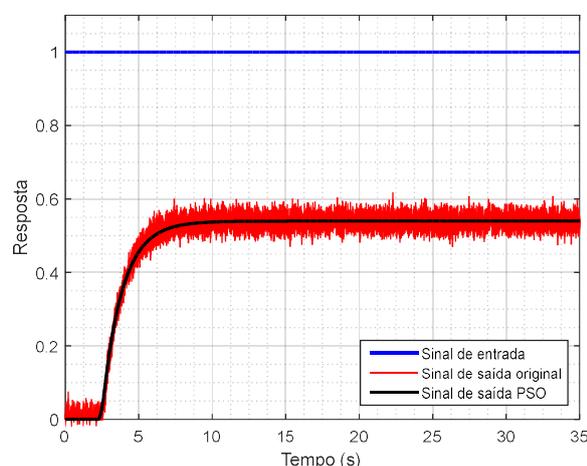


Figura 6. Resposta ao degrau unitário do sistema no caso 1

Os resultados do caso 1 mostram que o APSO alcançou melhor desempenho no tempo médio de processamento, pois alcançou o menor tempo, além de ter estabilizado seu EQM médio com menos iterações que as demais IE, indicando que esta IE foi mais rápida neste caso. Por outro lado, o PSO e o PSO-Co obtiveram melhor performance na acurácia e na precisão respectivamente.

• **Caso 2: Sistema lento com erro de regime permanente nulo**

Para o caso 2 considerou-se o sistema com função de transferência da equação (26), onde $K = 1$ e $T = 6,3$.

$$G(s) = \frac{1}{6,3s + 1} \quad (26)$$

A Tabela 8 mostra os valores de média e desvio padrão dos coeficientes estimados pelas IE. A Tabela 9 mostra os valores de média e desvio padrão da acurácia, e as precisões das IE no caso 2.

Tabela 8. Valores médio e de desvio padrão dos parâmetros estimados no caso 2.

	Média de K	Desvio Padrão de K	Média de T	Desvio Padrão de T
PSO	0,9996	0,0027	6,2948	0,0698
PSO-Co	1,0004	0,0023	6,3087	0,0698
APSO	1,0006	0,0024	6,2973	0,0572
Valores Reais	1,0	-	6,3	-

Tabela 9. Acurácia e precisão no caso 2.

	Média da Acurácia	Desvio Padrão da Acurácia	Precisão
PSO	99,9539	0,0290	27,5862
PSO-Co	99,9538	0,0283	27,7393
APSO	99,9560	0,0278	33,5570

Para o caso 2, o APSO obteve o melhor desempenho em estimar os parâmetros da planta, tanto em questão de exatidão quanto em precisão, o que comprova as médias de K e T estimados por essa IE.

A Tabela 10 e a Figura 7 mostram respectivamente o tempo médio de processamento e o EQM médio por iteração dos algoritmos no caso 2.

Tabela 10. TMP dos algoritmos no caso 2.

	Tempo Médio de Processamento (s)
PSO	17,4767
PSO-Co	7,5629
APSO	6,2961

Os resultados do caso 2 mostram que o APSO obteve o melhor desempenho nas métricas de acurácia e precisão, além do menor tempo médio de processamento. E o PSO levou menos iterações que as demais IE para estabilizar seu EQM médio.

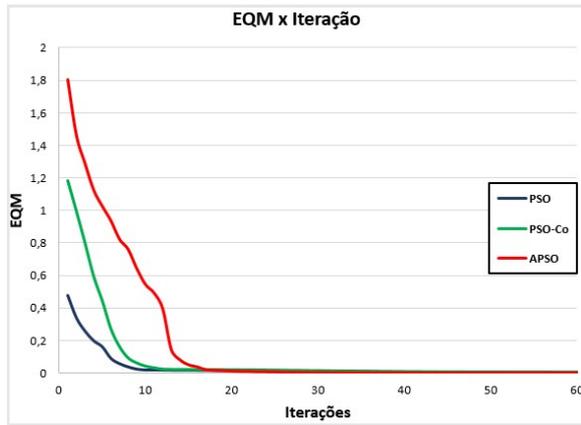


Figura 7. EQM médio por iteração dos algoritmos no caso 2

A Figura 8 mostra a resposta do sistema do caso 2 estimado pelo APSO, pois este obteve a melhor acurácia.

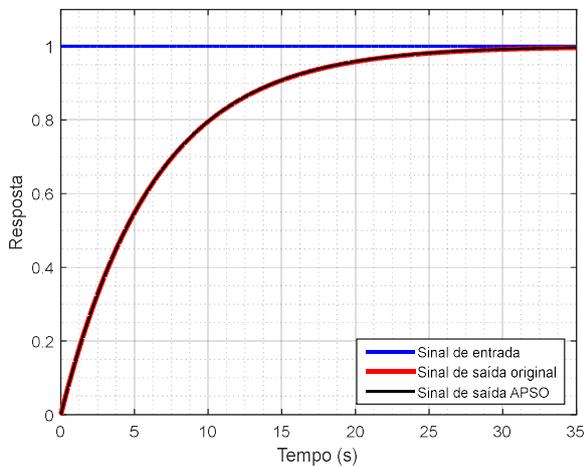


Figura 8. Resposta ao degrau unitário do sistema no caso 2

5.2 Sistemas de 2ª ordem

Para avaliar o desempenho dos algoritmos na identificação de sistemas de 2ª ordem utilizou-se uma planta contaminada por ruído com os quatro parâmetros para serem identificados.

As IE neste caso foram ajustadas conforme a Tabela 11.

Tabela 11. Parâmetros das IE para sistemas de 2º ordem.

Inteligência de Enxame	Enxame	w	$c_{1,2}$	V_{min}	V_{max}
PSO	40	0,8	2,0	-0,1	0,1
PSO-Co	30	-	2,01	-0,1	0,1
APSO	30	0,8	2,0	-0,1	0,1

- **Caso 3: Sistema com muita oscilação, com erro de regime nulo e atraso**

Para o caso 3 utilizou-se um sistema com função de transferência da equação (27), onde $K = 2$; $\zeta = 0,1$; $w_n = 0,4$ e $\theta = 10$. Esse sistema apresenta contaminação por ruído em sua saída.

$$G(s) = \frac{0,32}{s^2 + 0,08s + 0,16} e^{-10s} \quad (27)$$

Os limites de busca dos parâmetros desta planta de 2ª ordem são mostrados na Tabela 11, os quais foram definidos conforme as equações (16) a (19), possibilitando uma região de busca abrangente para a maioria das situações de identificação paramétrica. A Tabela 12 mostra os valores de média e desvio padrão dos coeficientes estimados. A Tabela 13 mostra os valores de média e desvio padrão da acurácia, e as precisões das IE no caso 3.

Tabela 11. Limites de busca dos parâmetros da planta do caso 3

Parâmetro da Planta	Limite Inferior	Limite Superior
K	0	3,5031
ζ	0	1,0
w_n	0	2,8917
θ	0	17,21

Tabela 12. Valores médio e de desvio padrão dos parâmetros estimados no caso 4.

	Média de K	Desvio Padrão de K	Média de ζ	Desvio Padrão de ζ
PSO	1,9993	0,0051	0,1006	0,0014
PSO-Co	1,9996	0,0049	0,0999	0,0016
APSO	2,0009	0,0046	0,1004	0,0015
Valores Reais	2,0	-	0,1	-
	Média de w_n	Desvio Padrão de w_n	Média de θ	Desvio Padrão de θ
PSO	0,4003	0,0005	9,9992	0,0315
PSO-Co	0,3999	0,0007	10,0089	0,0376
APSO	0,4001	0,0009	10,0066	0,0421
Valores Reais	0,4	-	10,0	-

Tabela 13. Acurácia e precisão no caso 3.

	Média da Acurácia	Desvio Padrão da Acurácia	Precisão
PSO	97,3820	0,2811	103,6855
PSO-Co	97,3413	0,1741	89,2253
APSO	97,2655	0,1591	81,3090

A Tabela 15 e a Figura 9 mostram respectivamente o tempo médio de processamento e o EQM médio por iteração dos algoritmos no caso 3.

Tabela 15. TMP dos algoritmos no caso 3.

	Tempo Médio de Processamento (s)
PSO	55,0754
PSO-Co	44,9025
APSO	39,2902

A Figura 10 mostra a resposta da planta do caso 3 estimada pelo PSO-Co, que teve melhor acurácia.

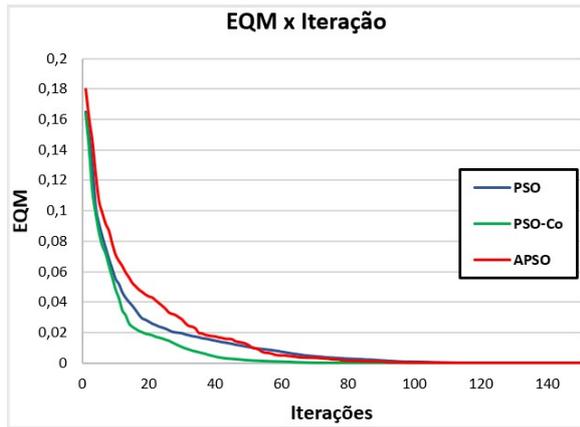


Figura 9. EQM médio por iteração dos algoritmos no caso 3

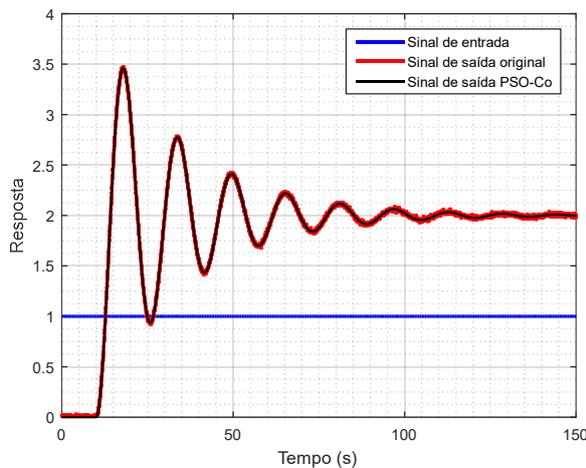


Figura 10. Resposta ao degrau unitário do sistema no caso 3

Em uma análise geral do caso 3, o PSO-Co obteve o melhor desempenho em acurácia, pois alcançou a segunda maior média e um dos menores desvio padrão, além de ter levado menos iterações entre as IE para estabilizar o EQM médio. Por outro lado, a maior precisão e o menor TMP foram alcançados pelo PSO e o APSO respectivamente.

6 Conclusão

Este trabalho apresentou as principais características dos algoritmos APSO, PSO, PSO-Co, ressaltando a aplicação dessas IE na identificação *off-line* de sistemas lineares de 1ª e 2ª ordem.

Realizou-se a comparação das três IE na identificação paramétrica de duas plantas de 1ª ordem e uma de 2ª ordem, totalizando 3 estudos de casos. Esta comparação foi feita com base em métricas de avaliação de desempenho como precisão, acurácia e tempo médio de processamento, as quais são de fundamental importância na análise do comportamento dos algoritmos.

Por meio dos resultados foi possível verificar que as metaheurísticas possuem um bom desempenho e podem ser usadas na identificação *off-line* de sistemas lineares de 1ª e 2ª ordem. Também se observou que o algoritmo APSO alcançou, em uma análise geral de todos os casos, a melhor performance em

relação ao tempo de processamento, embora a precisão e a acurácia tenha sido tão boa quanto as alcançadas pelo PSO e PSO-Co, o que no entanto não inviabiliza o uso desta IE adaptativa, uma vez que os valores médios estimados dos parâmetros, em cada estudo de caso, são próximos aos valores reais, mesmo no caso de planta com resposta contaminada com ruído.

Agradecimentos

Agradecemos a UFPA e ao Instituto de Tecnologia (ITEC) por apoiar esta pesquisa.

Referências Bibliográficas

- Aguirre, L. A. (2015). Introdução à identificação de sistemas: técnicas lineares e não lineares: teoria e aplicação / - 4. ed. rev. - Belo Horizonte: Editora UFMG.
- Clerc, M. e Kennedy, J. (2002). The particle swarm – explosion, stability, and convergence in a multi-dimensional complex space. IEEE transactions on evolutionary computation, vol. 6, no. 1.
- Coelho, A. A. R. (2004). Identificação de Sistemas Dinâmicos Lineares. Florianópolis: 1 ed. Editora UFSC.
- Gilat, Amos. (2006). MATLAB com aplicações em engenharia: tradução Glayson Eduardo de Figueiredo. – 2 ed. – Porto alegre: Bookman.
- Kennedy, J. e Eberhart, R. (1995). Particle swarm optimization. Proceedings of 1995 IEEE International Conference on Neural Networks, pp. 1942 -1948.
- Kumar, V E. e Jerome, J. (2014). An adaptive particle swarm optimization algorithm for robust trajectory tracking of a class of under actuated system. Archives of Electrical Engineering, vol. 63(3), pp. 345-365.
- Modares, H; Alfí, A e Sistani M. N. (2010). Parameter estimation of bilinear systems based on an adaptive particle swarm optimization. Engineering Applications of Artificial Intelligence 23, 1105–1111.
- Modares, H. e Alfí, A. (2011). System identification and control using adaptive particle swarm optimization. Applied Mathematical Modelling 35, 1210–1221.
- Pontes, M. R. (2010). Otimização por Enxames de Partículas utilizando Clãs com Comportamento Adaptativo. Dissertação (mestrado) – Universidade de Pernambuco. Programa de Pós-Graduação em Engenharia da Computação.
- Unbehauen, H., and Rao, G.P. (1990). Continuous-time approaches to system identification — a survey. Automatica, 26, (1), pp. 23–35
- Zhan, Z. et al. (2009). Adaptive Particle Swarm Optimization. IEEE Transactions on Systems, Man, and Cybernetics—part b: Cybernetics, vol. 39, no. 6.