

# Simultaneous Tuning of AVR and PSS Using Particle Swarm Optimization with Two Stages

F. W. Rodrigues, Y. P. M. Rodriguez and C. S. Araújo

**Abstract**— This work presents a new method for simultaneous adjustment of automatic voltage regulator (AVR) and power system stabilizer (PSS) parameters to control voltage oscillations and damping in a synchronous generator using the particle swarm optimization algorithm (PSO) with two stages. The increment of a new stage aims to improve the efficiency of the PSO method, providing a better performance of the system. The algorithm was developed in Matlab software and used for the linearized 3-order model of a synchronous generator connected to an infinite bus. To analyze the performance of the controllers an objective function was used based on the system time response to a change in the reference voltage. The results were compared with the values found by the classical design method of the conventional tuning technique.

**Index Terms**— Automatic Voltage Regulator, Stabilizer System Power, Particle Swarm Optimization.

## I. INTRODUÇÃO

O controle do sistema de potência requer um equilíbrio contínuo entre a geração elétrica e a demanda variável das cargas, de modo que os níveis de tensão e frequência permaneçam dentro dos limites aceitáveis [1]. Logo, a necessidade de um sistema de excitação de alto desempenho tornou-se mais adequado para manter o estado estacionário e a estabilidade transitória dos geradores nos sistemas de potência [2].

Os sistemas de excitação utilizam o Regulador Automático de Tensão (AVR – *Automatic Voltage Regulation*) para manter a magnitude da tensão terminal dos geradores síncronos em um nível desejado. O AVR também desempenha a função de controle de potência reativa, que ajuda na melhora da estabilidade dos sistemas [3]-[5].

A utilização de sistemas de excitação de alto desempenho tem causado melhoria na estabilidade transitória e no controle rápido da tensão terminal dos geradores síncronos. Porém, a ação rápida desse sistema, com alto valor de ganho do AVR, pode ocasionar a perda da estabilidade oscilatória do sistema

Submetido em: 17 de Setembro de 2019.

F. W. Rodrigues, Universidade Federal da Paraíba, Departamento de Engenharia Elétrica, João Pessoa, Paraíba, Brasil (e-mail: frank.rodrigues@cear.ufpb.br).

Y. P. M. Rodriguez, Universidade Federal da Paraíba, Departamento de Engenharia Elétrica, João Pessoa, Paraíba, Brasil (e-mail: molina.rodriguez@cear.ufpb.br).

C. S. Araújo, Universidade Federal da Paraíba, Departamento de Engenharia Elétrica, João Pessoa, Paraíba, Brasil (e-mail: clivaldo@cear.ufpb.br).  
de potência [6].

Uma das maneiras mais comum de conseguir o amortecimento das oscilações eletromecânicas é através do Estabilizador de Sistema de Potência (PSS – *Power System Stabilizer*) [7]. O PSS é representado por uma malha de controle adicional, inserida na referência de tensão do AVR, onde é capaz de compensar o amortecimento negativo causado pelo AVR e amortecer as oscilações do rotor através da modulação do sinal de entrada do sistema de excitação.

Para o projeto dos controladores AVR e PSS é importante levar em consideração a variação do ponto de operação do gerador síncrono. Os controladores devem se manter estáveis e demonstrar um nível de desempenho durante uma perturbação, ou seja, devem apresentar robustez para variações no sistema. Para que o projeto do AVR e PSS seja robusto, ambos devem ser ajustados de maneira coordenada, isto é, não devem ser determinados de maneira independente [8].

Uma variedade de técnicas de projeto convencional pode ser utilizada para ajustes dos parâmetros dos controladores, como: posicionamento dos polos [9]-[10], método dos resíduos [11], sensibilidade dos autovalores [12]. Porém, esses métodos convencionais apresentam convergência lenta, grande esforço computacional além de poderem convergir para soluções de ótimos locais [13].

Várias técnicas de computação evolucionária estão sendo utilizadas para o ajuste do AVR e PSS, entre os métodos mais conhecidos estão: Algoritmo Genético [14]-[15], Otimização por Enxame de Partícula (PSO – *Particle Swarm Optimization*) [2,16,17], Busca Tabu [18]-[19], Evolução Diferencial [20], *Simulated Annealing* [21]. Entre esses métodos, o PSO aparece com destaque, devido o mesmo produzir uma excelente solução dentro de um tempo de cálculo curto e uma boa característica de convergência [22]. O PSO pode lidar com problemas imprecisos sem considerar a complexibilidade e a não linearidade do sistema, fazendo com que a sua solução apresente um bom desempenho [23]. Geralmente, o PSO é conhecido por apresentar um conceito simples, fácil de executar e computacionalmente efetivo.

No entanto, a utilização da técnica de PSO depende muito dos seus parâmetros e muitas às vezes podem sofrer com problema de mínimos ou máximos locais, o que acaba por comprometer o seu desempenho [16].

Este artigo apresenta uma variação para a técnica de PSO [24], que é caracterizada pela adição de um segundo estágio no algoritmo do mesmo. O novo estágio é caracterizado após a execução de um número definido de simulações do primeiro estágio, onde o segundo estágio define um novo limite para os parâmetros dos controladores através das melhores e piores soluções encontrados durante o conjunto de simulações realizadas no primeiro estágio. A adição do segundo estágio

na técnica de PSO tem como objetivo proporcionar a fuga de pontos de máximos ou mínimos locais através da redução do espaço de busca dos parâmetros, possibilitando assim um melhor ajuste dos mesmos.

O PSO em dois estágios é aplicado para o ajuste dos parâmetros do AVR e do PSS, a fim de melhorar a estabilidade transitória e diminuir as oscilações do sistema de potência. Como forma de verificar o desempenho do método proposto é utilizada uma função objetivo baseada na resposta no tempo do Sistema Máquina Barra Infinita (SMIB – *System Machine Infinity Bus*) para uma variação na tensão de referência. Os resultados obtidos pelo método proposto foram comparados com os valores determinados por [24] através da técnica clássica de sintonia elaborada em [25].

## II. MODELO LINEARIZADO DO SISTEMA EM ESTUDO

Nesta seção, é apresentado o modelo linearizado de uma máquina síncrona ligada um grande sistema de potência através de uma linha de transmissão, válido para o estudo de estabilidade a pequenos sinais. Na Fig. 1 é possível observar a configuração geral de um sistema SMIB.




Fig. 1. Sistema máquina barra infinita (SMIB).

A máquina é representada pelo modelo linearizado de terceira ordem, onde são considerados apenas os efeitos dos enrolamentos de armadura e do enrolamento de campo. Este modelo é bastante utilizado para o estudo de oscilações de baixa frequência [6]. As Equações, após a transformação de Park, que representam o processo de operação em estado estacionário da máquina síncrona conectada por meio de uma linha de transmissão ( $Z_{eq} = R_E + jX_E$ ) ao barramento infinito podem ser linearizadas e apresentadas da seguinte forma:

$$\frac{d^2\delta}{dt^2} = \frac{\pi f}{H} (P_m - P_e) \quad (1)$$

$$\dot{e}'_q = \frac{1}{T'_{d0}} [E_{fd} - (x_d - x'_d)i_d - e'_q] \quad (2)$$

Onde,  $P_m$  e  $P_e$  são as potências mecânica e elétrica do gerador ambas em por unidade;  $H$  é a constante de inércia em segundo da máquina;  $\delta$  é a ângulo do rotor em radianos elétricos;  $E_{fd}$  é a tensão de campo;  $e'_q$  tensão interna atrás reatância transitória no eixo em quadratura;  $T'_{d0}$  é a constante de tempo transitória de circuito aberto;  $x_d$  é a reatância do eixo direto e  $x'_d$  é a reatância transitória do eixo direto, respectivamente e  $i_d$  é a corrente de armadura no eixo direto.

Diferentes tipos de sistema de excitação são descritos em [26]. Este trabalho utiliza o modelo de excitação estático STIC simplificado (substituto do ST1A), que atua diretamente

no enrolamento de campo da máquina síncrona e a retificação do campo é realizada por retificadores estáticos controlados. O modelo utilizado é de primeira ordem, onde os parâmetros  $K_A$  e  $T_A$  são referentes ao ganho e a constante de tempo do regulador, respectivamente.

O Estabilizador de Sistema de Potência é adicionado ao sistema de excitação para introduzir uma componente de torque de amortecimento em fase com a variação do sinal da velocidade. O PSS é composto por três blocos, o primeiro bloco representa o ganho  $K_{stab}$  do PSS. O segundo bloco corresponde ao filtro passa-alta (*washout*), onde  $T_W$  é a constante de tempo. O terceiro bloco está associado ao circuito de avanço de fase que é necessário para compensar o atraso de fase entre a entrada da excitação e o torque elétrico do gerador, as variáveis  $T_1$  e  $T_2$  correspondem as constantes de tempo.

Na Fig. 2 é ilustrado o sistema de excitação simplificado com o regulador automático de tensão (AVR) e o estabilizador de sistema de potência (PSS), essa simplificação é aceita para estudo de estabilidade para pequenos sinais [27].




Fig. 2. Diagrama de blocos do sistema de excitação com AVR e PSS.

Observa-se na Fig. 3 a representação em diagrama de blocos do modelo linearizado do sistema SMIB com o AVR e PSS.

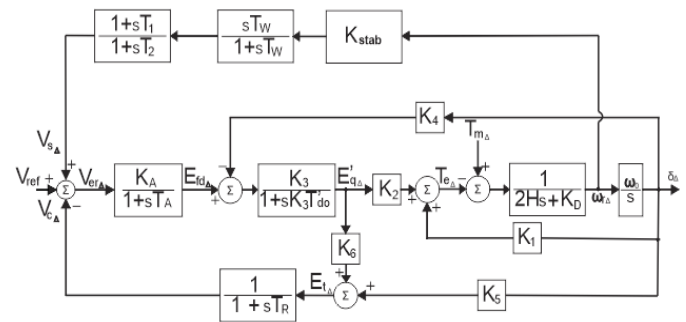


Fig. 3. Diagrama de bloco do sistema SMIB linearizado com AVR e PSS.

As constantes  $K_1$  a  $K_6$  descrevem a relação entre a velocidade do rotor e as equações de controle de tensão da máquina, que são denominadas como constantes de Heffron-Phillips [28]. Elas dependem dos parâmetros e das condições de operação da máquina e geralmente os valores  $K_1$ ,  $K_2$ ,  $K_3$  e  $K_6$  são positivos, enquanto  $K_4$  é positivo, exceto nos casos em que  $R_E$  é alto [29].  $K_5$  é positivo para cargas leves e médias, enquanto para condições de carga pesada esse valor é negativo, o que torna o torque de amortecimento ( $T_a$ ) negativo, podendo o problema de estabilidade ser ainda mais agravado para altos valores de ganho do AVR [30].

### III. PROJETO DOS CONTROLADORES AVR E PSS

Para análise da eficiência do processo de otimização, utilizou o estudo da resposta no tempo do sistema para uma entrada ao degrau unitário, que basicamente se refere à avaliação de quatro parâmetros [31]:

- Máximo sobressinal ( $M_p$ ): é o máximo valor de pico da curva da resposta;
- Erro de regime permanente ( $E_{ss}$ ): a diferença entre o sinal unitário e o valor da resposta em regime permanente;
- Tempo de acomodação ( $t_s$ ): é o tempo necessário para que a curva da resposta alcance valores na faixa de 2% ou 5% em torno de seu valor de regime permanente;
- Tempo de subida ( $t_r$ ): trata-se do tempo necessário para que a resposta passe de 0 a 100% do seu valor de regime permanente.

Na Fig. 4 é possível verificar alguns desses parâmetros para uma resposta no tempo ao degrau unitário de um sistema em malha fechada.




Fig. 4. Parâmetros para resposta do sistema para uma entrada ao degrau.

Os ganhos e as constantes de tempo dos controladores AVR e PSS são projetados e otimizados através da função objetivo, cujo objetivo é melhorar a resposta do sistema em relação à oscilação e tempo de estabilização. A função objetivo utilizada para análise do desempenho dos controladores AVR e PSS foi desenvolvida por Gaing [32] e é baseada em quatro parâmetros ( $M_p$ ,  $E_{ss}$ ,  $t_s$  e  $t_r$ ) através de (3):

$$f(M_p, E_{ss}, t_s, t_r) = \frac{1}{(1 - e^{-\beta})(M_p + E_{ss}) + e^{-\beta}(t_s - t_r)} \quad (3)$$

A melhora na performance do desempenho do sistema acontece com a maximização da função objetivo observada na Equação (3). O fator de peso  $\beta$  funciona como um critério de ponderação entre os parâmetros  $M_p$  e  $E_{ss}$  com os tempos  $t_s$  e  $t_r$ . Para um valor de  $\beta$  igual a 0,7 o ponto de equilíbrio entre os parâmetros é alcançado. Enquanto valores acima de 0,7 o algoritmo tende a priorizar a redução de sobressinal e do erro em regime permanente. Por outro lado, para valores de  $\beta$  menores que 0,7 o algoritmo proporciona uma maior ênfase na redução dos tempos de subida e no tempo de acomodação do sinal da resposta.

### IV. DESCRIÇÃO E IMPLEMENTAÇÃO DO PSO EM DOIS ESTÁGIOS

Para evitar convergência para pontos de mínimos ou máximos locais ou divergência que ocorriam com frequência no processo de otimização com o uso de PSO clássico, e também para melhorar a velocidade de convergência e a precisão do PSO, muitos tipos de esquemas foram introduzidos para realçar o PSO [33]. Nesta seção será apresentada a descrição do método proposto de Otimização por Enxame de Partícula em duas etapas. Para isso, inicialmente será retratado o PSO clássico.

#### A. Otimização por Enxame de Partículas

O método de otimização por enxame de partículas (*Particle Swarm Optimization* - PSO), originalmente desenvolvido por Kennedy e Eberhart em 1995 [34], é um algoritmo de otimização evolutivo que modela o comportamento social de grupos de pássaros ou peixes em busca de alimento [35]. Tem como principais características: fácil implementação, convergência estável e boa eficiência computacional.

O PSO conduz a busca pelo ponto ótimo através de um conjunto de partículas (enxame), onde cada partícula representa uma candidata a possível solução. As partículas alteram suas posições em um espaço de busca multidimensional até que uma posição relativamente imutável seja atingida ou que as limitações do sistema sejam alcançadas [36].

Por trás do PSO existe uma teoria social cognitiva, onde cada partícula possui sua própria experiência e é capaz de estimar a qualidade dessa experiência. Como as partículas também são sociais, elas possuem conhecimento sobre o comportamento dos seus vizinhos. Portanto, a probabilidade de um determinado indivíduo tome certa decisão será em função do seu desempenho no passado e do desempenho de alguns de seus vizinhos [33].

No algoritmo do PSO, cada partícula do enxame possui uma posição e uma velocidade associada, estas podem ser representadas por  $x_i$  e  $v_i$  respectivamente, onde  $i$  representa a  $i$ -ésima partícula. As partículas são capazes de armazenar informações em relação às suas posições. O melhor valor encontrado por cada partícula é chamado de  $P_{best}$ , ou seja, toda partícula possui um  $P_{best}$  associado. O melhor valor dentre todos os  $P_{best}$  é nomeado de  $G_{best}$ . O conceito básico dessa técnica está em acelerar cada partícula na direção do seu  $P_{best}$  e da localização do  $G_{best}$ . A velocidade e a posição das partículas são atualizadas de acordo (4) e (5):

$$v_i^{t+1} = wv_i^t + c_1r_1(P_{best} - x_i^t) + c_2r_2(G_{best} - x_i^t) \quad (4)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (5)$$

Onde,  $t$  é o número da iteração;  $w$  é o fator de inércia;  $c_1$  e  $c_2$  são as constantes de aceleração social e cognitiva;  $r_1$  e  $r_2$  são dois valores aleatórios no intervalo [0,1].

O fator de inércia ( $w$ ) é atualizado através de (6), desenvolvido por Shi e Eberhart [37], onde notaram que o processo de otimização apresentava um melhor desempenho

quando o fator de inércia se apresentava na forma de decaimento linear.

$$w = w_{max} - \frac{w_{max} - w_{min}}{iter_{max}} \times iter \quad (6)$$

Onde,  $w_{max}$  é o fator de inércia inicial de valor 1,1;  $w_{min}$  é o valor final do fator de inércia e é igual a 0,1;  $iter_{max}$  é o número máximo de iterações e  $iter$  é a iteração atual.

### B. Otimização por Enxame de Partículas em Dois Estágios

Em problemas muito complexos, onde ocorre um alto grau de não linearidade do sistema, o algoritmo do PSO apresenta soluções que podem ficar presas em pontos de máximos ou mínimos locais, o que pode acabar prejudicando a eficácia do método. Este trabalho apresenta uma nova modificação no método do PSO, onde será adicionado um novo estágio no PSO, cujo objetivo é proporcionar um melhor desempenho do sistema através da tentativa de fuga de pontos de ótimos locais, possibilitando uma maior eficiência do método com relação à convergência das simulações para o ponto de ótimo global ou um subótimo próximo do ótimo global.

A proposta do PSO em dois estágios não modifica as equações descritas anteriormente para o PSO clássico, apenas acrescenta uma nova etapa para o algoritmo. Sendo assim, o novo algoritmo proposto apresentará um comportamento como descrito a seguir:

- 1º Estágio: O algoritmo será executado como descrito pelo PSO clássico, onde a velocidade e a posição das partículas são calculadas pelas Equações (4) e (5), e os limites iniciais superiores e inferiores dos parâmetros são fornecidos. Porém nesse estágio é realizado um número limitado de simulações do PSO e através dessas simulações é que são definidos novos limites para os parâmetros do segundo estágio;
- 2º Estágio: Segue o mesmo princípio da etapa anterior, mas com os limites dos parâmetros modificados através da resposta das simulações do 1º estágio. O novo intervalo é dado pela melhor e pior solução encontrada para cada parâmetro através da análise do valor da função objetivo das simulações realizadas no 1º estágio.

Essa nova modificação no PSO é aconselhável para sistemas que se apresentam altamente não lineares onde uma mudança na casa dos décimos ou milésimos em alguma de suas variáveis pode influenciar o valor da sua resposta. Esses sistemas podem apresentar problemas com relação a sua convergência devido à solução do sistema poder apresentar dificuldade em encontrar o ponto ótimo global ou subótimo próximo a este ponto. Uma solução foi realizar um novo estágio no algoritmo inicial do PSO, para que o mesmo seja executado com os novos valores limites das variáveis reduzidos. Essa modificação proporciona que o PSO consiga atuar com uma melhor eficiência e possa realizar um ajuste ainda mais fino nos valores das variáveis fazendo com que o ponto ótimo global ou subótimo próximo a este ponto consiga ser atingido de maneira mais fácil.

### C. Algoritmo para o PSO em Dois Estágios

Inicialmente será apresentado o algoritmo do PSO Clássico que é utilizado na descrição do algoritmo proposto neste trabalho. A Fig. 5 ilustra o diagrama de blocos do PSO Clássico.

1. Início;
2. Determine o número de partículas da população ( $N$ ) e o número máximo de iterações  $iter_{max}$  e os valores dos parâmetros de aprendizagem ( $c_1$  e  $c_2$ );
3. Definir os limites máximos e mínimos dos parâmetros a serem determinados;
4. Inicializa aleatoriamente a posição ( $x_i$ ) e a velocidade ( $v_i$ ) das partículas para cada variável, respeitando os limites estabelecidos para ( $x_i$ ) e ( $v_i$ );
5. De início o  $P_{best}$  é igual ao valor gerado aleatoriamente para cada partícula, já o  $G_{best}$  será o melhor valor entre as partículas;
6.  $iter = iter + 1$ ;
7. Atualiza a velocidade ( $v_i$ ), posição ( $x_i$ ) e o coeficiente de inércia ( $w$ ), utilizando as Equações (4), (5) e (6), respectivamente;
8. Calcula o valor da função objetivo para cada partícula ( $FO_i$ );
9. Defina o novo  $P_{best_i}$  e  $G_{best}$   
Se o valor de  $FO_i > P_{best_i}$   
 $P_{best_i} = FO_i$   
Se o valor de  $P_{best_i} > G_{best}$   
 $G_{best} = P_{best_i}$ ;
10. Caso o número de iterações for maior que o número máximo de iterações, vá para o para o passo (11), se não, volte o passo (6);
11. Solução do algoritmo,  $G_{best}$ ;
12. Fim do algoritmo do PSO Clássico.

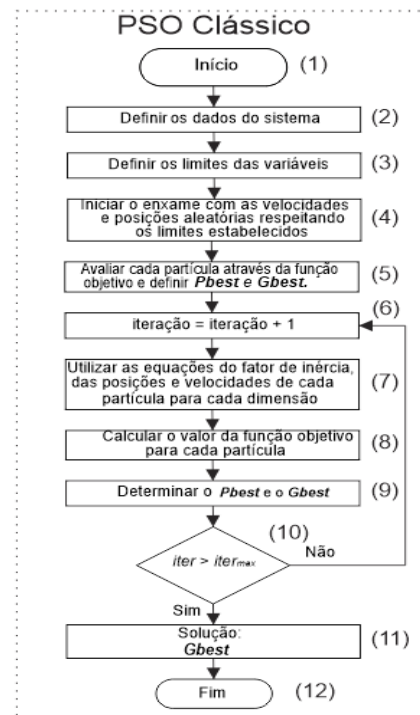


Fig. 5. Algoritmo do PSO Clássico.

O algoritmo do PSO em dois estágios foi dividido em nove passos. Para facilitar o entendimento do algoritmo e proporcionar uma visualização em blocos, gerou-se um fluxograma apresentado na Fig. 6.

1. Início;
2. O algoritmo inicia uma nova *simu* (simulação), essa variável também é utilizada como contador do número de simulações executadas no primeiro estágio;
3. PSO Clássico é simulado como descrito no seu algoritmo;
4. Caso o número de simulações no primeiro estágio seja atingido vá para o passo (5), caso contrário volte para o passo (2);
5. A solução do primeiro estágio é dada pela melhor e pior valor dos  $G_{best}^1$  das simulações realizadas nesse estágio;
6. É definido um novo limite para os parâmetros do espaço de busca de acordo com a solução do primeiro estágio;
7. Inicia o segundo estágio através de uma nova simulação do PSO Clássico, com os novos limites dos parâmetros do espaço de busca;
8. A solução do algoritmo do PSO com dois estágios será o valor de  $G_{best}^2$ ;
9. Fim.

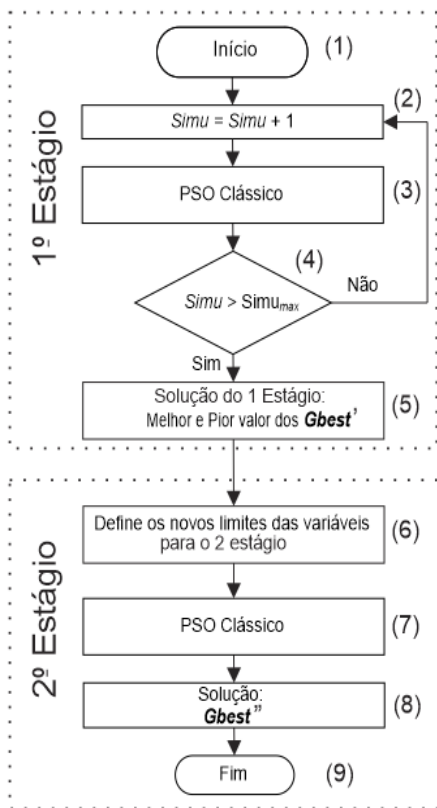


Fig. 6: Algoritmo do PSO com dois estágios.

## V. SIMULAÇÃO E RESULTADOS

O sistema considerado neste trabalho é o modelo do sistema SMIB com AVR e PSS apresentado na Fig. 3, cuja implementação foi realizada no ambiente *Simulink* do Matlab.

A constante  $K_A$  do AVR e os parâmetros  $K_{stab}$ ,  $T_1$  e  $T_2$  do PSS serão determinados através do método do PSO em dois estágios. Com relação às constantes  $T_A$  do AVR e  $T_W$  do PSS, elas podem variar entre 0,01-0.1s e 1-10s, respectivamente. Neste trabalho foi selecionado um valor de 0,02s para  $T_A$  e 1s para  $T_W$ . Na Tabela I é possível observar os limites superiores e inferiores dos parâmetros a serem determinados inicialmente pelo PSO com dois estágios. Os dados do sistema bem como os limites dos parâmetros estão disponíveis em [24].

TABELA I  
LIMITES DOS PARÂMETROS DO AVR E PSS

Parâmetros	$K_A$ (p.u.)	$K_{stab}$ (p.u.)	$T_1$ (s)	$T_2$ (s)
Limite inferior	1	0,1	1	0,0001
Limite superior	400	2	3	0,5

Para o sistema em estudo, utilizou-se o algoritmo descrito na Fig. 6. e adotou-se os seguintes valores de simulação para os parâmetros do PSO em dois estágios, como indicado na Tabela II.

TABELA II  
PARÂMETROS PARA SIMULAÇÃO DO PSO COM DOIS ESTÁGIOS

Parâmetros	Valor
Número de partículas ( $N$ )	100
$c_1$ e $c_2$	0,5 e 1,5
$w_{min}$ e $w_{max}$	0,1 e 1,1
Número de simulação no 1º estágio ( <i>simu</i> )	10

Para determinar o número de iterações necessárias para cada simulação do PSO no primeiro estágio, realizou-se 100 simulações com o PSO clássico variando o número de iteração como o indicado na Tabela III.

TABELA III  
DESEMPENHO DO PSO PARA VARIAÇÃO NO NÚMERO DE ITERAÇÕES

Número de Iterações	Função Objetivo			
	Maior	Menor	Média ( $\bar{x}$ )	Desvio padrão ( $\sigma$ )
50	14,0089	10,0911	11,1733	2,1647
100	14,3825	10,1109	12,7326	1,7760
500	13,9932	7,1109	10,4389	2,5714
1000	13,9901	7,0907	10,2981	2,8729

Como verificado pela Tabela III, o PSO apresentou um melhor desempenho para o número de iterações igual a 100. Para um número de iteração menor que 100, ocorreu a convergência prematura das partículas nas primeiras iterações. Enquanto, para um número de iteração maior que 100 as partículas demoravam muito para sua convergência e acabavam ficando presas em pontos de ótimos locais.

Na Tabela IV é possível verificar os valores dos parâmetros do AVR e PSS determinados pelas simulações realizadas no 1º estágio com o PSO com o número de iterações igual 100.



TABELA IV  
PARÂMETROS DO AVR E PSS DETERMINADOS PELO PSO NO 1º ESTÁGIO

Simulação	$K_A$ (p.u.)	$K_{stab}$ (p.u.)	$T_1$ (s)	$T_2$ (s)	Função Objetivo
1	306,2312	0,1000	1,1344	0,0113	<b>14,3825</b>
2	297,7762	0,1000	1,0893	0,0001	13,9984
3	222,5474	0,1244	3,0000	1,0893	<b>10,0872</b>
4	297,7762	0,1000	1,0893	0,0001	13,9984
5	306,5498	0,1000	1,1418	0,0113	14,3778
6	297,9724	0,1000	1,0874	0,0001	13,9932
7	297,7762	0,1000	1,0893	0,0001	13,9984
8	227,8286	0,3538	1,0001	0,0367	10,1246
9	305,8685	0,1000	1,1303	0,0001	14,3732
10	223,7531	0,1236	2,9628	0,0392	10,0921

Observando a Tabela IV é possível notar que as simulações realizadas no 1º estágio apresentam uma grande variação em relação aos valores dos parâmetros determinados, logo isso acaba por prejudicar a eficácia do método, tendo em vista que muitas vezes suas soluções ficam presas em pontos de ótimos locais. Como forma resolver esse problema, foi desenvolvida uma maneira simples que possa fornecer esse benefício, no qual consiste na adição de um segundo estágio para o PSO. Esse novo estágio realiza uma nova execução para o PSO, onde os limites dos parâmetros são dados pela melhor e pior solução encontradas através da análise do valor função objetivo das simulações realizadas no primeiro estágio. No caso em estudo, o limite superior é dado pelos valores dos parâmetros determinado na simulação 1 (maior valor da função objetivo) e o limite inferior é dado pelos parâmetros encontrados na simulação 3 (menor valor da função objetivo).

Para análise do desempenho da adição do novo estágio no algoritmo do PSO, realizou-se 100 simulações do PSO com o segundo estágio. Na Tabela V é possível notar o comportamento do sistema com relação a qualidades das simulações.

TABELA V  
INDICADORES DA TAXA DE CONVERGÊNCIA DAS SIMULAÇÕES DO PSO

Método	Função Objetivo			Desvio padrão ( $\sigma$ )
	Maior	Menor	Média ( $\bar{x}$ )	
PSO com 2 estágios	14,3842	14,3793	14,3821	0,0022

Analisando a Tabela V, percebe-se que o método do PSO com dois estágios proporcionou uma ótima convergência entre as simulações, isso pode ser notado através do baixo valor do desvio padrão e pelo valor da média que se aproxima muito do maior valor encontrado durante as simulações. Na Tabela VI é possível verificar uma comparação entre os parâmetros obtidos através do PSO com dois estágios com os valores determinados por [24] através da técnica clássica de sintonia desenvolvida em [25] e é baseada em aproximações de equações que descrevem o sistema.

TABELA VI  
PARÂMETROS DETERMINADOS PELO MÉTODO CLÁSSICO E PSO COM 2 ESTÁGIOS

Método	$K_A$ (p.u.)	$K_{stab}$ (p.u.)	$T_1$ (s)	$T_2$ (s)	Função Objetivo
Clássico	197,2500	0,2	0,7261	0,0051	3,1245
PSO com 2 estágios	306,1379	0,1	1,1349	0,0117	14,3842

A fim de analisar o desempenho do algoritmo aplicou-se um sinal degrau unitário na tensão de referência ( $V_{ref}$ ) e observou-se a resposta no tempo da tensão terminal e do ângulo do rotor da máquina síncrona, conforme apresentado nas Fig. 7 e Fig. 8 respectivamente, com os valores dos parâmetros do AVR e PSS apresentados na Tabela VI.

Observando a Fig. 7 e Fig. 8, nota-se que o ajuste do AVR e PSS realizado pelo PSO com dois estágios obteve um melhor desempenho em comparação ao método clássico, possibilitando uma redução da diferença entre o tempo de acomodação e o tempo de subida, porém mantendo o erro em regime permanente e o máximo sobressinal dentro dos limites desejados.

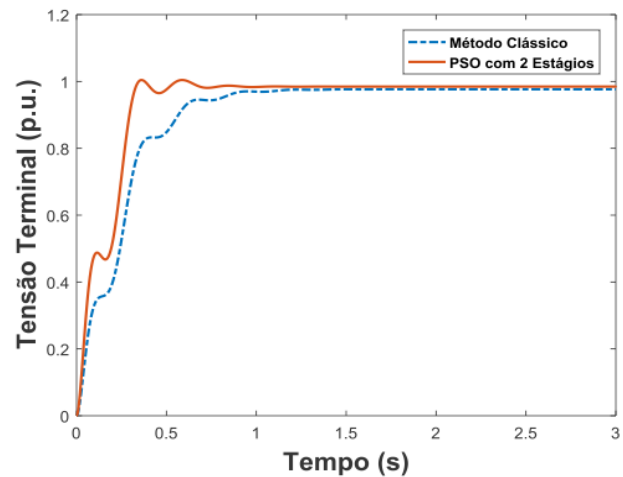


Fig. 7. Comportamento da tensão terminal para uma entrada degrau unitário na tensão de referência.

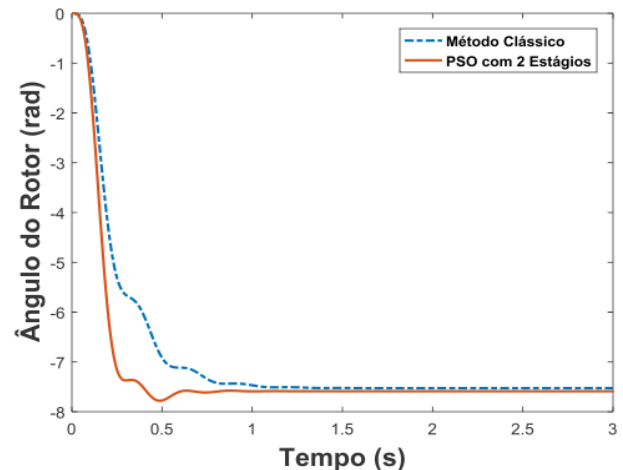


Fig. 8. Comportamento do ângulo do rotor para uma entrada degrau unitário na tensão de referência.

Na Tabela VII verifica-se uma comparação entre os principais indicadores da resposta temporal para sintonia dos parâmetros do AVR e PSS para a curva da tensão terminal.

TABELA VII  
COMPARAÇÃO ENTRE OS ÍNDICES DA RESPOSTA TEMPORAL PARA OS DOIS MÉTODOS

Método	Tensão Terminal				Ângulo do Rotor		
	$M_p$ (%)	$E_{SS}$ (%)	$t_s$ (s)	$t_r$ (s)	$M_p$ (%)	$t_s$ (s)	$t_r$ (s)
Clássico	0,00	2,35	0,76	0,46	0,00	0,74	0,37
PSO com 2 estágios	1,97	1,52	0,31	0,26	1,51	0,27	0,15

## VI. CONCLUSÕES

Neste trabalho foi apresentado o projeto simultâneo do AVR e PSS para um SMIB utilizando PSO com dois estágios. Adição de um novo estágio mostrou um melhor desempenho quando comparada com a técnica clássica, apresentando uma redução na diferença entre os tempos de acomodação e de subida e mantendo o sobressinal e o erro de regime permanente dentro dos limites desejados. Com relação a eficiência do algoritmo foi possível observar que o mesmo apresenta uma boa taxa de convergência, que pode ser notado pelo pequeno valor do desvio padrão e pelo valor da média das simulações que se aproxima do maior valor determinado. Sendo assim o PSO com dois estágios cumpriu com os objetivos, tendo em vista que conseguiu resolver o problema de baixa eficiência e qualidade das simulações enfrentadas pela técnica de PSO clássico.

## REFERÊNCIAS

- [1] P. Kundur, N. J. Balu and M. G. Lauby. *Power System Stability and Control*. vol. 7. New York: McGraw-hill, 1994.
- [2] A. M. El-Zonkoly, "Optimal tuning of power systems stabilizers and AVR gains using particle swarm optimization," *Expert Systems with Applications*, vol. 31, no. 3, pp. 551-557, 2006.
- [3] K. Hirayama *et al.*, "Digital AVR application to power plants," *IEEE Transactions on Energy Conversion*, vol. 8, no. 4, pp. 602-609, 1993.
- [4] A. Dysko, W. E. Leithead, J. O'reilly, "Enhanced power system stability by coordinated PSS design," *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 413-422, 2009.
- [5] A. Mahabuba, M. A. Khan, "Small signal stability enhancement of a multimachine power system using robust and adaptive fuzzy neural network based power system stabilizer," *European Transactions on Electrical Power*, vol. 19, no. 7, pp. 978-1001, 2009.
- [6] F. P. D. Mello, C. Concordia, "Concepts of synchronous machine stability as affected by excitation control," *IEEE Transactions on Power Apparatus and Systems*, vol. 88, no. 4, pp. 316-329, 1969.
- [7] K. Sundareswaran, S. R. Begun, "Genetic tuning of a power system stabilizer," *European Transactions on Electrical Power*, vol. 14, no. 3, pp. 151-160, 2004.
- [8] H. Bourles, S. Peres, M. P. Houry, "Analysis and design of a robust coordinated AVR/PSS," *IEEE Transactions on Power Systems*, vol. 13, no. 2, pp. 568-575, 1998.
- [9] P. S. Rao, I. Sen, "Robust pole placement stabilizer design using linear matrix inequalities," *IEEE Transactions on Power Systems*, vol. 15, no. 1, pp. 313-319, 2000.
- [10] M. A. Abido, "Pole placement technique for PSS and TCSC-based stabilizer design using simulated annealing," *International Journal of Electrical Power & Energy Systems*, vol. 22, no. 8, pp. 543-554, 2000.

- [11] G. Gurralla, I. Sen, "Power system stabilizers design for interconnected power systems," *IEEE Transactions on Power Systems*, vol. 25, no. 2, pp. 1042-1051, 2010.
- [12] D. P. Ke, C. Y. Chung and Y. Xue, "An eigenstructure-based performance index and its application to control design for damping inter-area oscillations in power systems," *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2371-2380, 2011.
- [13] S. Panda, N. P. Padhy, "Optimal location and controller design of STATCOM for power system stability improvement using PSO," *Journal of the Franklin Institute*, vol. 345, no. 2, pp. 166-181, 2008.
- [14] B. Selvabala, D. Devaraj, "Co-ordinated design of AVR-PSS using multi objective genetic algorithm," in *International Conference on Swarm, Evolutionary, and Memetic Computing*. Springer, Berlin, Heidelberg, 2010. pp. 481-493.
- [15] A. Kahouli, T. Guesmi, H. H. Adballah, A. Ouali, "A genetic algorithm PSS and AVR controller for electrical power system stability", in *2009 6th International Multi-Conference on Systems, Signals and Devices*. IEEE, 2009. pp. 1-6.
- [16] J. Usman, M. W. Mustafa, G. Aliyu, B. U. Musa, "Coordinated AVR-PSS for Transient Stability Using Modified Particle Swarm Optimization," *Jurnal Teknologi*, vol. 67, no. 3, 2014.
- [17] A. D. Falehi, M. Rostami and H. Mehrjadi, "Transient stability analysis of power system by coordinated PSS-AVR design based on PSO technique," *Engineering*, vol. 3, no. 05, pp. 478, 2011.
- [18] M. A. Abido, Y. L. Abdel-Magid, "Robust design of multimachine power system stabilisers using tabu search algorithm," *IEE Proceedings-Generation, Transmission and Distribution*, vol. 147, no. 6, pp. 387-394, 2000.
- [19] S. S. Farahani, M. Nikzad, M. G. Naraghi, M. B. Tabar, A. Javadian, "Power System Stabilizer Parameters Tuning Based on Tabu Search in a Multi Machine Power System", *Australian Journal of Basic and Applied Sciences*. vol.5, no. 8, pp. 624-630, 2011.
- [20] B. Selvabala, D. Devaraj, "Co-ordinated tuning of AVR-PSS using differential evolution algorithm," in *2010 Conference Proceedings IPEC*. IEEE, pp. 439-444, 2010.
- [21] S. S. Farahani, M. Nikzad, M. B. Tabar, M. G. Naraghi, A. Javadian, "Multi-machine Power System Stabilizer Adjustment using Simulated Annealing," *Indian Journal of Science and Technology*. vol.4, no.8, pp. 886-889, 2011.
- [22] A. M. El-Zonkoly, A. A. Khalil and N. M. Ahmied, "Optimal tuning of lead-lag and fuzzy logic power system stabilizers using particle swarm optimization," *Expert Systems with Applications*, vol. 36, no. 2, pp. 2097-2106, 2009.
- [23] M. Shafiullah, M. J. Rana and M. A. Abido, "Power system stability enhancement through optimal design of PSS employing PSO," in *2017 4th International Conference on Advances in Electrical Engineering (ICAEE)*. IEEE, 2017. pp. 26-31, 2017.
- [24] J. N. Junior, "Sintonia Ótima de Regulador Automática de Tensão e Estabilizador de Sistema de Potência Utilizando Algoritmo de Otimização por Enxame de Partículas". Dissertação (Mestrado), UFCE, Fortaleza, CE, Brasil, 2012.
- [25] P. M. Anderson, A. Fouad, *Power System Control and Stability*. John Wiley & Sons, 2008.
- [26] IEEE Recommended Practice for Excitation System Models for Power System Stability Studies, *IEEE Std 421.5-2016 (Revision of IEEE Std 421.5-2005)*, pp. 1-207, 2016.
- [27] Y. A. Baza, S. M. Cozo and R. L. Nayeli, "Excitation System Type ST1 for a Synchronous Machine", *International Journal of Engineering and Science*. vol. 4, no. 4, pp. 44-53, 2015.
- [28] W. Heffron, R. Phillips, "Effect of a modern amplidyne voltage regulator on underexcited operation of large turbine generators," *Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems*, vol. 71, no. 3, pp. 692-697, 1952.
- [29] K. R. Padiyar, *Power System Dynamics: Stability and Control*. New York: John Wiley, 1996.
- [30] W. S. Mota, *Simulação de Transitórios Eletromecânicos em Sistemas de Potência*. Campina Grande: EPGRAF, 2006.
- [31] H. F. Ogata. *Engenharia de Controle Moderno*, 5. ed. São Paulo, Pearson Prentice Hall, 2010.
- [32] Z. L. Gaing, "A particle swarm optimization approach for optimum design of PID controller in AVR system," *IEEE Transactions on Energy Conversion*, vol. 19, no. 2, pp. 384-391, 2004.
- [33] A. B. Serapião, "Fundamentos de otimização por inteligência de enxames: uma visão geral," *Sba: Controle & Automação Sociedade Brasileira de Automática*, vol. 20, no. 3, pp. 271-304, 2009.

- [34] J. Kennedy, R. Eberhart, "Particle swarm optimization," in *Proceedings of the 1995 IEEE International Conference on Neural Networks*, vol. 4, no. 1, pp. 1942-1948, 1995.
- [35] R. A. Pegado, Y. P. Rodriguez, "Distribution Network Reconfiguration with the OpenDSS using Improved Binary Particle Swarm Optimization," *IEEE Latin America Transactions*, vol. 16, no. 6, pp. 1677-1683, 2018.
- [36] Abido, A. A. "Particle swarm optimization for multimachine power system stabilizer design", in *2001 Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No. 01CH37262)*, IEEE, 2001. pp. 1346-1351.
- [37] Y. Shi, R. Eberhart, "A modified particle swarm optimizer", in *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No. 98TH8360)*. IEEE., pp. 69-73, 1998.



**Frank Wesley Rodrigues** possui graduação em Engenharia Elétrica (2017) na Universidade Federal de Campina Grande. Atualmente é aluno de mestrado do Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal da Paraíba. Atuando na área de Engenharia Elétrica, com ênfase em Sistema de Potência, principalmente nos seguintes temas: dinâmica e controle de sistemas de potência.



**Yuri P. M. Rodriguez** possui graduação em Engenharia Elétrica (2003) pela Universidade Nacional de Engenharia, Lima, Peru. M.Sc. em Sistemas de Potência (2005), na Universidade Federal do Maranhão. Doutorado em Engenharia Elétrica (2009) pela Universidade Católica do Rio de Janeiro, Brasil. Atualmente é Professor Adjunto do Departamento de Engenharia Elétrica da Universidade Federal da Paraíba, Centro de Energias Alternativas e Renováveis. Seus interesses abrangem operação de sistemas de potência em ambiente competitivo.



**Clivaldo Silva Araújo** possui graduação em Engenharia Elétrica pela Universidade Federal da Paraíba (1980), Mestrado em Engenharia Elétrica pela Universidade Federal da Paraíba (1988) e doutorado em Engenharia Elétrica pela Universidade Federal da Paraíba (1992). Atualmente é professor Titular da Universidade Federal da Paraíba. Tem experiência na área de Engenharia Elétrica, com ênfase em Medição, Controle, Correção e Proteção de Sistemas Elétricos de Potência, atuando principalmente nos seguintes temas: dinâmica e controle de sistemas de potência e mecânicos, eficiência energética.