

Estudo e desenvolvimento do método Particle Swarm Optimization para solução de problemas de otimização em GLD

Study and Development of the Particle Swarm Optimization method for solving Demand-Side Management optimization problems

Bruno Eduardo Esteves de Lima
limab@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Edson Aparecido Rozas Theodoro
edsontheodoro@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

RESUMO

O gerenciamento de carga pelo lado da demanda (GLD) é uma ferramenta essencial para controle de carga durante os intervalos de pico e assim reduzir os custos, visto que em algumas localidades as tarifas variam ao longo do dia. Particle Swarm Optimization (PSO) é método de otimização de funções que se aplica no gerenciamento de carga. Este trabalho consiste no estudo e implementação do método PSO tradicional e de sua versão Padrão-2011 para aplicação posterior em problemas de otimização encontrados no GLD.

PALAVRAS-CHAVE: PSO. Otimização. GLD.

ABSTRACT

The Demand Side Load Management (DSM) is an essential tool for load control during peak periods and thus reduce costs, since in some locations the rates vary throughout the day. The Particle Swarm Optimization (PSO) is an optimization method that applies to load management. This work consists of the study and development of the conventional and Standard-2011 PSO methods for DSM application.

KEYWORDS: PSO. Optimization. DSM.

Recebido: 30 ago. 2018.

Aprovado: 04 out. 2018.

Direito autoral:

Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



INTRODUÇÃO

No Brasil, a tarifa da energia elétrica varia ao longo do dia no setor de distribuição desde 2011 com a implementação da tarifa branca em determinadas localidades (SILVA; AFFONSO, 2015). O Gerenciamento de Carga é uma ferramenta necessária para reduzir o consumo da demanda total de energia durante os intervalos de pico (LOGENTHIRAN; SRINIVASAN; PHYU, 2015).

Métodos de otimização vem sendo aplicado no Gerenciamento de Carga, por possuírem uma inteligência computacional (heurística) capaz de obter soluções para problemas de larga dimensão em um tempo aceitável (FARIA et al., 2013).

O objetivo do trabalho é a aplicação do método Particle Swarm Optimization (PSO) no Gerenciamento de Carga pelo Lado da Demanda (GLD), primeiramente os métodos PSO tradicional e Padrão-2011 serão estudados e implementados a fim de comparar sua eficiência para posterior aplicação no problema de GLD.

O método de otimização PSO foi originalmente proposto por Kennedy e Eberhart em 1995. Este método consiste em solucionar problemas lineares e não lineares de grande porte utilizando um grupo de partículas (enxame) que explora o espaço amostral em busca do valor ótimo desejado para a função custo sob análise (KENNEDY; EBERHART, 1995).

O método PSO tem chamado a atenção dos pesquisadores por ser de fácil implementação, necessitar de ajustes em poucos parâmetros, ter baixa complexidade computacional e ser eficiente quando comparado a outros métodos de otimização heurísticos (HASSAN, COHANIM; WECK, 2004).

Foram criadas várias versões do método PSO para soluções de problemas de otimização. Uma destas versões é a Otimização por Enxame de Partícula Padrão – 2011, do inglês *Standard Particle Swarm Optimization* (SPSO-2011) (CLERC, 2012; ZAMBRANO; CLERC; ROJAS, 2013).

MÉTODOS

Foi utilizada a referência Hassan (2004) para a implementação do algoritmo PSO tradicional. A partir dos dados da referência, delimita-se o campo de busca das partículas, limite máximo $X_{máx}$ e mínimo X_{min} para a posição da partícula, e em seguida gera a posição de cada partícula (X_i^0), Eq. (1).

$$X_i^k = X_{min} + rand(X_{máx} - X_{min}) \quad (1)$$

A velocidade inicial das partículas (V_i^0) é gerada conforme Eq. (2). O subscrito i refere à partícula, variando de 1 a número máximo de partículas, enquanto que o sobrescrito k refere-se à iteração variando de 1 a número máximo de iterações permitido. Para efeito de cálculo, a variação do tempo (Δt) é definido como uma iteração.

$$V_i^k = \frac{X_{min} + rand(X_{max} - X_{min})}{\Delta t} \quad (2)$$

Com base em (V_i^k) e (X_i^k) é possível determinar a melhor posição histórica de cada partícula (P_b), e aplicando a posição atual na função custo é possível determinar a posição da melhor partícula do enxame, (G_b).

O próximo passo é atualizar a velocidade das mesmas através da Eq. (3). As variáveis ω , c_1 e c_2 representam o coeficiente de inércia, o coeficiente de aceleração pessoal e o coeficiente de aceleração do grupo, e possuem valores de 0,5, 1,5 e 1,5, respectivamente. O multiplicador *rand* é um valor aleatório uniforme definido entre 0 e 1.

$$V_i^{k+1} = \omega V_i^k + c_1 \text{rand} \left(\frac{P_b - X_i^k}{\Delta t} \right) + c_2 \text{rand} \left(\frac{G_b - X_i^k}{\Delta t} \right) \quad (3)$$

Atualizado a velocidade da partícula, atualiza-se a posição da mesma, realizada através da Eq. (4).

$$X_i^{k+1} = X_i^k + V_i^{k+1} \Delta t \quad (4)$$

Atualizado a nova posição das partículas, deve ser atualizada (P_b) e (G_b) a partir do retorno da função custo para os valores de X_i^{k+1} .

O algoritmo é iterado até que se atinja o critério de parada, seja este o número máximo de iterações desejado ($NIt_{m\acute{a}x} = 1000$), ou a diferença entre o valor da função custo da melhor partícula do enxame na interação atual com seu valor anterior for menor do que 1.10^{-5} , demonstrado na Eq. (5) e (6) (HASSAN; COHANIM; WECK, 2004).

$$i \geq NIt_{m\acute{a}x} \quad (5)$$

$$|f_g^k - f_g^{k-1}| \leq 1.10^{-5} \quad (6)$$

Caso a partícula saia do campo de busca, o PSO poderia divergir. Para solucionar o problema, foi proposto que caso isso ocorra, sua velocidade deve ser zerada e sua posição retornada a borda do espaço amostral $X_{m\acute{a}x}$ ou X_{min} .

O SPSO-2011, dito como a linha de base para comparações do PSO, é essencial para que se determine a eficiência da versão do PSO que se deseja avaliar. Para a implementação do *Standard-PSO* 2011 foram utilizados como base as referências (ZAMBRANO; CLERC; ROJAS, 2013).

Os parâmetros iniciais como $X_{m\acute{a}x}$, X_{min} , X_i^k e P_b são determinados semelhante ao PSO tradicional. Porém, o cálculo para a velocidade inicial é diferente, determinada pela Eq. (7).

$$V_i^0 = \text{rand}(X_{min} - X_i^0, X_{m\acute{a}x} - X_i^0) \quad (7)$$

No SPSO-2011, haverá número máximo de interconexões, definido nas referências como $K = 3$, ou seja, a partícula recebe informação de três partículas podendo ser a ela própria um informante, e pode informar de 1 (ela mesma) até o número máximo de partículas ($N_{m\acute{a}x}$).

Como K representa a topologia de interconexões, o sobrescrito para indicar o número de interações ficou definido como t .

O passo seguinte é a atualização da velocidade. Para determinar a velocidade de cada partícula, é necessário calcular um ponto definido como centro de gravidade (G_i^t), Eq. (10), definido com base em três informações: a atual posição

da partícula (X_i^t), um ponto um pouco além da sua melhor posição prévia (p_i^t), Eq. (8), e um ponto um pouco além da melhor posição da vizinhança (l_i^t), Eq. (9).

$$p_i^t = X_i^t + c_1 \text{rand}(P_i^t - X_i^t) \quad (8)$$

$$l_i^t = X_i^t + c_2 \text{rand}(L^t - X_i^t) \quad (9)$$

$$G_i^t = \frac{X_i^t + p_i^t + l_i^t}{3} \quad (10)$$

A variável ω representa o coeficiente de inércia e pode ser calculado pela Eq. (11), enquanto c_1 e c_2 representam o coeficiente de aceleração da partícula e coeficiente de aceleração do enxame, respectivamente, e podem ser determinados pela Eq. (12).

$$\omega = \frac{1}{2 \ln 2} \quad (11)$$

$$c_1 = c_2 = \frac{1}{2} + \ln 2 \quad (12)$$

Um ponto, x' , é escolhido aleatoriamente dentro da hipersfera $H_i^t(G_i^t, \|G_i^t - X_i^t\|)$, tendo centro em G_i^t e raio da hipersfera de $\|G_i^t - X_i^t\|$.

Sendo assim, a velocidade da partícula é atualizada segundo a Eq. (13). A atualização da posição da partícula X_i^{k+1} é atualizada pela Eq. (4).

$$V_i^{t+1} = \omega V_i^t + H_i^t(G_i^t, \|G_i^t - X_i^t\|) - X_i^t \quad (13)$$

O próximo passo é atualizar a posição histórica de cada partícula p_i^t e atualizar a melhor posição dos informantes l^t . Os passos da Eq. (10) à (13) devem ser repetidos segundo o critério de parada especificado pela Eq. (5) e Eq. (6).

Em nosso estudo, o número máximo de partículas ($N_{m\acute{a}x}$) foi definido em 40 partículas e o número máximo de iterações ficou definido em 1000 iterações [4].

Com base em Pant (2014), foram escolhidas 3 funções a serem analisadas para testar a eficiência das versões tradicional e do Padrão-2011 do método PSO, dispostas na Tabela 1.

Tabela 1 – Funções Numéricas

Número da Função	Nome da Função	Definição da Função	Campo de Busca	Valor de mínimo esperado
1	Rastrigin	$f_1(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	[-5,12; 5,12]	0
2	Esférica	$f_2(x) = \sum_{i=1}^n x_i^2$	[-5,12; 5,12]	0
3	Ruidosa	$f_3(x) = \left(\sum_{i=0}^{n-1} (i+1) + x_i^4 \right) + \text{rand}[0,1]$	[-1,28; 1,28]	0

Fonte: Pant (2014).

RESULTADOS

As duas versões do método PSO foram executados 1000 vezes para as 3 Funções descritas acima e foram anotadas a melhor solução assim como a pior solução no enxame e a média do melhor valor da função *fitness* com o objetivo de validar a convergência dos métodos em análise. Todas as informações colhidas estão dispostas na Tabela 2.

Tabela 2 – Dados obtido com a melhor partícula do enxame para 1000 repetições

Dados para melhor posição do enxame para 1000 repetições do PSO				
Função	PSO Tradicional	PSO Padrão-2011	PSO Tradicional	PSO Padrão-2011
	Melhor <i>fitness</i> do enxame	Melhor <i>fitness</i> do enxame	Média do valor custo mínimo obtido nas 1000 repetições	Média do valor custo mínimo obtido nas 1000 repetições
1	0,0000	0,0000	0,0160	0,0140
2	0,0000	0,0000	0,0000	0,0001
3	0,0000	0,0000	0,0003	0,0003

Fonte: Autoria própria (2018).

DISCUSSÃO

Os critérios de validação dos métodos PSO para as funções testadas são a convergência da melhor partícula no enxame para o valor ótimo esperado e a média da melhor partícula do enxame se manter próxima ao valor da melhor partícula durante as repetições.

A Função Rastrigin obteve o melhor valor *fitness* da função custo $f_1(X) = 0,0000$, e média dos valores mínimos da função custo $med_fitness = 0,0160$. Quando aplicado o método SPSO-2011 na função, obteve o melhor valor *fitness* $f_1(X) = 0,0000$, a média do valor custo das partículas foi $med_fitness = 0,0140$. Assim, conclui se que ambos os métodos convergem para esta função, porém algumas partículas estão ficando presas em mínimos locais, em 1.

Analisando os dados para a Função Esférica, no qual obteve melhores mínimos para o valor da função custo em $f_2(X) = 0,0000$ e $f_2(X) = 0,0006$ para o método PSO tradicional e Padrão-2011 respectivamente, atingindo a convergência em ambos os casos. A média do valor de mínimo para a função custo em ambos os casos foi $med_fitness = 0,0001$.

A Função Ruidosa obteve o melhor valor de mínimo para a função em $f_3(X) = 0,0000$ e a média dos mínimos valores de custo obtidos em $med_fitness = 0,0003$ para ambos os casos. Portanto, os métodos PSO tradicional e o SPSO-2011 foram considerados de semelhante eficiência para a Função Ruidosa.

CONSIDERAÇÕES FINAIS

Com base nas análises feitas no desempenho dos métodos de otimização PSO tradicional e PSO Padrão-2011, é possível determinar que os dois métodos em análise obtiveram bons resultados quando testados nas funções de avaliação, alcançando o objetivo de convergência para o valor ótimo.

O próximo objetivo é a aplicação do método PSO em GLD, e assim, auxiliar os consumidores finais de energia elétrica ao uso eficiente da eletricidade, a fim de reduzir o custo final, mas sem diminuir a potência consumida.

REFERÊNCIAS

CLERC, M. **Standard particle Swarm Optimization**. 2012. Disponível em: clerc.maurice.free.fr/ps0/SPSO_descriptions.pdf. Acesso em: 03 de agosto de 2018.

FARIA, P., et al. **Modified particle Swarm Optimization applied to integrated demand response and DG Resourcer Scheduling**. IEEE Transaction on Smart Grid, vol 4, 2013.

HASSAN, R.; COHANIM, B.; WECK, O. **A comparison of particle swarm optimization and the genetic algorithm**. American Institute of Aeronautics and Astronautics, 2004.

KENNEDY, J.; EBERHART, R. **Particle Swarm Optimization**, Proceeding of the IEEE International Conference on Neural Networks, Perth, Australia 1995, pp. 1942-1945.

LOGENTHIRAN, T., SRINIVASAN, D., PHYU, E. **Particle Swarm Optimization for demand side management in smart grid**. IEEE Innovative Smart Grid Technologies, Asia, 2015.

PANT, M., THANGARAJ, R., ABRAHAM, A. **Particle Swarm Optimization: Performance tuning and empirical analysis**. Foundations of Computational Intelligence Volume 3. Studies in Computational Intelligence, v. 203. Springer, Berlin, Heidelberg.

SILVA, R. V., AFFONSO, C. M. **Demand side management of a residential system using simulated annealing**, IEEE Latim America Transaction, vol. 13, 2015.

ZAMBRANO, M. B.; CLERC, M.; ROJAS, R. **Standard Particle Swarm Optimization 2011 at CEC-2013: A baseline for future PSO improvements**. Congress of Evolutionary Computation, IEEE, Mexico, 2013.



AGRADECIMENTOS

Os autores gostariam de agradecer ao Programa de Voluntariado em Iniciação Científica (PVICT) da Universidade Tecnológica Federal do Paraná - campus Cornélio Procópio.