

# Método de Otimização por Enxame de Partículas Aplicado ao Despacho Econômico de Geradores

Gabriel Q. Fechine\* Washington L. A. Neves\*\*  
Benemar A. Souza\*\*\*

Universidade Federal de Campina Grande, Departamento de Engenharia Elétrica  
Campina Grande, Brasil

\*Mestrando em Engenharia Elétrica, PPgEE/CEEI/UFCG, Rua Aprígio Veloso 882, Brasil  
(email: gabriel.fechine@ee.ufcg.edu.br)

\*\* Professor, Departamento de Engenharia Elétrica, PPgEE/CEEI/UFCG, Rua Aprígio Veloso 882, Brasil  
(emails: waneves@dee.ufcg.edu.br e benemar@dee.ufcg.edu.br)

---

**Abstract:** The economic dispatch of generators has the objective of minimizing the cost of energy production, which is done by the best distribution of load among the available generating units and the minimization of transmission losses with some imposed restrictions. Several optimization methods can be used to solve economic dispatch problems, whether these are classical or heuristic methods. The optimization method used in this paper is ALPSO (Augmented Lagrangian Particle Swarm Optimization), an extended version of the classic PSO (Particle Swarm Optimization) method, with the addition of constraints. This method will be applied to obtain the economic dispatch in an electric power system and the results will be compared with the solution obtained by the classical method of gradients. Also, the performance of different PSO topologies will be compared against each other. The ALPSO method achieved similar results with easier implementation, when compared to gradient method.

**Resumo:** O despacho econômico de geradores tem como objetivo a minimização do custo de produção de energia, o que se dá por meio da melhor distribuição de carga entre as unidades geradoras disponíveis e da minimização das perdas na transmissão mediante algumas restrições. Vários métodos de otimização podem ser utilizados para a resolução de problemas de despacho econômico, sejam estes métodos clássicos ou heurísticos. O método de otimização utilizado neste artigo é o ALPSO (*Augmented Lagrangian Particle Swarm Optimization*), uma versão ampliada do método PSO (*Particle Swarm Optimization*) clássico, com a inclusão de restrições por meio de um método baseado nos multiplicadores de Lagrange. Este método será aplicado para a obtenção do despacho econômico em um sistema elétrico de potência e os resultados serão comparados com a solução obtida pelo método clássico dos gradientes. Além disso, serão realizadas análises com diferentes topologias do PSO, comparando o desempenho das mesmas. O método ALPSO obteve resultados similares com implementações mais fáceis, quando comparado ao método dos gradientes.

**Keywords:** ALPSO; Economic dispatch; Economic operation; Optimization; Particle Swarm Optimization; PSO.

**Palavras-chaves:** ALPSO; Despacho econômico; Operação econômica; Otimização; Enxame de partículas; PSO.

---

## 1. INTRODUÇÃO

O problema de despacho econômico de geradores é um dos mais clássicos na área de sistemas elétricos de potência. Este trata do cálculo da potência de operação dos geradores diante de algumas restrições: limites operacionais (mínimos e máximos) das máquinas, limites de transmissão das linhas e, além disso, as potências calculadas devem atender às equações de fluxo de carga do sistema. O objetivo desta análise é obter o menor custo operacional possível diante das restrições citadas, o que a caracteriza como um clássico problema de otimização.

Um dos métodos tradicionais para o tratamento das restrições (de igualdade ou desigualdade), que são próprias dos problemas de otimização práticos é o método dos multiplicadores de Lagrange. Este método consiste na obtenção de uma nova função objetivo, chamada função Lagrangiana, que é constituída da função objetivo original acrescida das restrições de igualdade, ponderadas. Os pesos são os multiplicadores de Lagrange. A resolução do problema se dá pela minimização do Lagrangiano, obtendo a minimização do problema original, atendendo às restrições impostas. Este método é utilizado para o tratamento das restrições do cálculo de despacho econômico neste trabalho.

Para resolução de problemas como este, de minimização ou maximização, os chamados métodos de otimização são utilizados. Estes métodos podem ser classificados em métodos clássicos (determinísticos) e métodos heurísticos (probabilísticos). Neste trabalho, o método dos gradientes, um método clássico, é utilizado como referência para as demais análises.

Ao analisar o estado da arte na área de resolução de problemas de despacho econômico com a utilização de métodos heurísticos, verifica-se que esta é uma área promissora, com diversos trabalhos publicados, entre os mais relevantes, pode-se citar:

Güvenç e Kaymaz (2019) propuseram a utilização do *Coyote Optimization Algorithm* (COA) para a solução de problemas de despacho econômico (DE). Este é um método heurístico que se baseia no comportamento social de coiotes e como a espécie se adapta ao ambiente. No trabalho, o COA é utilizado para solucionar problemas de DE que incluem geradores eólicos.

Tu (2018) propôs a utilização do método *Bee Colony Optimization* (BCO) em conjunto com o método Taguchi (TM) para a solução de problemas de despacho econômico dinâmico de geradores. O método BCO é um método heurístico que possui algumas semelhanças com o PSO, porém, as abelhas (equivalentes as partículas no PSO) possuem funções diferentes: operárias, espectadoras e escoteiras, com equacionamentos distintos para cada função.

Davel, Goyal e Sharma (2019) apresentam uma análise comparativa entre o PSO e o método de busca Cuco (*Cuckoo Search* – CS). O CS é um método heurístico que se baseia no parasitismo obrigatório desta espécie de pássaro, que deposita seus ovos em ninhos de outras espécies, para realizar a otimização de funções. Os métodos foram aplicados a solução de problemas de DE em sistemas-teste IEEE.

Park (2005) propõe um método baseado no PSO para soluções de problemas de despacho econômico com funções custo não-suaves. Este tipo de função apresenta pontos não-diferenciáveis, que são causados pelo chamado *valve-point effect*, um efeito causado por características mecânicas das unidades geradoras.

O método heurístico que será abordado neste artigo, para realizar a minimização dos custos operacionais é o método ALPSO. Este método foi escolhido por sem uma heurística utilizada para solução de problemas com funções contínuas e não-lineares, que é caso do despacho econômico com modelagem quadrática.

**Tabela 1 - Síntese Bibliográfica.**

<b>Autor</b>	<b>Método</b>	<b>Função Objetivo</b>	<b>Características</b>
Güvenç e Kaymaz (2019)	COA	Custo combinado de unidades térmicas e eólicas.	Inclusão de geradores eólicos; Sistemas de pequeno porte.
Tu (2018)	BCO-TM	Modelagem quadrática com e sem VPE.	Função objetivo não-suave; Complexidade do método TM.
Davel, Goyal e Sharma (2019)	PSO e CS	Modelagem quadrática com VPE.	Função objetivo não-suave; Sistema-teste IEEE.
Park (2005)	MPSO	Modelagem quadrática com VPE.	Função objetivo não-suave; Sistemas de pequeno e médio porte;
Método proposto	ALPSO	Modelagem quadrática com e sem VPE.	Função objetivo não-suave;

## 2. DESPACHO ECONÔMICO DE GERADORES

Define-se o despacho econômico de geradores como o processo de otimização dos custos de geração de energia. Esta análise consiste em calcular as potências de operação dos geradores que minimizam os custos da geração, atendendo os limites operacionais dos geradores.

Primeiramente, para calcular o despacho econômico, é necessário estabelecer a função custo das usinas. Para o caso de usinas térmicas, um modelo usual do custo operacional é o modelo quadrático. Ou seja, o custo operacional é considerado uma função quadrática da potência gerada. Como mostrado por Saadat (2010), o custo operacional  $C_i$  (em \$/h) de um gerador  $i$  em função de sua potência de operação  $P_i$  (em MW) pode ser expresso pela função matemática apresentada em:

$$C_i = \alpha_i + \beta_i P_i + \gamma_i P_i^2, \quad (1)$$

sendo  $\alpha_i$ ,  $\beta_i$  e  $\gamma_i$  os parâmetros do modelo de geração.

Como citado, os limites operacionais de cada grupo gerador são restrições do problema de otimização, como mostrado em:

$$P_{i(\min)} \leq P_i \leq P_{i(\max)}. \quad (2)$$

Um dos requisitos para a operação normal do sistema, é o fato de que a soma das potências geradas supra a demanda do sistema acrescida das perdas nas linhas. Matematicamente, pode-se escrever esta restrição do seguinte modo:

$$\sum_{i=1}^{n_g} P_i = P_D + P_L, \quad (3)$$

sendo  $n_g$  o número total de geradores,  $P_D$ , a potência demandada e  $P_L$ , as perdas no sistema.

Existem diferentes expressões das perdas do sistema, uma delas é o método dos coeficientes  $B$  (*B-coefficient method*) desenvolvido por Gabriel Kron e utilizado por L. K. Kirchmayer (1964). Este método visa equacionar as perdas nas linhas em função das potências dos geradores, como mostrado em:

$$P_L = \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} P_i B_{ij} P_j + \sum_{i=1}^{n_g} B_{0i} P_i + B_{00}, \quad (4)$$

os coeficientes  $B_{ij}$  são constantes determinadas a partir do fluxo de carga do sistema.

Para realizar a otimização da função custo atendendo às restrições impostas, o método de Lagrange, descrito a seguir, é utilizado.

Neste método, o problema original é resolvido mediante resolução do problema dual de otimização sem restrição que tem como função objetivo o Lagrangiano do problema primal.

O Lagrangiano é constituído da função objetivo original acrescido das restrições ponderadas pelos fatores de peso  $\lambda_i$  e  $\mu_i$  os chamados multiplicadores de Lagrange. O minimizador do Lagrangiano (sem restrição alguma) também é minimizador da função objetivo original, atendendo às restrições impostas.

Para o caso do despacho econômico, a função custo aumentada é formulada levando em consideração as restrições anteriormente citadas, reescrevendo-as como

restrições de desigualdade e igualdade. Assim, obtém-se o Lagrangiano por meio da seguinte expressão:

$$L = \sum_{i=1}^{n_g} C_i + \lambda \left( P_D + P_L - \sum_{i=1}^{n_g} P_i \right) + \sum_{i=1}^{n_g} \mu_{i(\max)} (P_i - P_{i(\max)}) + \sum_{i=1}^{n_g} \mu_{i(\min)} (P_{i(\min)} - P_i). \quad (6)$$

A minimização da função  $L$  resulta na obtenção do despacho econômico dos geradores, minimizando a função custo.

A seguir, serão descritos os procedimentos para obtenção do despacho econômico de geradores em um sistema de potência.

Dado um sistema de potência com barras de geração e barras de carga, o cálculo do despacho econômico se torna parte de outro processo iterativo, que envolve o fluxo de carga do sistema e a obtenção dos coeficientes  $B$  da função das perdas do sistema.

O algoritmo de resolução desse processo pode ser descrito por:

1. Construção da matriz admitância do sistema: Utilização métodos clássicos de obtenção da matriz admitância;
2. Obtenção do fluxo de carga do sistema: Podem ser utilizados quaisquer métodos para cálculo de fluxo de carga;
3. Cálculo dos coeficientes  $B$  (fórmula das perdas): De acordo com a Equação 4.;
4. Cálculo do despacho econômico dos geradores: Utilização de métodos de otimização;
5. Obtenção de novo fluxo de carga: Barras PV atualizadas com as potências obtidas no despacho econômico;
6. Repetição dos itens 3 a 5 até que o critério de parada seja atingido.

O critério de parada para este processo é baseado na potência da barra de balanço do sistema. O processo iterativo continua até que a diferença entre o valor da potência obtido no fluxo de carga e o valor calculado no despacho econômico seja menor que a tolerância estipulada.

### 3. OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

O método PSO, ou otimização por enxame de partículas, é uma meta-heurística proposta inicialmente por Kennedy e Eberhart (1995). Trata-se de um método de otimização de funções contínuas e não-lineares, que utiliza a inteligência coletiva dos animais e o seu comportamento social como metáfora. Nessa metáfora, as partículas são pontos no espaço de busca multidimensional e o objetivo a ser alcançado é o ponto ótimo deste espaço. O conjunto de partículas é chamado de enxame.

O processo evolutivo do método PSO consiste na atualização da posição e da velocidade da partícula ao longo do tempo, percorrendo o espaço de busca. A atualização da velocidade é influenciada pela melhor posição da partícula e pela melhor posição entre todas as partículas do enxame até o momento, o que reflete o aprendizado cognitivo e o aprendizado social dos indivíduos.

Existem diferentes topologias e variações do método PSO, neste artigo serão apresentadas duas topologias: o PSO clássico e o PSO de rápida convergência (*Fast Convergence PSO - FCPSO*), proposto por Sahu, Panigrahi e Pattnaik (2012). O desempenho do método ALPSO, em conjunto com o PSO clássico e o FCPSO será comparado. Primeiramente, o equacionamento do PSO clássico será apresentado a seguir.

#### 3.1 PSO Clássico

O enxame é composto por  $S$  partículas e a atualização da posição e velocidade de cada partícula é realizado individualmente. Uma partícula  $i$  na iteração  $k$  é representado por  $x_k^i$  e seu deslocamento por  $\Delta x_k^i$ , a melhor posição da partícula até a iteração atual é representada por  $x_{best}^i$  e a melhor posição entre todas as partículas do enxame é representada por  $x_{best}^g$ . O equacionamento da atualização de sua posição e deslocamento pode ser dado por:

$$\Delta x_{k+1}^i = w\Delta x_k^i + c_1r_1(x_{best}^i - x_k^i) + c_2r_2(x_{best}^g - x_k^i) \quad (7)$$

$$x_{k+1}^i = x_k^i + \Delta x_{k+1}^i. \quad (8)$$

Os parâmetros  $w$ ,  $c_1$  e  $c_2$  são variáveis definidas previamente e podem seguir diferentes abordagens. Para o caso da constante de inércia ( $w$ ), um dos tratamentos mais comuns na literatura, e que será utilizado neste artigo, é a variação linear deste parâmetro durante as iterações do processo, sendo definidos os limites (máximo e mínimo) previamente. Para as constantes cognitiva e social ( $c_1$  e  $c_2$ ) também existem diferentes abordagens, neste artigo, serão comparados os desempenhos de duas abordagens diferentes, a primeira considera  $c_1$  e  $c_2$  como valores constantes ao longo do processo iterativo, já a segunda abordagem impõe uma variação linear para estes parâmetros. Além disso,  $r_1$  e  $r_2$  são variáveis aleatórias distribuídas uniformemente no intervalo  $[0,1]$ .

#### 3.2 FCPSO

Esta variação do PSO propõe a inclusão do valor médio das partículas na iteração  $k$  ( $x_k^{k_{mean}}$ ) no cálculo do deslocamento  $\Delta x_k^i$ . Esta modificação visa acelerar o processo de convergência do método e também evitar que as soluções obtidas fiquem presas em ótimos locais. Desta forma, o equacionamento para a atualização do deslocamento neste método pode ser representado por:

$$\Delta x_{k+1}^i = w\Delta x_k^i + c_1r_1(x_{best}^i - x_k^i) + c_2r_2(x_{best}^g - x_k^i) + c_3r_3(x_{k_{mean}}^i - x_k^i). \quad (9)$$

Outra possível variação no equacionamento do PSO é a inclusão de um fator de restrição, que será abordada a seguir:

#### 3.3 Fator de Restrição

A inclusão de um fator multiplicador na equação de cálculo do deslocamento das partículas no método PSO foi proposto por Lu et al. (2015) e aplicado por Yalcinoz e Rudion (2019). Este fator é baseado numa função cossenoidal que tem como variável o número de iterações, como mostrado em (10).

$$K = \frac{\cos(2\frac{\pi}{k_{m\acute{a}x}}(k - k_{m\acute{a}x})) + 2,428571}{4}. \quad (10)$$

O parâmetro  $k_{m\acute{a}x}$  é o limite de iterações do processo e  $k$  é o valor da iteração atual. Este fator é inserido no equacionamento no método ao multiplicar todos os termos do cálculo do deslocamento das partículas, como mostrado em (11) e (12), para o PSO clássico e o FCPSO, respectivamente.

$$\Delta x_{k+1}^i = K(w\Delta x_k^i + c_1r_1(x_{best}^i - x_k^i) + c_2r_2(x_{best}^g - x_k^i)), \quad (11)$$

$$\Delta x_{k+1}^i = K(w\Delta x_k^i + c_1r_1(x_{best}^i - x_k^i) + c_2r_2(x_{best}^g - x_k^i) + c_3r_3(x_{k_{mean}}^i - x_k^i)). \quad (12)$$

#### 3.4 Algoritmo PSO e Critérios de Parada

Os procedimentos para a execução do PSO clássico e para o FCPSO são os mesmos, e podem ser sintetizados nos passos descritos abaixo:

1. Inicialização do enxame ( $k=0$ ) de  $S$  partículas com posição aleatoriamente distribuída em um intervalo  $[x_{min}, x_{max}]$ .
2. Avaliação da função objetivo de cada partícula do enxame.
3. Atualização da melhor posição de cada partícula individualmente e da melhor posição do bando.
4. Atualização da velocidade e posição de cada partícula no tempo  $k+1$ .

5. Repetição do processo até que alguma condição de parada seja atendida.

Neste artigo, dois critérios de parada foram utilizados. O primeiro é baseado no método *MaxDistQuick*, proposto por Zielinski (2007). Este critério calcula a distância das melhores  $p\%$  (porcentagem definida previamente) partículas do enxame em relação a melhor solução do enxame, analisando a convergência das soluções. O processo iterativo é interrompido se a distância máxima calculada for menor do que uma tolerância. O segundo critério de parada é o limite máximo de iterações ( $k_{m\acute{a}x}$ ).

A seguir, o método ALPSO será descrito. Este método inclui multiplicadores de Lagrange e vetores de penalidade no processo evolutivo do PSO, realizando o tratamento das restrições.

#### 4. ALPSO

Para incluir as restrições no processo evolutivo do PSO, Sedlaczek e Ebehart (2005), propuseram a combinação do PSO com o método dos multiplicadores de Lagrange, desenvolvendo o método ALPSO.

A formulação da função aumentada de Lagrange para este caso é baseada na apresentada na seção 2.1, porém apresenta algumas diferenças, como a utilização da função de penalidade  $\theta(\mathbf{x})$ . O modo como se estabelece o Lagrangiano neste método é o seguinte:

$$L(\mathbf{x}, \boldsymbol{\lambda}, \mathbf{r}_p) = f(\mathbf{x}) + \boldsymbol{\lambda}\theta(\mathbf{x}) + \mathbf{r}_p [\theta_1^2(\mathbf{x}), \dots, \theta_{m_e+m_i}^2(\mathbf{x})]. \quad (13)$$

O vetor  $\boldsymbol{\lambda}$  representa o vetor de multiplicadores de Lagrange e possui  $m_e+m_i$  elementos, o que equivale ao número total de restrições do problema. Também é utilizado o vetor  $\mathbf{r}_p$ , que representa os fatores de penalidade, que são alterados dinamicamente de acordo com as variações das funções de penalidade. A função de penalidade  $\theta(\mathbf{x})$  é equacionada de acordo com:

$$\theta_i(\mathbf{x}) = \begin{cases} g_i(\mathbf{x}), & , i = 1(1)m_e \\ \max \left[ h_{i-m_e}(\mathbf{x}), -\frac{\lambda_i}{2r_{p,i}} \right], & , i = m_e + 1(1)m_e + m_i \end{cases} \quad (14)$$

Neste método, dois processos iterativos são executados sequencialmente. Primeiro são definidos valores iniciais para  $\boldsymbol{\lambda}$  e  $\mathbf{r}_p$ , e em seguida, o enxame de partículas é inicializado com posições aleatórias. O processo do PSO clássico (ou FCPSO) é executado, até que algum critério de parada seja atingido. Em seguida, os valores de  $\boldsymbol{\lambda}$  e  $\mathbf{r}_p$  são atualizados, o contador de iterações do PSO é zerado e o processo se repete por completo até que o critério de parada do ALPSO seja atingido.

A atualização dos vetores  $\boldsymbol{\lambda}$  e  $\mathbf{r}_p$  é feita do seguinte modo:

$$\boldsymbol{\lambda}^{u+1} = \boldsymbol{\lambda}^u + 2\mathbf{r}_p \cdot \text{diag}\{\theta_1(\mathbf{x}^u), \dots, \theta_{m_e+m_i}(\mathbf{x}^u)\}, \quad (15)$$

$$\mathbf{r}_{p,i}^{u+1} = \begin{cases} 2\mathbf{r}_{p,i}^u & \text{se } [|g_i(\mathbf{x}^u)| > |g_i(\mathbf{x}^{u-1})|] \cap [|g_i(\mathbf{x}^u)| > \varepsilon_g] \\ \frac{1}{2}\mathbf{r}_{p,i}^u & \text{se } |g_i(\mathbf{x}^u)| \leq \varepsilon_g \end{cases} \quad (16)$$

para  $i = 1(1)m_e$

Neste processo, os valores das equações de restrição são utilizados para definir se o coeficiente de penalidade deve ser expandido ou contraído, de acordo com a tolerância desejada para o atendimento das restrições ( $\varepsilon_g$  e  $\varepsilon_h$ ).

O processo detalhado do ALPSO pode ser descrito por:

1. Inicializar os contadores de iteração ( $u=0$  e  $k=0$ ) e os vetores de penalidade ( $\boldsymbol{\lambda}^0=0$  e  $\mathbf{r}_p^0 = \mathbf{r}_{p0}$ ). Inicializar as partículas aleatoriamente.
2. Checar critérios de parada, caso satisfeito, o algoritmo termina e retorna a solução. Caso  $u > u_{m\acute{a}x}$ , o processo é interrompido e retorna como falha.
3. Executar os itens 2) a 5) do algoritmo básico do PSO clássico ou FCPSO.
4. Atualizar  $\boldsymbol{\lambda}$  e  $\mathbf{r}_p$ ,  $u=u+1$  e  $k=0$ .
5. Retornar ao item 2).

Para o caso do ALPSO, o critério de parada utilizado é relacionado com o atendimento às restrições. Caso todas as restrições do problema sejam atendidas (uma tolerância deve ser considerada), o critério de parada é atingido e o processo é finalizado. Caso o critério de parada não seja atingido até o limite de iterações ( $u_{m\acute{a}x}$ ), o processo é interrompido e retorna como falha, ou seja, a solução obtida não será considerada.

A seguir, os métodos descritos serão aplicados para a resolução de problemas de despacho econômico de geradores em sistemas de potência, comparando o desempenho das diferentes topologias abordadas.

#### 5. ANÁLISES E RESULTADOS

Com o objetivo de validar a utilização do método ALPSO para solucionar problemas de despacho econômico de geradores em sistemas elétricos de potência, foi utilizado um sistema-teste do IEEE de 30 barras. (CHRISTIE, 2000)

O sistema de 30 barras, conta com 6 geradores, alocados nas barras 1, 2, 5, 8, 11 e 13. As demais barras do sistema são barras de carga. As funções custo dos geradores e os limites operacionais das máquinas estão mostrados abaixo:

$$\begin{aligned} C_1 &= 2,00P_1 + 0,00375P_1^2, & 50 \text{ MW} \leq P_1 \leq 200 \text{ MW}, \\ C_2 &= 1,75P_2 + 0,01750P_2^2, & 20 \text{ MW} \leq P_2 \leq 80 \text{ MW}, \end{aligned}$$

$$\begin{aligned}
C_3 &= 1,00P_3 + 0,06250P_3^2, & 15 \text{ MW} &\leq P_3 \leq 50 \text{ MW}, \\
C_4 &= 3,25P_4 + 0,00834P_4^2, & 10 \text{ MW} &\leq P_4 \leq 35 \text{ MW}, \\
C_5 &= 3,00P_5 + 0,02500P_5^2, & 10 \text{ MW} &\leq P_5 \leq 30 \text{ MW}, \\
C_6 &= 3,00P_6 + 0,02500P_6^2. & 12 \text{ MW} &\leq P_6 \leq 40 \text{ MW}.
\end{aligned}$$

Primeiramente, o problema de despacho econômico para este sistema foi solucionado com a utilização do método dos gradientes, para que esta solução seja utilizada como referência para os demais métodos. Com a utilização deste método, a custo operacional mínimo obtido foi de **803,73 \$/h** e o tempo de simulação necessário para a resolução do problema foi de **0,0183 segundos**.

Para a resolução do problema com o ALPSO e para comparar o desempenho do método com as diferentes topologias do PSO aqui abordadas, a seguinte metodologia será aplicada:

Com a utilização do PSO clássico, 4 diferentes abordagens serão utilizadas:

**PSO1:** PSO clássico com parâmetros ( $c_1$  e  $c_2$ ) constantes.

**PSO2:** PSO clássico com parâmetros ( $c_1$  e  $c_2$ ) linearmente variáveis.

**PSO3:** PSO clássico com fator de restrição e parâmetros ( $c_1$  e  $c_2$ ) constantes.

**PSO4:** PSO clássico com fator de restrição e parâmetros ( $c_1$  e  $c_2$ ) linearmente variáveis.

A mesma lógica será aplicada analogamente para o FCPSO, totalizando 8 diferentes combinações de topologias e abordagens. Para analisar o desempenho dos métodos para a resolução do problema em questão, os seguintes parâmetros foram considerados: erro relativo percentual entre a solução ótima obtida e o valor de referência (solução do método dos gradientes) e tempo médio por execução.

Os parâmetros utilizados nos métodos estão mostrados na Tabela 1, o tamanho do enxame ( $S$ ), neste trabalho, é considerado uma variável dependente do número de geradores do problema de DE, sendo utilizado o número inteiro aproximado pela equação:

$$S = 10 + 4\sqrt{n_g}. \quad (17)$$

Os parâmetros  $c_1$ ,  $c_2$  e  $c_3$  foram utilizados com seus valores constantes apenas nas topologias que utilizaram estas metodologias, como citado acima. Os valores mostrados na Tabela 1 para estes parâmetros são usuais na literatura, como citado por Sengupta, Basak e Peters (2019).

Os limites de iteração ( $k_{m\acute{a}x}$  e  $u_{m\acute{a}x}$ ) foram estipulados a partir de tentativas de execução do método, analisando as soluções obtidas e o tempo de execução médio necessário. A partir

(20) isto, determinou-se os valores mostrados na Tabela 2 como apropriados para a aplicação do método para este problema.

Os resultados obtidos com as 8 topologias estão mostrados na Tabela 3. É válido ressaltar que, por ser um método heurístico, que tem componentes probabilísticas, foram realizadas 50 execuções para cada topologia, e, ao final das execuções, foram extraídas a solução ótima e o tempo de execução médio.

**Tabela 2. Parâmetros do método ALPSO**

$S$	$c_1$	$c_2$	$c_3$	$k_{m\acute{a}x}$	$u_{m\acute{a}x}$
20	2,05	2,05	1,00	50	5

**Tabela 3. Soluções obtidas com método ALPSO.**

Topologia	Custo operacional mínimo (\$/h)	Erro relativo percentual	Tempo de execução (s)
<b>PSO1</b>	803,5479	0,0271	0,2853
<b>PSO2</b>	803,4185	0,0388	0,3276
<b>PSO3</b>	803,3282	0,0500	0,2049
<b>PSO4</b>	802,7574	0,1210	0,1879
<b>FCPSO1</b>	803,5489	0,0225	0,3288
<b>FCPSO2</b>	803,2515	0,0595	0,3477
<b>FCPSO3</b>	803,5892	0,0175	0,2460
<b>FCPSO4</b>	803,6136	0,0145	0,2580

Analisando os resultados obtidos, verifica-se que todas as soluções obtidas resultaram em um custo operacional mínimo menor do que o valor obtido com o método dos gradientes.

Quanto ao tempo de execução médio, os valores obtidos com o método ALPSO foram maiores do que o tempo obtido com o método dos gradientes, o que já era esperado, visto que os métodos heurísticos tendem a demandar um maior tempo de execução para a resolução de problemas, quando comparados aos métodos clássicos.

Ao analisar os resultados com a utilização das diferentes topologias citadas, verifica-se que o resultado obtido com o PSO4 foi o de menor custo operacional e também de menor tempo de simulação, sendo assim, o mais satisfatório. É válido ressaltar que a utilização do fator de restrição reduziu

o tempo de execução, quando comparados com as topologias sem fator de restrição. Quanto a utilização do FCPSO, pode-se verificar que os tempos de execução foram maiores do que o PSO clássico, contradizendo o conceito de rápida convergência do método. Assim, pode-se concluir que a topologia que retornou os melhores resultados para a resolução deste problema foi a PSO4.

## 6. CONCLUSÕES

Ao final das análises realizadas, pôde-se comprovar que a utilização do método ALPSO para resolução de problemas de despacho econômico em sistemas de potência é válida, obtendo soluções melhores do que a solução obtida com o método dos gradientes, com tempos de execução aceitáveis e com maior facilidade na programação e implementação do método.

Quanto à análise das diferentes topologias do PSO que foram utilizadas em conjunto com o ALPSO, conclui-se que a utilização do fator de restrição é uma melhoria satisfatória ao método, pois, a inclusão deste fator reduziu consideravelmente o tempo de execução do método. Já a utilização da topologia FCPSO não se mostrou satisfatória, pois, os resultados com o PSO clássico foram melhores, tanto em relação às soluções obtidas quanto aos tempos de execução. A utilização do PSO clássico com fator de restrição e parâmetros linearmente variáveis pode ser considerada a topologia ótima para a solução deste problema, dentre as topologias analisadas.

## AGRADECIMENTOS

Agradecimentos ao CNPq, pelo financiamento da pesquisa que resultou neste artigo e ao Departamento de Engenharia Elétrica da UFCG, que forneceu a estrutura e apoio necessários para a realização desta pesquisa.

## REFERÊNCIAS

- Christie, R. *Power systems test case archive (PSTCA)*. University of Washington. Disponível em: <http://labs.ece.uw.edu/pstca/>.
- Davel, D.; Goyal, G. R.; Sharma, J. Solution of dynamic economic power dispatch problem using AI techniques. *Journal of Emerging Technologies and Innovative Research (JETIR)*, vol. 6, issue 1, 2019.
- Kennedy, J. and Eberhart, R. (1995). Particle Swarm Optimization. *Proceedings of the International Conference on Neural Networks*, Perth, Australia, pp. 1942-1948.
- Güvenç, U.; Kaymaz, E. Economic Dispatch Integrated Wind Power Using Coyote Optimization Algorithm. In: *7th International Istanbul Smart Grids and Cities Congress and Fair (ICSG)*, 2019.
- Kirchmayer, L.K. Direct Calculation of Transmission Loss Formula-II. *Trans. Am. Inst. Electr. Eng.* 1964, 83, 702–707.
- Lu, J. et al. Post-nonlinear blind source separation with kurtosis constraints using augmented Lagrangian particle swarm optimization and its application to mechanical systems. *Journal of Vibration and Control*, 2019.
- Park, J. B. et al. A particle swarm optimization for economic dispatch with non smooth cost functions. In: *IEEE Transaction on Power System*, February 2005.
- Saadat, H. (2010) *Power System Analysis*, 3<sup>rd</sup> ed, pp. 296-352, PSA Publishing.
- Sahu, A., Panigrahi, S. K. and Pattnaik, S. (2012). Fast Convergence Particle Swarm Optimization for Functions Optimization. *Procedia Technology* 4, pp 319-324.
- Sedlaczek, K. and Eberhart, R. (2005). Constrained Particle Swarm Optimization of Mechanical Systems. *6th World Congresses of Structural and Multidisciplinary Optimization*, Rio de Janeiro, Brasil.
- Sengupta, S.; Basak, S. and Peters, R. A.: Particle Swarm Optimization: A survey of historical and recent developments with hybridization perspectives. *Machine Learning & Knowledge Extraction*, 2019, 1, 157-191.
- Tu, C. et al. Bee colony optimization with Taguchi method for solving the dynamic economic dispatch. In: *MATEC Web of Conferences* 185, 2018.
- Yalcinoz, T. and Rudion, K. (2019). Economic Load Dispatch Using an Improved Particle Swarm Optimization based on functional constriction factor and functional inertia weight. *EEEIC / I&CPS Europe*. Genova, Italy.
- Zielinski, K. and Laur, R. (2007). Stopping Criteria for a Constrained Single-Objective Particle Swarm Optimization Algorithm. *Informatica* 31, pp. 51-59.