

Algoritmo Evolutivo Inspirado em Enxames para o Problema da Programação Hidrotérmica a Curto-Prazo

Sergio Augusto Trovão, Igor Soares dos Santos, Sidney Cerqueira e Osvaldo Ronald Saavedra

Universidade Federal do Maranhão Centro de Ciências Exatas e Tecnologia Av. dos Portugueses s/n
Campus do Bacanga - São Luís, Maranhão, Brasil CEP: 65080-040
{ats.sergio,igorsds,cerqueirasidney}@gmail.com, o.saavedra@ieee.org

Resumo – Este trabalho propõe um novo algoritmo Evolutivo inspirado em Exames para a resolução do despacho hidrotérmico de curto prazo. O algoritmo proposto usa os paradigmas da Computação Evolutiva baseados nas teorias evolutivas de Darwin e a inteligência de enxames, esta última observada em várias espécies da natureza tais como pássaros e formigas. O algoritmo pode ser aplicado para resolver uma variedade de problemas de otimização numérica. Neste artigo, é usado para resolver o problema da coordenação hidrotérmica de curto-prazo. A heurística proposta é validada com alguns casos-teste retirados da literatura e comparado com outros métodos, mostrando desempenho competitivo quanto à qualidade das soluções.

Palavras-chave – Algoritmos Evolutivos, Teoria de Enxames, Coordenação Hidrotérmica, Sistemas de Potência.

Abstract – This paper proposes a new Evolutionary Algorithm inspired Swarms for the resolution of short-term hydrothermal dispatch. The proposed algorithm uses the paradigms of evolutionary computing based on evolutionary theories of Darwin and swarm intelligence, this latter observed in several species of nature such as birds and ants. The algorithm can be applied to solve a variety of numerical optimization problems. In this article, is used to solve the coordination problem of short-term hydrothermal coordination. The proposed heuristic is validated with a few test cases taken from literature and compared with other methods showing competitive performance and the quality of solutions.

Keywords –Swarm-Inspired Theory, Evolutionary Computation, Hydrothermal Coordination, Power systems.

1. INTRODUÇÃO

Nas últimas décadas as técnicas computacionais inspiradas na natureza têm atraído cada vez mais atenção no meio científico. A natureza serve como uma fonte fértil de conceitos, princípios e mecanismos para projetar sistemas inteligentes para resolver problemas computacionais complexos [1]. Entre os mais conhecidos estão os Algoritmos Evolutivos (AE's), de onde se derivam três grandes correntes: os Algoritmos Genéticos (AG's), a Programação Evolutiva (PE) e as Estratégias Evolutivas (EE's). Nos últimos anos, uma nova área de pesquisa conhecida como Inteligência Coletiva (¹) inspirada no comportamento coletivo de algumas espécies da natureza, tem sido desenvolvida. Atualmente, a SI inclui dois tipos de algoritmos diferentes: a Otimização por Colônia de Formigas (OCF²) [2] inspirada no comportamento das formigas; e a Otimização por Enxame de Partículas (OEP³) [3] criada a partir do comportamento de um grupo de aves ou peixes.

Variadas modificações nos algoritmos originais têm sido propostas (ver: [5]-[7]). Principalmente para o PSO, onde as modificações podem ser vistas como componentes algorítmicas que proporcionam melhorias em desempenho e velocidade. Além disso, outras técnicas inspiradas na natureza têm surgido tais como Bacterial Foraging Optimization (BFO) [4] e Group Search Optimizer (GSO) [1].

Neste trabalho uma nova meta-heurística é introduzida, denominada Algoritmo Evolutivo inspirado em Enxames (Swarm-Inspired Evolutionary Algorithm - SEA). Assim como as já citadas AG e PSO, é baseada em um conjunto de soluções que passam por repetidos processos de aprendizado coletivo em busca de uma solução ótima.

O algoritmo proposto - SEA, apesar de fundamentalmente ser um AE, possui algumas características inspiradas na SI. A vantagem do SEA em relação a outros AE's é que ele possui uma memória coletiva, sendo a geração de novos indivíduos governada por esta memória. Por outro lado, diferente do clássico PSO, mantém em sua estrutura o conceito Darwiniano da seleção natural, onde é realizada uma competição entre os filhos pelo lugar do pai no enxame (População). Além disso, o mecanismo para geração dos filhos leva em conta uma região de busca para cada indivíduo, sendo esta denominada - campo de visão.

As principais características do método são:

1. A inteligência coletiva combinada com o processo de seleção natural;

¹Swarm Intelligence (SI)

²Ant Colony Optimization (ACO)

³Particle Swarm Optimization (PSO)

2. A introdução do conceito de *campo visão* para cada indivíduo, que ajuda a identificar de forma mais eficiente uma região promissora;
3. Realização da competição apenas entre parentes, levando a um esforço computacional menor evitando a ordenação de grande quantidade de variáveis;
4. O algoritmo é de fácil compreensão e implementação, sendo adequado para problemas de alta dimensionalidade e características não-convexas e/ou descontínuas.

O algoritmo proposto foi aplicado para resolver o problema do Planejamento da Operação de Sistemas Hidrotérmicos a curto prazo (STH), mostrando-se eficiente e competitivo em termos de qualidade das soluções encontradas assim como de tempo computacional.

O STH é um problema complexo não-linear, de contornos não convexos e de difícil resolução por métodos convencionais. O planejamento a curto prazo se preocupa com a operação em dias ou horas bases durante uma única semana, atendendo a demanda de forma a otimizar a operação elétrica e hidráulica, do seu ponto de vista, sujeita condições de fluxos determinadas, para que dessa forma o planejamento a longo/médio prazo seja realizado adequadamente [10].

A literatura apresenta um grande número de técnicas de otimização aplicadas a este problema, entre elas pode-se citar: relaxação de Lagrange [11]; programação dinâmica [12]; meta-heurísticas [13][14]; e soluções híbridas [15][16]. Em [17] é apresentado um resumo bibliográfico da aplicação do método dos pontos interiores ao problema.

O método foi validado com três sistemas-teste com soluções em espaços não-convexos. Os resultados da proposta são comparados com abordagens clássicas e algumas derivações.

O artigo está organizado como segue: primeiro é apresentada formulação do STH e uma breve revisão do estado da arte. Em seguida, é descrito o algoritmo proposto e por fim são reportados os resultados de testes e as conclusões deste trabalho.

2 Formulação do STH

O objetivo do STH é encontrar a política energética ótima entre o subsistema hidrelétrico e termelétrico em um determinado horizonte programação, com confiabilidade e por um custo mínimo [9]. Como a fonte da geração de energia hidrelétrica é a água, o objetivo principal é minimizar os custos de produção termelétrica enquanto são atendidas as restrições impostas aos dois subsistemas.

O problema da programação hidrotérmica é usualmente decomposto em sub-problemas menores para facilitar sua solução. O STH envolve três principais estágios de decisão, separados usando uma hierarquia decomposta no tempo: Coordenação Hidrotérmica (HTC), Pré-Despacho (PDE⁴) e Despacho Econômico (DE⁵) [8].

O problema da Coordenação Hidrotérmica (HTC) consiste em determinar a quantidade ótima de energia (hidráulico-térmica) que será gerada em um período de programação [17]. Conhecida a carga em cada período referente às unidades termo-geradoras, o problema UC trata de determinar quais unidades atuarão a cada hora de operação no período de estudo, a um custo mínimo. Para tal consideram-se restrições como: custos de partida, limites rampa e etc. Após determinada as unidades que atuarão durante os intervalos de programação, o ED encontra a configuração ótima entre estas.

Neste trabalho é assumido que o Pré-despacho já é conhecido, modelando simultaneamente restrições de HTC a curto prazo (intervalos de dias ou horas) e do ED.

2.1 Notação

τ Atraso entre as plantas;

n Índices para as plantas rio acima;

i Índices para as plantas termelétricas;

j Índices para os intervalos de planejamento;

F Custo de produção;

T Número de intervalos de planejamento;

Nt Número de plantas termelétricas;

Nh Número de plantas hidrelétricas;

Nu Número de plantas rio Acima;

D_j Demanda para o intervalo j ;

I_{ij} Fluxo natural de água para planta i no instante j ;

⁴Unit Commitment (UC)

⁵Economic Dispatch (ED)

Pt_{ij} Geração da planta termelétrica i no instante j ;

q_{ij} Vazão da planta hidrelétrica i no instante j ;

v_{ij} Volume da planta hidrelétrica i no instante j ;

s_{ij} Vertimento de água da planta i no instante j ;

Ph_{ij} Geração da planta hidrelétrica i no instante j ;

P_{loss} Perda na linha de transmissão;

v^0 Volume definido para o início do planejamento;

v^T Volume definido para o final do planejamento;

2.2 Formulação Matemática

Matematicamente o STH pode ser formulado como segue.

$$\begin{aligned} \text{Min: } & \sum_{i=1}^{Nt} \sum_{j=1}^T F(P_{ij}) \\ \text{s.a: } & i - iv \end{aligned} \quad (1)$$

O STH está sujeito a várias restrições impostas ao subsistema termelétrico e hidrelétrico incluindo entre outras: o balanço energético; limites operacionais, limites rampa e pontos válvula para o subsistema térmico; continuidade hidráulica, zonas de operação proibida, limites operacionais para o subsistema hidráulico. Algumas restrições são formuladas a seguir:

i Balanço de Potência:

$$\sum_{i=1}^{Nt} Pt_{ij} + \sum_{i=1}^{Nh} Ph_{ij} = D_j + P_{loss j} \quad (2)$$

ii Os limites operacionais do volume dos reservatórios, da taxa de vazão turbinada, e da geração de potência das hidrelétricas e termelétricas, são definidos conforme as equações 3-5.

$$v_i^{min} < v_{ij} < v_i^{max} \quad (3)$$

$$q_i^{min} < q_{ij} < q_i^{max} \quad (4)$$

$$Pt_i^{min} < Pt_{ij} < Pt_i^{max} \quad (5)$$

$$Ph_i^{min} < Ph_{ij} < Ph_i^{max} \quad (6)$$

iii O volume esperado no início e final do horizonte de programação é definido pelo planejamento de longo/médio prazo, e é modelado como:

$$\begin{aligned} v_t|^{t=0} &= v^0 \\ v_t|^{t=T} &= v^T \end{aligned} \quad (7)$$

iv Equação de continuidade hidráulica:

$$v_{ij} = v_{i(j-1)} + I_{ij} - q_{ij} - s_{ij} + \sum_{n=1}^{Nu} (q_{n(j-\tau_n)} + s_{j-\tau_n}) \quad (8)$$

A função do custo de produção de uma unidade termelétrica $F(P)$ é modelada como uma função do segundo grau acrescida de uma perturbação senoidal quando considerado o efeito dos pontos válvulas. Um exemplo típico é apresentado na seção IV Eq. 16.

Já a curva característica para a geração hidrelétrica é função dependente da taxa de vazão da água turbinada (q) e do volume armazenado no reservatório (v). Sua modelagem depende das restrições consideradas para cada planta, como o efeito da altura do reservatório (h) e o número de unidades de geração presentes na planta. Genericamente, pode ser definida como $q = f(Ph, v, h)$.

3 Descrição do Algoritmo

No SEA a população de soluções é chamada de *Enxame* e cada indivíduo da população é denominado *partícula*. Uma partícula i em um espaço de busca n -dimensional possui coordenadas hiper-espaciais $x_i \in R^n$ e velocidade

$$\lambda_i = \lambda_{i1}, \lambda_{i2}, \dots, \lambda_{in} \in R^n$$

. Além disso, cada partícula possui um campo de visão que irá auxiliar na geração de descendentes dessa partícula dentro do seu espaço de busca. A largura desse campo de visão é igual para cada partícula, sendo representada pelo vetor σ , onde $\sigma = \sigma_1, \sigma_2, \dots, \sigma_n \in R^n$. A Figura 1 apresenta um exemplo da localização de uma partícula qualquer e seu campo de visão em um espaço de busca unidimensional ρ .

Na Fig.1 o campo de visão da partícula - $f(\rho)$ é definido como uma função triangular $f: \rho \rightarrow \lambda$, onde a base do triângulo é uma sub-área dentro do espaço de busca ρ , aqui denominada *largura do campo de visão* (σ); para auxiliar na geração de descendentes, a altura do triângulo é mantida constante e igual a 1; a partícula encontra-se na posição x e poderá gerar descendentes nas posições d_1 e d_2 encontradas a partir de sua velocidade λ .

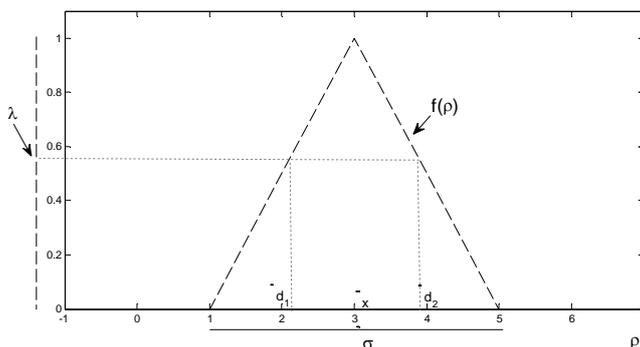


Figura 1: Campo de visão da partícula

Para um espaço de busca multidimensional, o campo de visão é considerado para cada gene de uma *Partícula* do *Enxame*. Assim $f(\rho)$ pode ser modelado matematicamente conforme apresentado na estrutura condicional da equação 9. Esta equação será importante durante o processo iterativo do SEA.

$$\begin{aligned}
 & \text{if } (|\rho - x_i| \leq \frac{\sigma}{2}) \\
 & \quad f_i(\rho) = -\frac{2}{\sigma}|\rho - x_i| + 1 \\
 & \text{else} \\
 & \quad f_i(\rho) = 0 \\
 & \text{end}
 \end{aligned} \tag{9}$$

Cada partícula mantém suas coordenadas no hiper-espaço de busca associadas a um valor de desempenho (*fitness*). Semelhante a outras técnicas baseadas em inteligência coletiva (*swarm intelligence*), o SEA mantém as melhores informações adquiridas durante o processo iterativo guardadas na memória coletiva do enxame. Conforme definido em [4], as posições de melhor avaliação de cada partícula são armazenadas em uma variável denominada *Pbest*. A melhor posição entre todas é chamada de *Gbest*.

3.1 O algoritmo do SEA

A Fig.2 apresenta a descrição dos passos do algoritmo.

```

INICIALIZAÇÃO DO ENXAME
iniciar vetores x, σ, λ
03% PARA i = 1:K
04% | x_i(0) <-- random(H);
05% | λ_i(0) <-- random(0,1);
06% | f_xi(0) <-- evaluate(xi);
07% FIM PARA
08% σ <-- largura do espaço de busca;
09%
PROCESSO ITERATIVO
11%
12% PARA t = 1:T
13% |
14% |   Geração de descendentes
15% |   |
16% |   |   PARA i = 1:k
17% |   |   | Atualiza velocidade λ_i(t)
18% |   |   | Gera [d1_i; d2_i] <-- f-1(λ_i);
19% |   |   | [d1_i; d2_i] <-- cruzamento([d1_i; d2_i]+Pbest)
20% |   |   |
21% |   |   Avaliação e disputa entre os descendentes
22% |   |   |
23% |   |   | f_d1 <-- avaliação(d1_i)
24% |   |   | f_d2 <-- avaliação(d2_i)
25% |   |   |
26% |   |   | SE f_d1_i < f_d2_i
27% |   |   | | x_i(t) <-- d1_i
28% |   |   | | SE NÃO:
29% |   |   | | x_i(t) <-- d2_i;
30% |   |   | FIM SE
31% |   |   |
32% |   |   Atualização da memória coletiva
33% |   |   | SE f_x_i(t) < f_Pbest_i(t)
34% |   |   | | Pbest_i(t) <-- x_i(t)
35% |   |   | | f_Pbest_i(t) <-- f_x_i(t)
36% |   |   | FIM SE
37% |   |   FIM PARA
38% |   |
39% |   Redimensionamento do campo de visão
40% |   |
41% |   | SE ALPHA for múltiplo de t
42% |   | | Avalia busca
43% |   | | SE Melhora na busca
44% |   | | | Diminui
45% |   | | SE NÃO
46% |   | | | Aumenta
47% |   | | FIM SE
48% |   | FIM SE
49% FIM PARA

```

Figura 2: Algoritmo do SEA

O primeiro passo do algoritmo refere-se ao posicionamento do grupo de partículas dentro do espaço de busca (H) e a inicialização dos vetores de velocidade e campo de visão. Conforme descrito na Fig.2, as posições das partículas (x) são inicializadas com coordenadas aleatórias dentro do espaço de busca; a velocidade (λ) é dada por um valor aleatório entre 0 e 1; e a largura do campo de visão (σ) é igual à largura total da área de busca. Após o posicionamento, o grupo é então avaliado e seus valores de desempenho (*fitness*) armazenados em um vetor $f(x) \in R^k$ sendo k o número de partículas no grupo.

Após a inicialização dos vetores que compõem as partículas do grupo, é iniciado o processo evolutivo do algoritmo. Este laço ocorrerá ao longo de um número (T) limitado de iterações durante os quais as partículas atualizam seus vetores de posição (x), velocidade (λ) e largura do campo de visão (σ), gerando novos descendentes dentro do espaço multidimensional.

3.2 Geração de descendentes das Partículas

O segundo passo do algoritmo é a etapa principal porque é nela que são criadas novas informações para a busca. Nesta etapa cada partícula i do *Enxame*, gera dois novos descendentes com coordenadas dentro do seu campo de visão, respectivamente d_{1_i} e $d_{2_i} \in R^n$, encontradas a partir de sua velocidade λ_i . Entretanto, antes da geração de descendentes é necessária a atualização das velocidades das partículas.

3.2.1 Atualização da velocidade

A atualização de λ_i pode ser feita considerando diversos fatores conhecidos pelas partículas, fatores estes provindo da memória individual ou da interação desta partícula com o resto do enxame com o conhecimento da melhor posição em que cada partícula já esteve ($Pbest_i$). A partir destes fatores, esta variável pode ser calculada com intuítos variados, tais como: não se aproximar demais de outras partículas; pesquisar novas regiões; refinar a busca em torno das melhores soluções, entre outras.

Neste trabalho, o movimento do *Enxame de Partículas* é realizado de forma que a busca se concentre nas melhores posições até então encontradas. Assim, para atualização de λ são considerados três fatores provindos da memória coletiva do Enxame: (i) a melhor posição entre todas encontradas ($Gbest$); (ii) a melhor posição encontrada por cada partícula ($Pbest_i$) e; (iii) a inércia, referente ao valor atual de λ . Dessa forma, a velocidade para cada partícula é atualizada a cada iteração de acordo com a média aritmética desses 3 fatores conforme a Eq. 10, sendo f uma função triangular apresentada em Eq. 10.

$$\lambda_i = \frac{f(Gbest) + f(Pbest_i) + \lambda_i}{3} \quad (10)$$

Para geração das posições dos novos descendentes, a idéia é que cada partícula gere duas posições d_{1_i} e d_{2_i} a partir do seu campo de visão, sendo λ a representação do quão afastado da posição atual (x_i) as posições serão geradas.

Conforme é observado na Figura 1, a solução para $f^{-1}(\lambda_i)$ são duas posições d_{1_i} e d_{2_i} equidistantes de x_i , sendo a distância de qualquer uma das duas posições para x_i proporcional ao valor de λ_i . Tais posições podem ser interpretadas como possíveis posições de deslocamento para “procria” da partícula. Matematicamente, d_{1_i} e d_{2_i} podem ser determinados como segue:

$$d_{1_i} = x_i + \frac{\sigma(1 - \lambda_i)}{2} \quad e \quad d_{2_i} = x_i - \frac{\sigma(1 - \lambda_i)}{2} \quad (11)$$

Seguindo as etapas do fluxograma após a atualização de λ (10), são encontradas as posições referentes aos descendentes das partículas (vide Equação 11). Respectivamente, linhas 18 e 19 do fluxograma.

3.2.2 Cruzamento

Depois de encontradas as duas coordenadas (d_{1_i} e d_{2_i}) para os descendentes de cada partícula i e antes da avaliação e disputa entre os descendentes, é realizado um processo de cruzamento entre a população de descendentes (d_x) e as posições armazenadas na memória coletiva do grupo ($Pbest_i$). A realização deste processo nesta etapa do algoritmo implica em uma aceleração da convergência do mesmo, onde uma informação nova gerada (d_{1_i} e d_{2_i}) é misturada a uma boa informação já conhecida, de modo que a busca se realize em torno das melhores regiões. Em outras palavras, isto aproxima o grupo às melhores posições encontradas, tornando as novas partículas mais "fortes". Por outro lado, este processo pode levar o algoritmo a cair em um ótimo local. Para evitar isto, é recomendável que esse processo não ocorra a uma taxa elevada, assim as novas informações têm mais chance de serem repassadas.

A recombinação usada é do tipo discreta, similar à recombinação uniforme do GA [7] [18].

3.3 Avaliação e disputa entre os descendentes

Definidos os dois descendentes gerados por cada partícula e guardados em d_1 e d_2 , a partícula pai i dá lugar para o descendente que tem a posição melhor avaliada entre d_1 e d_2 . A nova partícula passa a fazer parte do Enxame e é herda os valores de velocidade e largura do campo de visão.

Nesta etapa também é calculada a função de desempenho, e a memória coletiva do Enxame (matriz $Pbest$ assim como os valores de fitness) são atualizados (linhas 21-37 do fluxograma).

3.4 Atualização do campo de visão das partículas

Um aspecto importante durante a busca é a forma como a largura campo de visão das partículas muda sua extensão ao longo das iterações do Algoritmo. O campo de visão da partícula representa uma região onde a partícula gera seus novos descendentes. O tamanho desta região vai variando ao longo das iterações. Conforme o Enxame vai buscando em uma determinada área, ele pode escolher por restringir sua busca - focalizar seu campo de visão para uma área menor - ou por expandir sua busca a áreas nunca antes visitadas.

O redimensionamento da largura do campo de visão das partículas é realizado conforme a regra do sucesso do 1/5 proposta por Rechenberg [18]. Esta regra é aplicada a cada α iterações do algoritmo, onde α é outro parâmetro do método.

$$\sigma = \begin{cases} \sigma \cdot \delta & \text{se } \varphi < 1/5 \\ \sigma / \delta & \text{se } \varphi > 1/5 \\ \sigma & \text{se } \varphi = 1/5 \end{cases} \quad (12)$$

Sendo $\varphi(\alpha)$ a taxa de sucesso da população durante as últimas α iterações. $c_i > 1$ e $c_d < 1$ regulam o incremento e decremento da extensão do campo de visão das partículas.

4 Estudos de casos

Esta seção apresenta estudos de casos para a aplicação do SEA ao problema do planejamento da operação de sistemas hidrotérmicos a curto prazo. Este estudo assume que o problema do Pré-Despacho já foi solucionado, e somente o subproblema do despacho é considerado, a fim de concentrar-se nas peculiaridades do sub-sistema hidráulico. Para a análise, dois sistemas hidrotérmicos foram considerados. Em ambos o sub-sistema térmico é representado por um única planta equivalente.

4.1 Descrição dos testes

Teste 1 - (SHT-11) Sistema composto por uma planta termelétrica e uma hidrelétrica. O problema, inicialmente proposto em [1], apresenta a coordenação entre as unidades em um horizonte de três dias em intervalos de 12 horas. A curva de custo e os limites operacionais de geração para a planta termelétrica equivalente são representados nas equações 13 e 14, respectivamente.

$$F(P_t) = 575 + 9.2P_t + 0.000184P_t^2 \quad (\$/h) \quad (13)$$

$$150 < P_t < 1500 \quad (MW) \quad (14)$$

O modelo matemático para a geração de potência na unidade hidrelétrica é composto apenas da vazão de água conforme descrito abaixo:

$$\begin{aligned} q_j &= 0, \quad \text{if } Ph_j = 0 \\ q_j &= 330 + 4.91Ph_j, \quad \text{if } 0 < Ph_j < 10^3 \\ q_j &= 5300 + 12(Ph_j - 10^3) + 0.05(Ph_j - 10^3)^2, \quad \text{if } Ph_j > 10^3 \end{aligned} \quad (15)$$

O fluxo de água na reserva é constante durante todo o horizonte de planejamento e é igual a 2000 (m^3/h). O volume na reserva é calculado pela equação de continuidade hidráulica Eq. 8, considerando para tal a ausência de vertimento na reserva. Na Tabela 1 são apresentados a capacidade máxima e mínima da reserva, assim como o volume esperado no início e no fim do horizonte de planejamento. Os valores da curva de demanda é apresentada na Tabela 2.

Tabela 1: Configuração do volume do reservatório (m^3)

v_min	v_max	v_inic	v_final
60000	120000	100000	60000

Tabela 2: Demanda para o STH-11

Intervalo	Dia	horas	Carga (MW)
1	1	0-12h	1200
2	1	12-24h	1500
3	2	0-12h	1100
4	2	12-24h	1800
5	3	0-12h	950
6	3	12-24h	1300

Para este sistema quatro simulações foram realizadas, cada uma considerando uma variável diferente a ser otimizada: (i) o volume da reserva; (ii) a taxa de vazão de água; (iii) a potência gerada pela hidrelétrica; e (iv) a potência gerada pela termelétrica.

Teste 2 - (SHT-14) Apresenta um sistema hidrotérmico contendo um sub-sistema hidráulico e uma única planta térmica equivalente. O período de coordenação é de 24h com intervalos de uma hora. O problema foi inicialmente proposto em [2] e mais tarde recebeu o acréscimo de algumas restrições em [3].

O sub-sistema hidráulico é composto de quatro plantas hidrelétricas e possui, entre outras, as seguintes características: plantas em cascata, sendo que todas elas estão em um único rio; atraso de transporte de água entre reservas sucessivas; variação do fluxo natural de água de cada reserva; demanda de carga variável durante todo o período de programação; regiões de operação proibidas para a geração de potência ou vazão de água turbinada.

Os dados referentes a este problema, como a curva de demanda, fluxo de água em cada reservatório além das capacidades de armazenamento e os limites de geração plantas hidrelétricas podem ser encontrados em [2].

A curva de custo da planta termelétrica equivalente considerando a restrição dos pontos válvulas e os limites operacionais de geração de potência são apresentados nas equações 16 e 17 respectivamente.

$$F(P_t) = 5000 + 19 \cdot P_t + 0.002P^2 + |700\sin \cdot (0.0085(P_t - P_t^{min}))|(\$/h) \quad (16)$$

$$500MW < P_t < 2500MW \quad (17)$$

Neste teste foram realizados dois tipos de simulações: (i) desconsiderando as restrições de pontos válvula e de zonas de operação proibida para a taxa de vazão da água e (ii) considerando restrições de pontos válvula e de zonas de operação proibida para a taxa de vazão da água.

4.2 Análise e resultados dos testes

4.2.1 Análise de parâmetros para o SEA

Uma importante etapa na simulação e análise de resultados é o dimensionamento dos parâmetros. O SEA apresenta 4 parâmetros principais (número de interações, tamanho da população, alfa e cross_rate). Neste trabalho, para a análise dos resultados e determinação dos parâmetros para a técnica, várias simulações foram executadas, em cada simulação os parâmetros eram modificados para comparação dos resultados. Em todos os estudos de casos foram realizadas 50 execuções independentes para cada simulação.

4.2.2 Resultados para o sistema STH-11

Os resultados dos testes considerando as quatro opções de variáveis de otimização são apresentadas na Tabela 3. Nota-se, pela tabela, que os melhores resultados foram encontrados para a simulação STH-11.i, ou seja, quando utilizado o volume do reservatório como gene. Observa-se, pelos resultados dos testes, que a variável solução que melhor responde ao problema ou a que retorna um menor custo, é o volume do reservatório. Esta característica também é observada quando o problema é resolvido por outros métodos como em [4] e [5].

A Tabela 4 é referente aos resultados de custo médio e mínimo para o teste com o SHT-11.i. Observa-se que o algoritmo SEA consegue encontrar a melhor solução média entre os dez métodos apresentados. Além disso, apresenta uma solução melhor que a encontrada até agora na literatura, que era de (\$)693.428,5 [4].

Este sistema, por possuir poucas unidades, é didático para demonstrar o comportamento ideal entre a contribuição da unidade termelétrica e da unidade hidrelétrica para o suprimento da demanda. Uma característica inerente dos sistemas hidrotérmicos é o custo indireto de oportunidade da hidrelétrica economizar combustível, onde o valor ótimo é obtido quando se equilibram valores imediatos e futuros do uso da água.

Tabela 3: Volumes (m^3) para as 4 simulações do STH11

dias	teste i	teste ii	teste iii	teste iv
dia 1	96551,51975	96856,49753	101927,9557	101356,9418
dia 1	75211,04196	75339,94332	85963,42987	86408,61098
dia 2	99211,04196	99339,94332	93855,29933	94234,86326
dia 2	60000	60000	60000	60077,84594
dia 3	84000	84000	70437,00013	71107,50652
dia 3	60000	60000	60000	60000
Custo	693.427,0830	693.427,921	709.862,0489	709.792,9794

Tabela 4: Comparação de resultados com outras técnicas

Método	Custo (\$)
GS [1]	709877.3800
IFEP [3]	709862.0500
SA [6]	709874.3600
GAF [5]	709863.7000
CEP [5]	709862.6500
FEP [5]	709864.5900
PSO [5]	709862.0480
Hybrid-EP [7]	703180.2600
PSO [4]	696002.3000
SEA(med)	694618.4526
SEA(max)	697676.1210

Essa característica pode ser observada na Figura 3 abaixo. Note que a contribuição da termelétrica é maior no intervalo 3 (dia 2); neste período a hidrelétrica economiza energia (volume de água) para suprir uma demanda mais alta no período seguinte (intervalo 4). Situação semelhante ocorre no dia seguinte (intervalos 5 e 6).

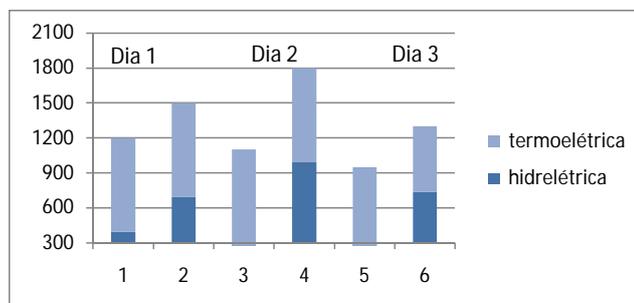


Figura 3: Contribuição das unidades térmicas e hidráulicas.

O tempo médio de processamento para as quatro simulações foram de 1s. Os parâmetros ótimos para os 4 testes foram: número de partículas igual a 100, 600 iterações, $cross_rate = 0.5$ e $Alfa = 50$.

4.2.3 Resultados para o sistema STH-14

Os resultados dos testes para o STH-14 são apresentados nas Tabelas 5, 6 e 7. Nota-se na Tabela 6 que para ambos os testes, em comparação com as outras técnicas, o SEA encontra a melhor solução apresentada até o presente momento e respeita as restrições impostas pelo problema. A Figura 4 apresenta o comportamento programado para os reservatórios das quatro plantas hidrelétricas ao longo das 24 horas sem considerar as zonas de operação proibidas. Observa-se como característica da programação ótima deste sistema que para que ele funcione a custo mínimo é necessário que o reservatório da planta quatro permaneça com um volume grande de água armazenado por mais tempo em relação as outras reservas.

Para ambos os testes do STH-14 foram considerados um Enxame com 50 Partículas, 10000 iterações, $cross_rate = 0,7$ e $alfa = 50$.

5 Conclusão

Neste trabalho foi apresentada uma proposta para resolução do problema do STH através de uma nova meta-heurística evolutiva inspirada no comportamento coletivo de algumas espécies da natureza, o SEA.

Nos casos testes considerados, as soluções obtidas respeitam todas as restrições impostas por cada problema tais como limites operacionais e de continuidade hidráulica. Além disso, o SEA se mostrou competitivo na medida que encontrou bons resultados para problemas tanto de pequeno porte (STH-11) quanto para problemas não-convexos, não-contínuos e de grande dimensionalidade como é o caso do STH-14.

Os resultados dos testes de validação do algoritmo demonstram que o SEA é capaz de encontrar boas soluções e se mostra uma técnica robusta na medida que sua busca é mais sensível às características de não-linearidade do STH.

Tabela 5: Geração termelétrica e vazões para o STH104.i

hr	G. thermal	q1	q2	q3	q4
1	1036,9578	9,21918	6,05317	29,96138	13,00314
2	1064,3325	8,52706	7,27310	29,95454	13,00817
3	1054,4947	8,50779	6,08837	29,99201	13,07833
4	1007,6921	7,12195	6,32745	29,96553	13,03828
5	980,5312	7,90810	6,32100	29,69940	13,00261
6	1044,8864	8,38187	6,96741	15,31799	13,03047
7	1267,6751	7,74656	6,90772	14,35307	13,02829
8	1592,1247	8,42144	7,36156	13,97176	13,00644
9	1808,2227	8,94455	7,52324	14,97512	13,66673
10	1880,8984	8,58362	8,12960	15,26122	14,02001
11	1792,8456	7,62963	8,18976	16,31229	14,49769
12	1862,6975	9,45538	8,27367	14,24695	13,65338
13	1767,4225	9,25586	8,48453	15,59654	15,39290
14	1735,5033	8,73939	7,82034	15,99182	16,25214
15	1672,1832	8,63850	8,08545	16,01326	14,88735
16	1605,2558	9,87305	8,98930	16,32680	14,34405
17	1650,5540	9,15325	9,80545	15,42989	15,76703
18	1673,3626	6,99611	9,52209	15,40785	16,15095
19	1756,5578	8,24536	12,30483	13,94784	15,62854
20	1803,5929	7,34835	9,60076	13,35659	16,85146
21	1759,8289	6,72564	12,68320	10,12759	16,66108
22	1634,9008	7,91634	10,04046	10,69743	17,41687
23	1366,3364	6,13946	9,33055	10,71321	20,89322
24	1111,2839	5,52279	9,91697	10,73093	22,60275

Tabela 6: Geração termelétrica e vazões para o STH104.ii

hr	G. thermal	q1	q2	q3	q4
hr	g. termelétrica	vazão Ph1	vazão Ph2	vazão Ph3	vazão Ph4
1	1054,4042	5,96149	6,60731	29,91328	13,00069
2	1054,4171	11,11603	6,79863	29,98238	13,06260
3	1054,3987	7,87710	6,72174	29,88192	13,03087
4	980,4793	10,98144	6,99997	29,42556	13,58395
5	980,4789	7,67151	6,87027	29,11382	13,04170
6	1054,3987	9,12682	6,30620	17,69610	13,00904
7	1276,1582	6,83623	6,31814	14,46281	13,34103
8	1571,8375	9,92910	9,41855	14,33020	13,47247
9	1830,5569	7,29636	6,07613	14,33287	13,52408
10	1867,5168	9,56007	8,34386	14,10003	14,53863
11	1793,5970	9,93187	6,67046	15,43534	13,67080
12	1830,5569	10,27685	11,08565	13,24188	15,19277
13	1793,5970	9,47487	6,20441	14,70646	13,60711
14	1719,6771	9,81144	9,94587	14,38990	15,58773
15	1682,7172	6,49065	11,59771	18,24196	14,27588
16	1645,7573	5,95847	8,42659	17,56110	13,63563
17	1682,7172	6,71864	10,63725	17,51594	14,34777
18	1682,7172	9,05581	9,27266	15,56843	13,90878
19	1756,6371	7,12808	9,21669	13,75533	18,40130
20	1793,5970	6,57973	10,45700	14,13975	18,79953
21	1756,6371	5,83048	9,91263	11,41204	19,73479
22	1608,7974	10,07125	9,08922	10,05201	21,66510
23	1387,0379	5,68444	10,20074	10,00011	18,26105
24	1128,3185	5,63145	8,82234	10,61277	19,90174

Tabela 7: Custo médio, máximo e desvpad para o STH14.

	teste 1	teste 2
EGA [8]	934727.0000	NLP [9] 936709.5200
GA [2]	932734.0000	DP [9] 935617.7600
FEP [3]	930268.0000	IFEP [3] 933949.2500
CEP [3]	930166.0000	DE [9] 928236.9400
IFEP [3]	930130.0000	HDE [10] 927895.8100
PSO [8]	928878.0000	APSO [11] 925991.3500
BCGA [12]	926922.7100	IPSO [9] 925978.8400
RCGA [12]	925940.0300	MDE [10] 925960.5600
LWPSO [13]	925383.8000	MHDE [10] 925547.3100
DE [13]	923991.0800	MAPSO [11] 924636.8800
EPSO [8]	922904.0000	ACDE [14] 924661.5300
IPSO [9]	922553.4900	- -
MAPSO [11]	922421.6600	- -
SEA (min)	922389.5007	SEA (min) 923805.2970
SEA (med)	923196.5699	SEA (med) 926360.6510
SEA (max)	924717.3618	SEA (med) 928759.3436
desvPad	484	945
cpu time	22,7886	25,0878

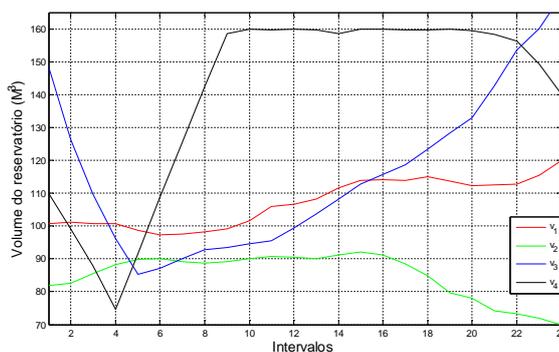


Figura 4: volume no reservatórios ao longo do período de programação (solução para STH-14.i).

Referências

- [1] A. Wood and B. Wollenberg. *Power Generation, Operation and Control*. Willey, New York, second edition, 1996.
- [2] S. Orero and M. Irving. “A genetic algorithm modelling framework and solution technique for short term optimal hydrothermal scheduling”. *IEEE Transactions on Power Systems*, vol. 13, no. 2, pp. 501–518, may. 1998.
- [3] N. Sinha, R. Chakrabarti and P. K. Chattopadhyay. “Fast evolutionary programming techniques for short term hydrothermal scheduling”. *IEEE Transaction Power System*, vol. 18, pp. 214–220, 2003.
- [4] C. Samudi, D. G. P. Ojha, P. C. Sreeni and S. Cherian. “Hydro thermal scheduling using particle swarm optimization”. *Transmission and Distribution Conference and Exposition*, vol. 1-5, 2008.
- [5] N. Sinha and L. L. Lai. “Meta Heuristic Search Algorithms for ShortTerm Hydrothermal Scheduling”. *International Conference on Machine Learning and Cybernetics*, pp. 4050 – 4056, 2006.
- [6] K. P. Wong and Y. W. Wong. “Short-term hydrothermal scheduling, part-I: Simulated annealing approach”. *IEE Proc.*, vol. 141, pp. 497 – 501, 1994.
- [7] D. S. Suman, C. N. J. Henry and S. Ravichandran. “A Novel Approach for ShortTerm Hydrothermal Scheduling Using Hybrid Technique”. *IEEE Power India Conference*, pp. 10–12, 2006.
- [8] X. Yuan, L. Wang and Y. Yuan. “Application of enhanced PSO approach to optimal scheduling of hydro system”. *Energy Conversion and Management*, vol. 49 (11), pp. 2966–2972, 2008.
- [9] P. K. Hota, A. Barisal and R. Chakrabarti. “An improved PSO technique for short-term optimal hydrothermal scheduling”. *Electric Power Systems Research*, 2009.
- [10] L. Lakshminarasimman and S. Subramanian. “A modified hybrid differential evolution for short-term scheduling of hydrothermal power systems with cascaded reservoirs”. *Energy Conversion and Management*, vol. 49(10), pp. 2513–2521, 2008.
- [11] A. N. and S. H.R. “Daily Hydrothermal Generation Scheduling by a new Modified Adaptive Particle Swarm Optimization technique”. *Electric Power Systems Research*, vol. 80 (6), pp. 723–732, june 2010.
- [12] S. Kumar and R. Naresh. “Efficient real coded genetic algorithm to solve the non-convex hydrothermal scheduling problem”. *International Journal of Electrical Power and Energy Systems*, vol. 29 (10), pp. 738–747, 2007.
- [13] X. Yu, B. and Yuan and J. Wang. “Shortterm hydrothermal scheduling using particle swarm optimization method”. *Energy Conversion and Management*, vol. 8, pp. 1392 – 1399, 2007.
- [14] Y. Lu, Q. H. Zhou, J. and, Y. Wang and Y. Zhang. “An adaptive chaotic differential evolution for the short-term hydrothermal generation scheduling problem”. *Energy Conversion and Management*, vol. 51, pp. 1481–1490, 2010.