

# PROGRAMAÇÃO DIÁRIA DA OPERAÇÃO DE SISTEMAS TERMOELÉTRICOS DE GERAÇÃO UTILIZANDO ALGORITMO DE OTIMIZAÇÃO SENOS E COSENOS E INFORMAÇÕES HEURÍSTICAS

LAYON M. DE OLIVEIRA, PEDRO HENRIQUE M. NASCIMENTO, FREDERICO F. PANOEIRO, IVO C. SILVA JUNIOR, LEONARDO W. DE OLIVEIRA

*Laboratório de Sistemas de Potência, Depto. de Energia Elétrica, Universidade Federal de Juiz de Fora  
Rua José Lourenço Kelmer, São Pedro, Juiz de Fora/MG – CEP: 36036-900*

*E-mails: layonmescolin@hotmail.com, pedro.nascimento@engenharia.ufjf.br,  
frederico.panoeiro@engenharia.ufjf.br, ivo.junior@ufjf.edu.br,  
leonardo.willer@ufjf.edu.br*

**Abstract**— The proposal of the present paper is to apply the recent multimodal optimization method known as sine-cosine algorithm (SCA) for solving the problem related to the planning of thermoelectric energy generation systems operation. The proposed approach is evaluated in its original form as well as associated with the use of heuristic information from sensitivity indexes, in the context of priority lists concept of literature. Therefore, with the purpose of assessing the proposed hybrid approach, two well-known systems from literature are simulated and the obtained results are compared with those from the multimodal process based on ant colony optimization in addition to others found in the related literature. The carried out studies indicate the best efficiency of the proposed hybrid approach.

**Keywords**— planning , heuristic , optimization, multimodal, thermoelectric.

**Resumo**— A proposta do presente trabalho é aplicar o método recente de otimização multimodal denominado seno-cosseno (SCA) para a resolução do problema referente ao planejamento da operação de sistemas termoeletricos de geração de energia elétrica. A metodologia é avaliada em sua forma original, bem como associada ao uso de informações heurísticas oriundas de índices de sensibilidade, no âmbito do conceito de listas de prioridade existente na literatura. Desta forma, para validar e aferir a metodologia híbrida proposta foram simulados dois sistemas bastante difundidos na literatura e os resultados comparados com o processo de otimização multimodal baseado em colônia de formigas e os resultados apresentados na literatura especializada. Os resultados apontam para uma maior eficiência do modelo híbrido proposto.

**Palavras-chave**— planejamento, heurísticas , otimização, multimodal, termoeletricas.

## 1 Introdução

A demanda de energia elétrica e a atividade humana seguem ritmos semelhantes, sendo estes ditados pela sociedade através de suas componentes residenciais, comerciais e industriais. Diante destes ritmos, que crescem de forma acentuada, o atendimento a demanda de forma econômica torna-se um fator importante na operação dos sistemas elétricos de potência (Padhy, 2004).

O atendimento econômico a demanda, conhecido também como despacho econômico (DE), visa determinar unicamente a potência de saída de cada unidade geradora do sistema de forma a minimizar o custo total de operação. Entretanto, o DE não considera a variação da demanda ao longo do tempo (Silva Junior et al, 2013).

Esta análise é importante, pois possibilita o desligamento e/ou acionamento de determinadas unidades geradoras durante um determinado período de operação pré-estabelecido, o que envolve novos custos e restrições técnicas que limitam as opções de decisão.

Desta forma, a seleção das unidades geradoras a serem colocadas em serviço representa um problema hierarquicamente superior ao despacho econômico.

O planejamento da operação de sistemas termoeletricos de geração de energia elétrica é formulado como um problema de programação não linear inteira mista que apresenta algumas particularidades, tais como: (i) Região de solução não convexa, o que permite a existência de várias soluções e conduz grande parte dos algoritmos a convergirem em direção de mínimos locais; (ii) Natureza combinatória do processo de decisão, que leva ao fenômeno da explosão combinatória referente às alternativas de geração, acarretando elevado tempo computacional; (iii) Natureza Dinâmica do processo de Decisão, que limita as opções de decisão e consequentemente ocasiona antagonismo em relação ao despacho econômico (Viana, Sousa and Matos, 2003; Yang, Yang and Huang, 1996). As dificuldades descritas anteriormente evidenciam que o desenvolvimento de técnicas e algoritmos que conciliem rapidez, robustez e eficiência na resolução do problema é um campo atrativo de estudo e pesquisa.

Fazendo uma breve busca na literatura podem-se verificar as seguintes técnicas de resolução: Listas de Prioridade (Alam, Hari Kiran and Kumari, 2016), Programação Inteira Mista (Li et al, 2014), Programação Dinâmica baseada em redes neurais (Kumar and ), Relaxação Lagrangeana (Bragin et al, 2015), além de técnicas híbridas (Ting, Rao and Loo,

2006). Entretanto, apesar da grande variedade de técnicas empregadas para resolução do problema, a solução ótima global só pode ser garantida através da enumeração exaustiva de todas as alternativas de decisão de operação, o que pode tornar sua obtenção inviável.

A resolução de problemas não lineares e com regiões de solução não convexa torna a utilização de métodos exatos bastante restrita, sendo este o motivo que justifica esforços na utilização de heurísticas para solucionar problemas desta natureza. Sendo assim, a partir da associação entre os conceitos da área de otimização e de inteligência artificial, é possível conceber estratégias heurísticas mais eficientes e inteligentes, as quais são conhecidas como metaheurísticas ou métodos de otimização multimodais.

Nos últimos anos, é possível observar o desenvolvimento de novas abordagens para problemas de otimização multimodal. Esses desenvolvimentos têm-se apresentado com certa eficiência na resolução de inúmeros problemas não só de engenharia, mas de outras áreas de conhecimento. Atualmente, tais algoritmos fazem parte de um conjunto de ferramentas que se associam a um grande número de projetos de alta tecnologia, sendo a otimização baseada em funções seno e cosseno (Mirjalili, 2016) aplicada no presente trabalho.

Os resultados obtidos através da simulação de sistema termoeletrônicos compostos por dez e vinte unidades geradoras, amplamente difundidos na literatura, demonstram a aplicabilidade da metodologia proposta e apontam para importância da utilização de técnicas híbridas na resolução de problemas multimodais.

## 2 Formulação do problema

### 2.1 Notações Utilizadas

A notação a seguir é utilizada na formulação do problema aqui estudado.

$T$	Número total de períodos do horizonte de operação (horas);
$NG$	Número total de unidades geradoras;
$a_i, b_i, c_i$	Componentes constante (\$/h), linear (\$/MWh) e quadrática (\$/MW <sup>2</sup> h) de custo da unidade geradora $i$ , respectivamente;
$Pg_i(t)$	Potência ativa gerada pela unidade $i$ (MW) no instante $t$ ;
$CP_i(t)$	Custo (\$) de partida da unidade geradora $i$ no instante $t$ ;
$CD_i(t)$	Custo (\$) de desligamento da unidade geradora $i$ no instante $t$ ;
$U_i(t)$	Variável binária de decisão de operação (1) ou não (0) para a unidade geradora $i$ no instante $t$ ;
$T_{ij}^{ON}$	Número de horas que a unidade geradora $i$ está em operação até a hora $j$ ;

$T_{ij}^{OFF}$	Número de horas que a unidade geradora $i$ está sem operar até a hora $j$ ;
$TMP_i$	Tempo mínimo de partida (horas) da unidade geradora $i$ ;
$TMD_i$	Tempo mínimo de desligamento da unidade térmica $i$ ;
$csh_i$	Tempo de partida a frio (horas) da unidade térmica $i$ ;
$CP_i^f$	Custo de partida a frio (\$) da unidade geradora $i$ ;
$CP_i^q$	Custo de partida (\$) a quente da unidade geradora $i$ ;
$Pl(t)$	Valor da demanda (MW) no instante $t$ ;
$rg(t)$	Reserva girante prevista (MW) para o instante $t$ (percentual da demanda solicitada no instante $t$ );
$Pg_i^{min}$	Limite mínimo de geração de potência ativa (MW) da unidade geradora $i$ ;
$Pg_i^{max}$	Limite máximo de geração de potência ativa (MW) da unidade geradora $i$ ;
$Pg_i^{med}$	Potência média gerada;
$Pg_i^{otm}$	Potência ótima gerada;
$CI_i$	Número de horas que a unidade $i$ está ligada (+) ou desligada (-) no início do horizonte de operação estudado;
$\alpha$	Constante do algoritmo SCA; e
$t_{max}$	Número máximo de iterações do algoritmo SCA;
$r_2, r_3$ e $r_4$	Números aleatórios gerados durante a execução do algoritmo SCA.

### 2.2 Formulação

Para a otimização da programação diária de sistemas termoeletrônicos de geração, a função objetivo é formulada em (1), onde são considerados o custo de operação das unidades termoeletrônicas (2) e o custo de partida (3) referente ao período em análise.

$$\text{Min FOB} = C_1 + C_2 \quad (1)$$

$$C_1 = \sum_{t=1}^T \sum_{i=1}^{NG} [a_i + b_i \cdot Pg_i(t) + c_i \cdot Pg_i^2(t)] \cdot U_i(t) \quad (2)$$

$$C_2 = \sum_{t=1}^T \sum_{i=1}^{NG} CP_i(t) \cdot U_i(t) \cdot [1 - U_i(t-1)] \quad (3)$$

O custo de partida é dependente de quanto tempo a unidade permanecer sem operar antes de ser acionada. Abaixo observa-se a dinâmica a ser seguida:

$$CP(t) = CP^f \text{ se } T^{OFF} \geq csh$$

$$CP(t) = CP^q \text{ se } T^{OFF} < csh$$

A função objetivo apresentada em (1), está sujeita às seguintes restrições: (i) atendimento da demanda horária (4); (ii) atendimento à reserva girante (5), adotada como 10% do valor da demanda horária de acordo com (Kazarlis, Bakirtzis and Petridis, 1996);

(iii) tempos mínimos de parada e partida (6); (iv) restrições de canalização da geração de potência de cada unidade termoeletrica (7).

$$\sum_{i=1}^{NG} U_i(t) \cdot Pg_i(t) = Pl(t) \quad (4)$$

$$\sum_{i=1}^{NG} U_i(t) \cdot Pg_i^{max} \geq Pl(t) + rg(t) \quad (5)$$

$$T_{ij}^{ON} \geq TMP_i \quad (6)$$

$$T_{ij}^{OFF} \geq TMD_i$$

$$Pg_i^{min} \leq Pg_i(t) \leq Pg_i^{max} \quad (7)$$

### 3 Metodologia proposta

No intuito de resolver o problema descrito na seção anterior foi proposto um algoritmo que combine quatro etapas distintas, (A) garantia de soluções factíveis, (B) heurísticas, (C) SCA e (D) refinamento das soluções. As etapas mencionadas são apresentadas a seguir.

#### 3.1 Soluções Factíveis

A programação diária da operação de sistemas termoeletricos é conhecida por apresentar número elevado de combinações de operação. De uma amostragem aleatória, é possível que a configuração de “0” e “1” referentes ao funcionamento de usinas ao longo do dia não atenda às restrições do problema. Neste sentido, a metodologia aqui proposta garante a viabilidade das soluções ao garantir o cumprimento de restrição ao atendimento à demanda e reserva, além do cumprimento dos tempos mínimos de parada e partida. Neste sentido, para que uma solução não factível atenda as restrições, é necessário que uma ou mais usinas entrem em operação. As usinas que serão acionadas seguirão uma das heurísticas propostas neste trabalho.

#### 3.2 Heurísticas

A utilização de informações que tenham como objetivo facilitar de alguma forma a resolução de problemas de grande porte é denominada heurística (Goldberg and Luna, 2000). Desta forma, para que a factibilidade das soluções seja garantida, a metodologia proposta faz uso do conceito de listas de prioridades ou ordens de mérito. Para tanto, dois índices conhecidos na literatura serão investigados: (i) lista baseada no custo médio de geração, denominado aqui de OMA (Momoh, 2005); (ii) lista baseada em multiplicadores de lagrange, denominado aqui de OMB (Silva Junior et al, 2008).

#### 3.3 SCA

Como o objetivo deste trabalho é verificar o desempenho da metodologia híbrida, a qual conjuga informações da lista de prioridade e uma metodologia recente de otimização multimodal, foi utilizada a metaheurística baseada no algoritmo proposto por Mirjalili (2016), denominado Sine Cosine Algorithm (SCA). O SCA tem como proposta a busca pela melhor solução através da aproximação ou distanciamento entre uma solução  $X_i$  qualquer e a melhor solução  $P_i$ . A partir desta premissa, as soluções são atualizadas em uma iteração ‘ $t + 1$ ’ para  $X_i^{t+1}$  de acordo com as equações (11) ou (12).

$$X_i^{t+1} = X_i^t + r_1 \cdot \sin(r_2) \cdot |r_3 \cdot P_i^t - X_i^t| \text{ se } r_4 < 0,5 \quad (11)$$

$$X_i^{t+1} = X_i^t + r_1 \cdot \cos(r_2) \cdot |r_3 \cdot P_i^t - X_i^t| \text{ se } r_4 \geq 0,5 \quad (12)$$

Com:

$$r_1 = \alpha - \left( \alpha * \frac{t}{t_{max}} \right) \quad (13)$$

Ainda de acordo com Mirjalili (2016), através de  $r_1$ , o algoritmo tem a capacidade de busca global nas primeiras iterações e buscas locais mais ao fim do processo iterativo;  $r_2$  define quão longo deve ser o passo em direção direta ou oposta à melhor solução;  $r_3$  atenua ou aumenta a magnitude da melhor solução e;  $r_4$  decide se a equação utilizada é a do seno ou a do cosseno. Todos os valores anteriores, com exceção de  $r_1$ , são aleatórios em uma faixa predeterminada para o tipo de problema em estudo. Inicialmente SCA foi criado para resolução de problemas contínuos, portanto, para a obtenção dos valores discretos necessários à matriz de decisões  $U_i(t)$ , foi adotado o seguinte critério para discretização:

$$X_i^{t+1} = 1 \text{ se } X_i^{t+1} \geq 0,5; \text{ ou}$$

$$X_i^{t+1} = 0 \text{ se } X_i^{t+1} < 0,5$$

#### 3.4 Refinamento de Soluções

Como a garantia da factibilidade das soluções é realizada apenas na ativação das unidades térmicas, realiza-se um refinamento de soluções através da busca de unidades ativas sobressalentes, ou seja, que estão excedendo à demanda horária. Tal refinamento é feito utilizando as ordens de mérito apresentadas na seção 3.2. Desta forma, as unidades desligadas serão as de menor importância segundo a heurística adotada por cada lista de prioridade/ordem de mérito. O fluxograma da metodologia proposta é apresentado na Figura 1.

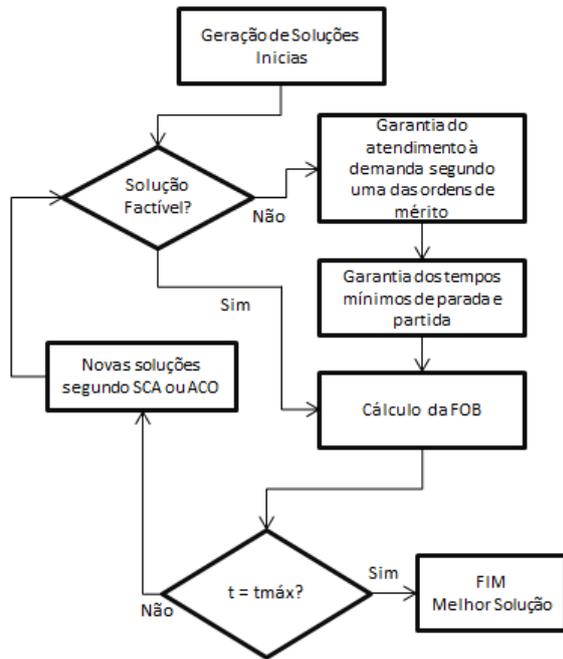


Figura 1. Fluxograma da metodologia proposta

## 4 Resultados

São utilizados para a avaliação da metodologia proposta dois sistemas de geração amplamente difundidos na literatura e apresentados por Kazarlis et al (1996): O primeiro contendo 10 unidades termoeletricas (UTEs) e o segundo com 20 unidades, ambos em um período de estudo de 24 horas.

Para ambos os sistemas em estudo foram feitas variações de dois parâmetros do SCA: (a) 20 soluções e 20 iterações, originando um total de 400 soluções investigadas; (b) 40 soluções e 40 iterações, originando um total de 1600 soluções investigadas. Em todas as simulações foram utilizados os mesmos parâmetros de ajuste do SCA:  $\alpha=2$ ,  $r_2$  entre 0 e  $2\pi$  e  $r_3$  entre 0 e 1, todos obtidos de forma empírica através de simulações, as quais originaram os melhores resultados.

Destaca-se ainda a comparação do SCA com outra técnica de otimização multimodal bem difundida na literatura, o *Ant Colony Optimization* (ACO) (Dorigo and Gambardella, 1997).

### 4.1 Sistema 10 unidades

A Figura 2 mostra a evolução das melhores soluções encontradas para 20 iterações e 20 soluções iniciais onde foram realizados testes com apenas as metaheurísticas ACO e SCA de forma a garantir a factibilidade de forma aleatória e a utilização do método híbrido utilizando as metaheurísticas supracitadas com as OMA e OMB.

Na figura 3 é possível verificar o mesmo estudo com o aumento do número de iterações máximas de 20 para 40 e também da população inicial de 20 para 40.

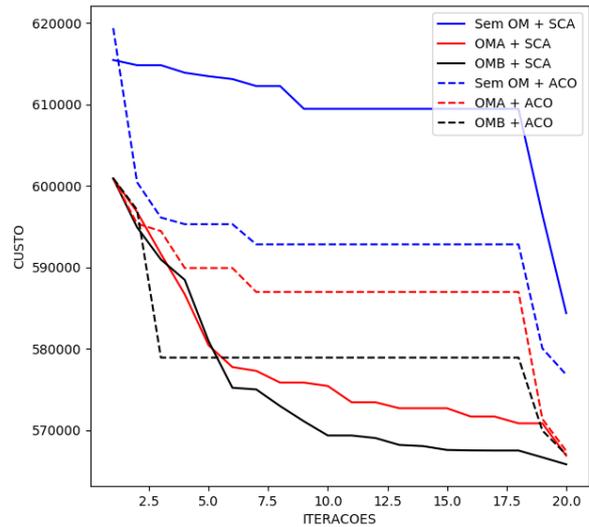


Figura 2. Evolução das melhores soluções sistema 10 UTEs com 20 iterações e 20 soluções iniciais

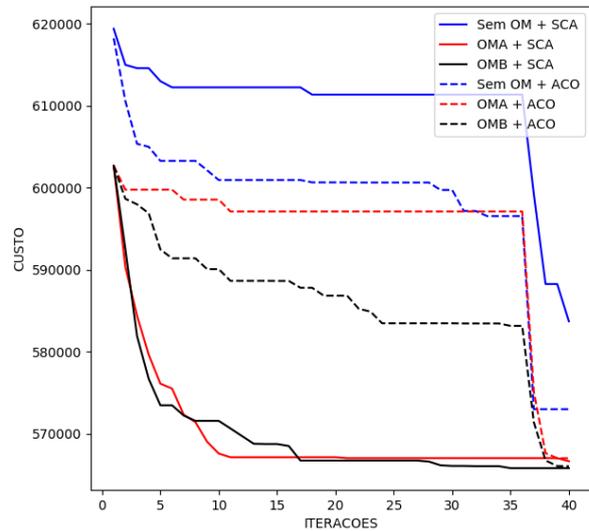


Figura 3. Evolução das melhores soluções sistema 10 UTEs com 20 iterações e 20 soluções iniciais

A evolução das melhores soluções apresentadas nas Figuras 3 e 4 mostram que nos casos com OM o uso do SCA tem um decaimento em direção a melhor solução desde as primeiras iterações, já no uso das OM com o ACO existe uma faixa de estagnação das soluções que só decaem no refinamento proposto através do desligamento das unidades que excederam a demanda. Para as simulações nas quais não foram utilizadas OM os resultados foram ruins tanto para o ACO quanto para o SCA, sendo os piores resultados apresentados neste último. É importante salientar que a queda acentuada ao final das simulações se deve ao desligamento realizado em 90% do valor máximo de iterações.

A Figura 4 mostra a distribuição das soluções para as 20 simulações realizadas onde o número máximo de iterações e soluções iniciais eram respectivamente 20 e 20. Na Figura 5 é possível analisar a distribuição das melhores soluções com o aumento das iterações máximas e soluções máximas cujos valores são 40 e 40 respectivamente.

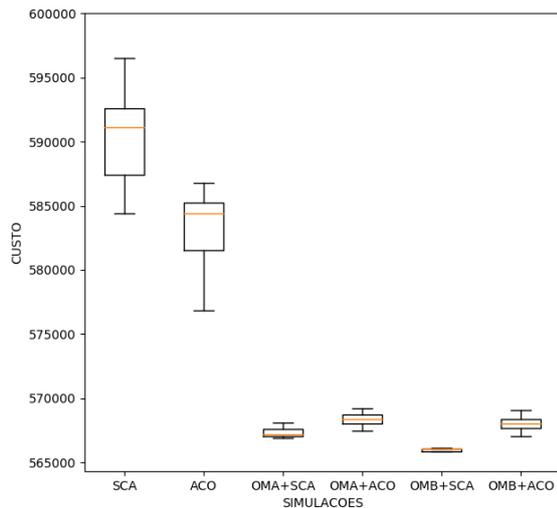


Figura 4. Distribuição das soluções finais para o sistema de 10 UTEs com 20 iterações e 20 soluções iniciais

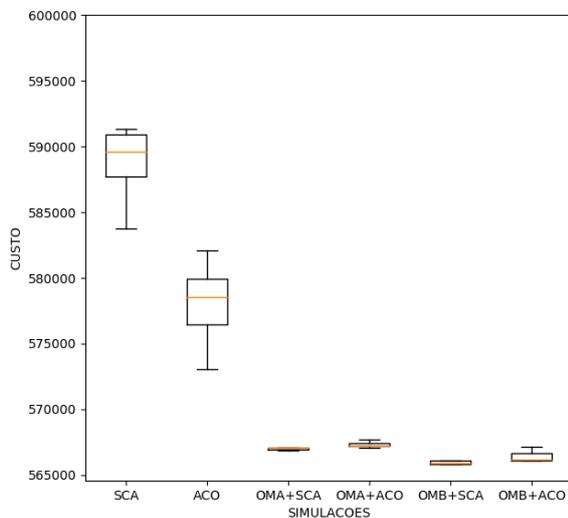


Figura 5. Distribuição das soluções finais para o sistema de 10 UTEs com 40 iterações e 40 soluções iniciais

Nas Figuras 4 e 5 é possível observar que o aumento do número de iterações proporciona uma melhora na qualidade das soluções, bem como uma menor variação das mesmas ao longo das 20 simulações realizadas.

#### 4.2 Sistema 20 unidades/24 horas

De maneira análoga ao sistema visto em 4.1, na Figura 6 é exibida a evolução das melhores soluções encontradas para 20 iterações e 20 soluções iniciais, e na Figura 7 a evolução das melhores soluções com o aumento do número de iterações e soluções para 40.

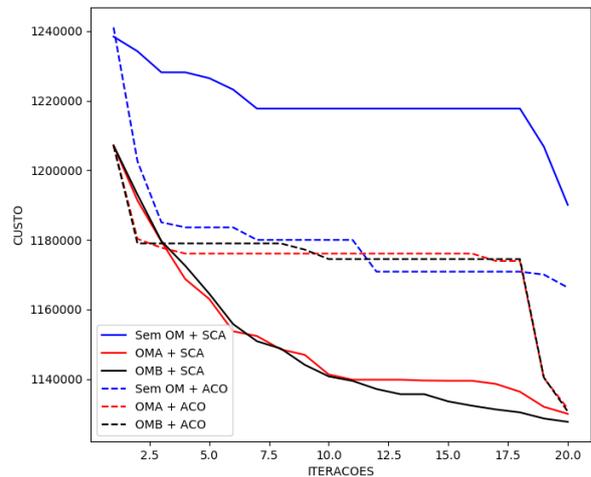


Figura 6. Evolução das melhores soluções sistema 20 UTEs com 20 iterações e 20 soluções iniciais

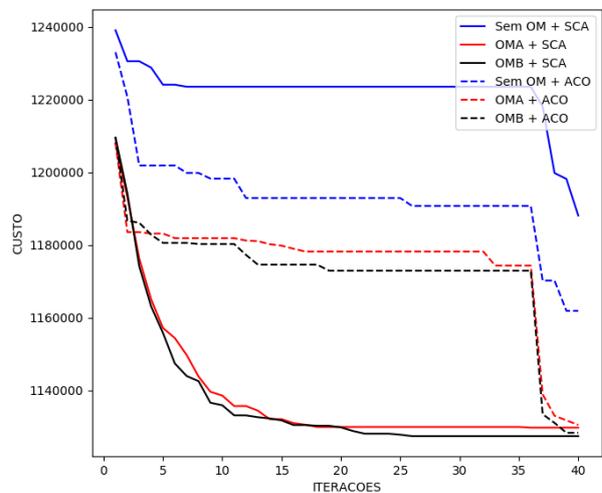


Figura 7. Evolução das melhores soluções ao longo das 20 iterações

Como no caso do sistema anterior o sistema com 20 UTEs demonstra uma estagnação dos resultados até que haja o refinamento das soluções aos 90% do máximo de iterações, isto só não ocorre nos sistemas cuja a metaheurística empregada é o SCA em conjunto com qualquer uma das duas OM.

As distribuições das melhores soluções dos sistemas com 20 UTEs para 20 iterações e 20 soluções iniciais com 40 iterações e 40 soluções iniciais pode ser encontradas nas Figuras 8 e 9 respectivamente.

Ao comparar os sistemas das Figuras 8 e 9 observa-se que o aumento do número de iterações e soluções iniciais permite que a metodologia proposta alcance resultados melhores ao longo das simulações.

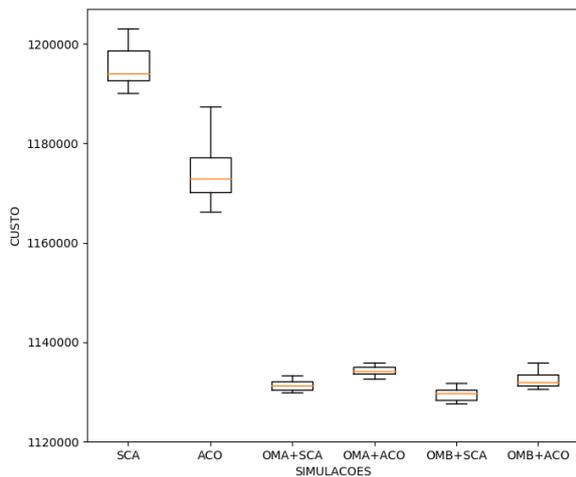


Figura 8. Distribuição das soluções finais para o sistema de 10 UTEs com 20 iterações e 20 soluções iniciais

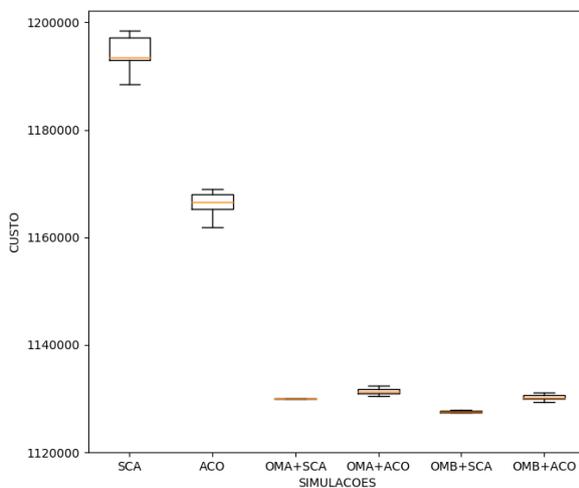


Figura 9. Distribuição das soluções finais para o sistema de 20 UTEs com 40 iterações e 40 soluções iniciais

#### 4.3 Resultados Gerais

A comparação dos melhores valores encontrados nas simulações realizadas na seção anterior pode ser observada na Tabela I para o sistema de 10 UTEs, são ainda incluídos resultados encontrados na literatura, utilizando métodos distintos ao apresentado pela metodologia proposta, são eles os métodos *de Genetic Algorithm* (GA) proposto por Kazarlis et al (1996), *Hybrid Particle Swarm Optimization* (HPSO) proposto por Ting et al (2006), *Dynamic programming based fast computation Hopfield neural network* (DPHNN) proposto por Kumar e Palanisamy (2006) e o método híbrido *Gaussian Harmony Search and Jumping Gene Transposition Algorithm* (GHS-JGT) introduzido por (Kumar et al, 2016) . Os resultados são apresentados em percentual em referência à melhor resposta em destaque.

Tabela I. Comparação do Custo total em \$ para o sistema de 10 UTEs

Metodologia empregada	Diferença % em relação ao melhor – 10 UTEs	
<b>GA</b>	<b>565825 (Melhor)</b>	
<b>GHS-JGT</b>	+0,0005	
<b>DPHNN</b>	+4,0516	
<b>HPSO</b>	+0,0012	
	<b>Config. 20/20</b>	<b>Config. 40/40</b>
<b>SCA</b>	+3,2821	+3,1651
<b>ACO</b>	+1,9465	+1,2716
<b>SCA + OMA</b>	+0,1905	+0,1504
<b>ACO + OMA</b>	+0,2907	+0,214
<b>SCA + OMB</b>	+0,0005	+0,0005
<b>ACO + OMB</b>	+0,2142	+0,0429

É importante salientar que as simulações realizadas em GHS-JGT, HPSO e DPHNN possuem formulação diferente para partida a frio, os autores decidiram manter a formulação proposta por Kazarlis et al (1996). Desta forma, para efeito comparativo foram realizados os cálculos referentes ao custo de partida dos três métodos supracitados e acrescentados ao valor fornecido em suas respectivas matrizes de despacho horário.

Através da análise da Tabela I é possível perceber que a metodologia proposta quando não utiliza de OM traz resultados piores em relação à metodologia combinada a OM, isto fica exemplificado ao analisarmos a melhor resposta apresentada (GA) e a resposta obtida pelo SCA em conjunto com a OMB, que neste caso apresenta uma diferença percentual de 0.0005% (\$565828) tanto para 20 quanto para 40 iterações máximas.

A Tabela II de forma análoga a Tabela I, mostra os resultados das melhores soluções em cada sistema simulado, diferenciando-se por conter os resultados obtidos para 20 UTEs. Nesta tabela é importante salientar que foi comparado apenas o valor encontrado por (GA) visto que os outros métodos (GHS-JGT, HPSO e DPHNN) não disponibilizam a matriz de despacho horário para o sistema de 20 UTEs, tornando impossível o cálculo do custo de partida considerando a formulação de partida quente e frio.

Tabela II - Comparação do Custo total em \$ para o sistema de 20 UTEs

Metodologia empregada	Diferença % em relação ao melhor – 20 UTEs	
<b>GA</b>	<b>1126243 (Melhor)</b>	
	<b>Config. 20/20</b>	<b>Config. 40/40</b>
<b>SCA</b>	+5,6656	+5,5276
<b>ACO</b>	+3,5556	+3,1678
<b>SCA + OMA</b>	+0,3320	+0,3164
<b>ACO + OMA</b>	+0,4626	+0,3831
<b>SCA + OMB</b>	+0,1279	+0,1082
<b>ACO + OMB</b>	+0,3932	+0,1900

Como no sistema de 10 UTEs, a metodologia proposta tem na combinação SCA + OMB a melhor solução e esta diferencia-se do melhor valor encontrado por GA em 0,1082% (\$1127462), novamente o aumento das iterações/soluções iniciais melhora a qualidade das soluções.

Os tempos médio para realização de uma simulação para cada sistema proposto pode ser observado nas Tabelas III e IV onde as configurações tem 10 UTEs e 20 UTEs respectivamente. Foram comparados apenas os tempos computacionais referentes às simulações executadas neste trabalho. As informações computacionais dos sistemas que utilizam GA, GHS-JGT e HPSO não foram levadas em consideração por terem sido realizadas em sistemas computacionais distintos.

Todas as simulações foram realizadas em um computador com processador Intel® Core™ I5 de 2,4Ghz e 8 Gb de memória RAM.

Tabela III. Tempo computacional das simulações em segundos para arranjo de 10 UTEs

Metodologia empregada	Tempo computacional em segundos - 10 UTEs	
	Config. 20/20	Config. 40/40
SCA	116,99	541,58
ACO	105,02	432,04
SCA + OMA	105,15	521,33
ACO + OMA	103,97	451,80
SCA + OMB	116,06	442,28
ACO + OMB	95,19	435,32

Tabela IV. Tempo computacional das simulações em segundos para arranjo de 20 UTEs

Metodologia empregada	Tempo computacional em segundos 20 UTEs	
	Config. 20/20	Config. 40/40
SCA	352,33	1483,68
ACO	308,26	1287,99
SCA + OMA	310,53	1169,64
ACO + OMA	354,28	1272,99
SCA + OMB	306,16	1119,78
ACO + OMB	296,75	1108,36

A análise das Tabelas III e IV possibilita constatar que a diferença no tempo computacional entre as metaheurísticas é relativamente pequena, sendo o ACO na maioria dos casos mais rápido que o SCA. É fácil perceber também que o aumento do número de iterações e soluções iniciais de 20/20 para 40/40 aumenta o tempo computacional exigido nas simulações. No caso de 20 UTEs os tempos também são superiores por se tratar de um sistema com o dobro de unidades térmicas em relação ao sistema composto por 10 UTEs.

## 5 Conclusões

O presente trabalho apresentou a aplicação de uma metodologia híbrida na resolução do problema referente à programação diária da operação de sistemas termoeletrônicos de geração. Os resultados alcançados se mostram satisfatórios, sendo evidente a melhora nas soluções obtidas com a inclusão das informações heurísticas, tais como: (i) menor dispersão das soluções finais obtidas pelas técnicas de otimização multimodais; (ii) obtenção de programações de operação mais econômicas.

Ao comparar as duas metodologias híbridas (com ordens de mérito) o uso do SCA como metaheurística para resolução do problema do despacho econômico se mostrou mais vantajoso em relação à utilização do ACO, tais vantagens são exemplificadas através de uma menor variação das respostas finais encontradas pelo algoritmo além de resultados absolutos menores apesar do pequeno aumento do tempo computacional. As características da metaheurística SCA na busca da melhor solução são propícias à resolução do problema por evitarem ótimos locais, o que pode ser comprovado através da comparação dos resultados obtidos e os encontrados na literatura.

Além disso, pode-se observar que o tempo de processamento com a inclusão da heurística é mínimo quando comparado às simulações que não levaram em consideração estas informações. Este fato é um incentivador à utilização destas heurísticas na resolução de problemas semelhantes ao aqui abordado.

## Agradecimentos

Os autores deste artigo agradecem o apoio da FAPEMIG, CAPES, CNPq, INERGE, Programa de Pós Graduação em Engenharia Elétrica - PPEE da Universidade Federal de Juiz de Fora e do grupo de pesquisa "Otimização Heurística e Bio-inspirada".

## Referências Bibliográficas

- Alam M. S; Hari Kiran B. D. and Kumari M. S. (2016). Priority list and particle swarm optimization based unit commitment of thermal units including renewable uncertainties, 2016 IEEE International Conference on Power System Technology (POWERCON), Wollongong, NSW, p. 1-6.
- Bragin M. A; Luh P. B; Yan J. H and Stern G. A. (2015). Novel exploitation of convex hull invariance for solving unit commitment by using surrogate Lagrangian relaxation and branch-and-cut, Proc. 2015 IEEE Power and Energy Society General Meeting, pp. 1-5.
- Dorigo, M; Gambardella, L. M. (1997). Ant colony system: a cooperative learning approach to the traveling salesman problem. IEEE Transactions on evolutionary computation, v. 1, n. 1, p. 53-66.

- Goldbarg M.C. and Luna H. P. (2000). *Otimização Combinatória e Programação Linear*. Rio de Janeiro: Editora Campus.
- Kazarlis S. A; Bakirtzis A. G. and Petridis V. (1996). A genetic algorithm solution to the unit commitment problem, *IEEE Trans. Power Syst.*, vol. 11, pp. 83-92.
- Kumar S. S; Palanisamy V. (2007) . A dynamic programming based fast computation Hopfield neural network for unit commitment and economic dispatch, *Electric Power System Research*, vol. 77, pp. 917-925.
- Kumar N; Panigrahi B. K; Singh B. (2016). A solution to the ramp rate and prohibited operating zone constrained unit commitment by GHS-JGT evolutionary algorithm, *International Journal of Electrical Power & Energy Systems*, vol. 81, pp. 193-203.
- Li X; Li T; Wei J; Wang G. and Yeh W.-G. (2014). Hydro unit commitment via mixed integer linear programming: A case study of the Three Gorges project China. *IEEE Trans. Power Syst.*, vol. 29, no. 3, pp. 1232-1241.
- Mirjalili S. (2016). SCA: A Sine Cosine Algorithm for solving optimization problems, *Knowledge-Based Systems*, vol. 96, pp. 120-133.
- Momoh J.A. (2005). *Electric Power System Application of Optimization* editora Marcel Dekker, 2005.
- Padhy N. P. (2004). Unit Commitment A Bibliographical Survey, *IEEE Trans. On Power Systems*, Vol. 19, No. 2, pp. 1196-1205.
- Silva Junior I.C.; Carneiro Junior S.; Oliveira E. J.; Pereira J.L.R.; Garcia P. A.N.; Marcato A. L.M. (2008). A Lagrangian Multiplier Based Sensitive Index To Determine The Unit Commitment Of Thermal Units. *International Journal of Electrical Power & Energy Systems*, vol.30, issue 9, issn 0142-0615, pp. 504-510.
- Silva Junior I. C; Nascimento F. R; Oliveira E. J; Marcato A. L. M; Oliveira L. W. and Passos Filho J. A. (2013). Programming of Thermoelectric Generation System Based on Heuristic Composition of Ant Colonies. *International Journal of Electrical Power & Energy Systems*, v.44,p. 134-145.
- Ting T. O; Rao M. V. C, and Loo C. K. (2006). A novel approach for unit commitment problem via an effective hybrid particle swarm optimization, *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 411-418.
- Viana A; Sousa J.P. and Matos M.A. (2003). GRASP with Constraint Oriented Neighborhoods: an application to the Unit Commitment Problem. The fifth Metaheuristic International Conference, Kyoto, Japan, August 25-28.
- Yang H.T; Yang P. C; and Huang C.L. (1996). Evolutionary programming based economic dispatch for units with non-smooth fuel cost functions, *IEEE Trans. Power Syst.*, vol.11, pp.112-118.