

ALOCÇÃO DE UNIDADES GERADORAS TÉRMICAS VIA ALGORITMO GENÉTICO ADAPTATIVO

ROBERTO F. A. MENEZES*, ANDRÉA ARAÚJO SOUSA*

**Programa de Pós-Graduação em Engenharia Elétrica (PROEE)
Departamento de Engenharia Elétrica (DEL)
Universidade Federal de Sergipe (UFS)
Av. Marechal Rondon, s/n, Jardim Rosa Elze, 49100-000
São Cristóvão, Sergipe, Brasil*

Abstract— The growth of the electric energy consumption in the last years has generated the need of the increase in the amount of power sources, making the electricity sector undergo some large changes. This has provided the search for tools that promotes a better efficiency and security to the electrical power systems. A planning problem that is considered important in the daily operation of the power systems is the unit commitment. The main objective of the problem is define the schedule of the units, determining which machines will be online or offline, and which are the operating points. Those units must operate by load variation, respecting the operative and security constraints. This research proposes the resolution of the problem for the short-term planning, taking a set of constraints associated with the thermal generation and the power system. The methodology used involves the utilization of an adaptive genetic algorithm, for the unit commitment problem, and the interior-point method, for DC power flow resolution in economic dispatch problem. The results were obtained through simulations in an IEEE test system.

Keywords— Unit Commitment, Economic Dispatch, Thermal Systems, Genetic Algorithm, Interior-Point Method.

Resumo— O crescimento do consumo de energia elétrica nos últimos anos vem gerando a necessidade de um aumento na quantidade de fontes geradoras, fazendo com que o setor elétrico passe por grandes mudanças. Isso vem proporcionado a busca por ferramentas que ofereçam maior eficiência e segurança aos sistemas elétricos de potência. Um problema de planejamento considerado importante na operação diária dos sistemas elétricos é a alocação das unidades geradoras. O objetivo do problema é definir a programação horária das unidades do sistema, determinando quais máquinas deverão estar ligadas ou desligadas, e quais serão seus respectivos pontos de operação. Essas unidades geradoras devem operar mediante a variação da carga, respeitando restrições operativas e de segurança do sistema. Este trabalho propõe a resolução do problema para o planejamento de curto prazo, levando em consideração uma série de restrições relacionadas a geração térmica e ao sistema elétrico. A metodologia utilizada envolve a utilização de um algoritmo genético adaptativo, para alocação das unidades, e o método de pontos interiores, para a resolução do fluxo de potência ótimo DC no problema do despacho econômico. Os resultados foram obtidos através de simulações em um sistema teste do IEEE.

Palavras-chave— Alocação de Unidades Geradoras, Despacho Econômico, Sistemas Termoeletrônicos, Algoritmo Genético, Método de Pontos Interiores.

1 Introdução

A operação e controle do sistema elétrico mundial está se tornando uma tarefa complexa devido a expansão do sistema, impulsionada pelo aumento da demanda nas últimas décadas. Por conta disso, estudos estão sendo realizados com o propósito de otimizar o uso da energia através de técnicas que promovam maior eficiência e segurança no fornecimento da mesma.

Um problema considerado de extrema importância, na operação em curto prazo, é o que envolve a *Alocação de Unidades Geradoras Térmicas* (AUGT). Nele serão definidas quais as unidades que estarão em funcionamento. Esse problema é hierarquicamente superior ao *Despacho Econômico* (DE), que determina quais serão as potências geradas por cada máquina de forma a minimizar a soma dos custos operacionais, satisfazendo o balanço energético do sistema (Wood and Wollenberg, 2012).

No problema de DE mais simples é utilizado o modelo barra única para representar o sistema

elétrico, desconsiderando o sistema de transmissão. Porém, é possível representar o modelo de forma mais detalhada, levando em consideração esse sistema, e com isso as equações de fluxo de carga das linhas de transmissão. Apesar do modelo barra única ser mais simples, ele pode não atender importantes requisitos operativos do sistema de transmissão, fazendo com que alguns resultados provoquem uma sobrecarga nesse sistema. Embora a sua resolução seja mais complexa e demorada, os modelos que levam em consideração as restrições de capacidade do sistema de transmissão podem representar com um pouco mais de fidelidade a operação do sistema (Wang et al., 1995).

A introdução da restrição de capacidade da linha de transmissão ao problema de DE pode torná-lo um problema de *Fluxo de Potência Ótimo* (FPO), podendo assim ser usado o seu modelo (Sun et al., 1984).

A representação linearizada (DC) do fluxo de potência tem sido adotada nos estudos de DE devido a sua simplicidade e ao grau de precisão sa-

tisfatório. Assim, o modelo do problema de DE pode ser formulado considerando os limites de potências dos geradores e o fluxo de carga das linhas (Carvalho et al., 1988).

Nesse trabalho o problema de DE é resolvido através do *Método de Pontos Interiores* (MPI) com base em (Oliveira and Soares Filho, 2003).

O problema de AUGT é um problema de otimização não-linear, inteira-mista e de grande escala. Nesse problema a solução ótima pode ser encontrada checando todas as combinações possíveis, tornando inviável em alguns sistemas de grande porte. Desta forma, é necessário o uso de algoritmos eficientes para encontrar soluções viáveis.

O *Algoritmo Genético* (AG) proposto nesse trabalho possui característica adaptativa para resolução do problema de AUGT. Esse algoritmo contém operadores genéticos de *cross-over* e mutação modificados, com metodologia anelar, baseado em Pavez-Lazo and Soto-Cartes (2011), e um método de busca local, com intuito de evitar mínimos locais, como descrito em (Sudhakaran and Raj, 2010).

Os resultados foram obtidos através de simulações no software MATLAB, utilizando o sistema teste do IEEE de 30 barras com 9 geradores.

2 Formulação do Problema

O modelo utilizado para descrever o problema de AUGT possui seguintes restrições: balanço de potência, reserva girante, limite de geração das unidades, tempo mínimo de permanência e saída de operação das máquinas, variação da potência de saída (rampa) e capacidade do sistema de transmissão. A função objetivo e todas as restrições são detalhadas a seguir.

2.1 Função Objetivo

A função objetivo do problema de AUGT é modelada como descrito em (1).

$$\text{Min } C_T = \sum_{t=1}^T \sum_{i=1}^{N_G} \{ [a_i P_i^2(t) + b_i P_i(t) + c_i] U_i(t) + [1 - U_i(t-1)] C P_i U_i(t) \} \quad (1)$$

Sendo C_T o o custo de produção total (R\$) para o período de análise; T é o total de horas; N_G é o total de unidades geradoras; $P_i(t)$ é a potência ativa (MW) gerada pela unidade i no instante t ; a_i , b_i e c_i são constantes da unidade i ; $U_i(t)$ representa o estado da unidade i no tempo t , onde 1 identifica a unidade ligada e 0 desligada; $C P_i(t)$ é o custo de partida (R\$) da unidade i no instante t .

Com o objetivo de simplificar o problema, nesse trabalho foi considerado o custo do combustível como sendo 1,00R\$/MBTU.

2.2 Restrições

A solução viável do problema de AUGT deve satisfazer as restrições a seguir:

- Balanço de Potência

$$U_{i,k}(t) P_{i,k}(t) - P_{l,k}(t) - \sum_{m \in \Omega_k} f_{km}(t) = 0 \quad (2)$$

Onde $U_{i,k}(t)$ representa o estado da unidade i localizada na barra k no tempo t ; $P_{i,k}(t)$ é a potência ativa (MW) gerada pela unidade i localizada na barra k no instante t ; $P_{l,k}(t)$ é o valor da demanda (MW) localizada na barra k no instante t ; $f_{km}(t)$ é o fluxo de carga (MW) na linha entre as barras k e m no instante t ; Ω_k é conjunto de de barras vizinhas a barra k .

- Reserva Girante

$$\sum_{i=1}^{N_G} U_i(t) P_i^{Max} \geq \sum_{k=1}^{N_B} P_{l,k}(t) + P_R(t) \quad (3)$$

Onde P_i^{Max} é o limite máximo de geração de potência (MW) da unidade i ; N_B é o número de barras do sistema; $P_R(t)$ é a reserva girante (MW) prevista para o instante t .

- Limite de Geração das Unidades Térmicas

$$P_i^{Min} \leq P_i(t) \leq P_i^{Max} \quad (4)$$

Onde P_i^{Min} é o limite mínimo de geração de potência (MW) da unidade i .

- Tempo Mínimo de Permanência e Saída de Operação das Máquinas

$$\begin{cases} T_i^{on} \geq TML_i \\ T_i^{off} \geq TMD_i \end{cases} \quad (5)$$

Onde T_i^{on} é o tempo (h) que a unidade i está em operação; T_i^{off} é o tempo (h) que a unidade i está fora de operação; TML_i é o tempo mínimo (h) de permanência em operação (h); TMD_i é o tempo mínimo de saída de operação.

- Variação da Potência das Máquinas (Rampa)

$$|P_i(t) - P_i(t-1)| \leq R p_i \quad (6)$$

Onde $R p_i$ é a variação máxima permitida de geração de potência (MW/h) da unidade i .

- Capacidade do Sistema de Transmissão

$$f_{km}^{Min} \leq f_{km}(t) \leq f_{km}^{Max} \quad (7)$$

Onde f_{km}^{Min} é a capacidade mínima (MW) da linha de transmissão que liga a barra k e m ; f_{km}^{Max} é a capacidade máxima (MW) da linha de transmissão que liga a barra k e m .




Figura 1: Codificação de um indivíduo do AG aplicado ao problema de AUGT.

3 Metodologia Proposta

A metodologia proposta para resolução do problema de AUGT é a de usar um algoritmo genético adaptativo para definir quais serão as máquinas que estarão em operação e, posteriormente, realizar o DE através do MPI para encontrar o ponto de operação de cada máquina. A seguir é detalhado o processo.

3.1 Algoritmo Genético

Os AGs são técnicas de busca inspiradas na genética e em processos naturais de seleção de indivíduos que competem no mesmo ambiente. Sendo que os indivíduos mais aptos tem uma maior probabilidade de transmitir sua informação genética para os seus descendentes (Holland, 1975).

3.2 Codificação e Inicialização

Os indivíduos do AG criado foram codificados como matrizes de dimensão igual ao número de geradores pelo período de análise (em horas). Essas matrizes são preenchidas com o estado de cada unidade, sendo representado por 0 quando a unidade estiver desligada e 1 quando a mesma estiver ligada. Os indivíduos iniciais do problema são criados randomicamente, formando assim a população inicial de tamanho T_{pop} (Sheblé and Maifeld, 1994).

A Figura 1 mostra um exemplo de indivíduo codificado para um problema que envolve 4 unidades geradoras para um período de análise de 8 horas.

3.3 Avaliação

O processo de avaliação do indivíduo leva em consideração se ele está obedecendo as restrições do problema. Caso isso ocorra, o indivíduo será avaliado como descrito em (8).

$$fitness = C_T / C_{Max} \quad (8)$$

Onde C_{Max} é o custo máximo do problema. Esse valor é adquirido realizando o DE com todas as

unidades ligadas a potência máxima em todo o período analisado. Assim é possível garantir que haverá uma normalização do valor do *fitness*.

O valor de C_T é calculado como mostrado em (1). Para isso, o cálculo das potências que serão fornecidas por cada unidade geradora é realizado através do MPI Primal-Dual Predictor-Corretor. Esse método é aplicado em todas as máquinas que estejam em operação para cada hora analisada. O MPI utilizado é descrito detalhadamente em (Oliveira and Soares Filho, 2003).

Caso as restrições não sejam obedecidas, a avaliação será feita com base na quantidade de restrições que aquele indivíduo conseguiu obedecer. Quanto maior o número de restrições obedecidas, melhor será sua avaliação do indivíduo. Dessa forma, a medida que as restrições forem sendo obedecidas a avaliação do indivíduo fica descrita como em (9).

$$fitness = \frac{(C_{Max} - 0.001N_r C_{Max})}{C_{Max}} \quad (9)$$

Onde N_r é o número de restrições que foram obedecidas.

3.4 Seleção e Elitismo

A proposta de seleção nos AGs é dar mais chances de reprodução aos indivíduos da população que tenham as melhores avaliações, ou seja, aos indivíduos mais aptos. Essa técnica é utilizada para que a próxima geração possa ser formada.

A técnica de seleção utilizada no trabalho foi a da *Roleta*. Nessa técnica os espaços da roleta possuem tamanho proporcional a avaliação do indivíduo. Indivíduos que possuem as melhores avaliações ocuparão um lugar maior na roleta, da mesma forma que indivíduos com avaliação ruim ocuparão lugares menores na roleta (Linden, 2008).

Paralelamente foi aplicada a técnica de *Elitismo* para garantir que as características de alguns indivíduos que tenham boa avaliação se propague nas próximas gerações. Essa técnica garante que os melhores indivíduos sejam mantidos na população com o passar das gerações, sendo substituídos somente no caso de aparecerem indivíduos melhores no decorrer do processo. Dessa forma, a nova população gerada será formada uma parte pelo grupo elite, de tamanho T_{ge} , e a outra parte pelos indivíduos que foram selecionados e passaram pelos processos de *cross-over* e *mutação* (Linden, 2008).

3.5 Cross-Over e Mutação

Os operadores de *Cross-Over* e *Mutação* tem a função de promover a exploração de novas regiões no espaço de busca. O *cross-over* contribui fortemente para a igualdade entre os indivíduos. Já o operador de *mutação* é fundamental para garantir




Figura 2: Semi-anel para o *cross-over* anelar, adaptado de Pavez-Lazo and Soto-Cartes (2011).

a diversidade genética na população com o passar das gerações (Linden, 2008).

No problema de AUGT as matrizes de alocação têm grande sensibilidade principalmente devido a restrição de tempo mínimo de permanência e saída de operação das máquinas. Para sistemas onde o período de análise são maiores que 12h foi constatado que as técnicas clássicas de *cross-over* e mutação utilizadas não são viáveis pelo fato do processo demorar para sair de mínimos locais ou, em alguns casos, não conseguir sair. Para reverter esse problema, foi aplicada a técnica anelar proposta em Pavez-Lazo and Soto-Cartes (2011) para esses operadores.

O *cross-over* é realizado a partir de uma probabilidade de ocorrência P_{cross} onde, primeiramente, são escolhidas, de forma randômica, as unidades m e n de cada um dos indivíduos selecionados pela roleta. As duas linhas escolhidas contendo os estados operativos de cada uma das máquinas são transformadas em um anel e logo depois são escolhidos os pontos de corte (P_c) e o tamanho do semi-anel (T_{sa}), ambos de forma randômica. Por fim, o cruzamento pode ser realizado. Essa técnica é ilustrada na Figura 2, onde é criado um semi-anel com P_c sendo 22 para a unidade m e 18 para a unidade n . Já o T_{sa} escolhido tem o total de 9h do período de operação.

Embora em Pavez-Lazo and Soto-Cartes (2011) não considere o uso da mesma técnica para o operador de mutação, a idéia foi aplicada e foi constatada uma melhoria considerável em relação a mutação clássica de um ponto. De forma semelhante ao que foi feito no operador de *cross-over*, a mutação é realizada a partir de uma probabilidade de ocorrência P_{mut} . Na metodologia proposta, é




Figura 3: Nova alocação da unidade m após a mutação anelar, adaptado de Pavez-Lazo and Soto-Cartes (2011).

criado um anel com uma linha contendo os estados operativos de uma unidade m , escolhida de forma randômica. Logo depois é escolhido o ponto de corte (P_c) e o tamanho do semi-anel (T_{sa}), ambos de forma randômica. Esse semi-anel será o pedaço que será alterado. Essa alteração é feita modificando o estado da primeira posição do semi-anel e todas as outras posições com o mesmo estado da primeira posição. Essa alteração seria análoga a uma “contaminação” daquele pedaço do anel. Tal metodologia adotada tem grande força devido a sensibilidade da matriz, como descrita anteriormente. A modificação dos estados das posições no semi-anel, de forma semelhante ao que é feito na metodologia clássica, não trouxe bons resultados, por isso a escolha dessa metodologia de “contaminação”.

A Figura 3 mostra um exemplo do operador de mutação criado, aplicado a uma de unidade que tem o período de operação de 8h.

3.6 Adaptabilidade

O AG oferece a opção de adaptar os parâmetros de probabilidade de realização do *cross-over* e mutação de acordo com o progresso do algoritmo. Nesse trabalho foi implementado um processo baseado nas observações dos experimentos, onde foi constatada a importância do operador de mutação em alguns momentos. Por conta disso, foi utilizada uma técnica de probabilidade de mutação variável, de acordo com o *Grau de Homogeneidade da população* (GHP).

O GHP mede o quanto os indivíduos da população são semelhantes. A verificação do mesmo é feita com uma frequência de gerações, ou seja, a cada $freq_h$ gerações é analisado se o GHP ultrapassou o limite estabelecido de homogeneidade Lim_h . Caso isso ocorra, a probabilidade de ocorrência do operador de mutação passa de um valor mínimo inicial $P_{mut,Min}$ para um valor máximo $P_{mut,Max}$ que irá decaindo a uma taxa Tx_{mut} , a medida que as gerações vão avançando, até voltar ao valor mínimo inicial.

Essa estratégia promove maior diversidade a população além de evitar que o processo possa fi-




Figura 4: Curva de evolu  o dos melhores indiv duos.

car preso em um m nimo local.

3.7 Busca local

A medida que as gera  es v o avan ando, e a busca por melhores solu   es vai ficando cada vez mais dif cil,   preciso introduzir alguma ferramenta que auxilie nessa busca. Os AGs quando auxiliados por alguma t cnica de busca local   caracterizado como *Mem tico*.

A t cnica de busca local incorporada ao AG criado   baseada em Sudhakaran and Raj (2010). Nesse trabalho s o propostos dois tipos de busca local denominados *1-OPT* e *2-OPT* que s o aplicadas   melhor solu   o encontrada. A busca do tipo *1-OPT* modifica o estado de cada uma das unidades para todo o per odo de opera  o analisado. A busca do tipo *2-OPT* modifica, primeiramente, o estado de duas unidades para cada hora, e posteriormente a busca continua modificando o estado de cada unidade para duas horas diferentes.

Nessa t cnica, a avalia  o do indiv duo deve ser feita a cada modifica  o realizada. A busca s o ir  parar caso encontre um indiv duo melhor que o da  ltima gera  o ou caso n o ache nenhum indiv duo melhor.

A busca local s o   requisitada no AG quando n o h  mudan a do melhor indiv duo encontrado ap s um n mero $freq_{bl}$ de gera  es.

4 Resultados

O AG proposto nesse trabalho foi testado em um sistema composto por 9 unidades t rmicas, com per odo de an lise de opera  o de 24h e ligadas ao sistema do IEEE de 30 barras (Ma

et al., 1997; da Silva Junior, 2008). A simula  o foi realizada no software MATLAB em uma plataforma computacional com processador Intel Core i3-3217U, CPU 1.80 GHz, mem ria de 4 GB com sistema operacional de 64 bits.

Os par metros usados no AG proposto podem ser vistos na Tabela 1. Esses valores foram sintonizados com base em testes realizados, por m,   preciso aprofundar os estudos para melhorar essa sintonia e o AG possa ser aperfei oado.

Os crit rios de parada considerados no AG proposto foram o n mero m ximo de gera  es (G_{Max}) ou quando a busca local n o consegue achar nenhuma solu   o melhor que a  ltima encontrada.

A Figura 4 mostra a curva de evolu  o dos melhores indiv duos encontrados no decorrer das gera  es em tr s metodologias diferentes. A primeira utiliza o AG cl ssico, a segunda utiliza o AG com os operadores gen ticos modificados, e a terceira utiliza o AG adaptativo proposto, com os operadores gen ticos modificados e a busca local. Cada uma das metodologias foram simuladas 10 vezes, sendo a melhor solu   o encontrada a de R\$146.925,25, decorrente do AG proposto, com 880 gera  es necess rias para chegar a esse resultado.

  poss vel observar que o fato de a popula  o inicial ser gerada de forma rand mica faz com que os melhores indiv duos iniciais n o obede am as restri   es estabelecidas e comecem com valores de *fitness* alto. A partir do momento que   encontrado um indiv duo que obede a todas as restri   es estabelecidas, o valor do melhor *fitness* sofre uma queda abrupta. Al m disso, as curvas mostram como o AG tem dificuldade de encon-

Tabela 1: Parâmetros do AG

T_{pop}	G_{Max}	P_{cross}	$P_{mut,Min}$	$P_{mut,Max}$	Tx_{mut}	T_{ge}	Lim_h	$freq_h$	$freq_{bl}$
100	1000	70%	5%	80%	10%	5	80%	20	100

trar novas soluções a medida que as gerações vão avançando, sendo a busca local de extrema importância.

Ainda analisando os resultados obtidos através do gráfico da Figura 4 é possível observar que o AG adaptativo proposto consegue ter uma resposta melhor em relação as outras duas metodologias. O AG clássico não consegue encontrar solução que obedeça as restrições estabelecidas e o AG com operadores genéticos modificados encontra dificuldade na busca por melhores soluções a medida que as gerações vão avançando.

A alocação encontrada para o sistema analisado através do AG adaptativo pode ser visto na Figura 5 e o DE horário das unidades geradoras, contendo as potências ativas que serão entregues ao sistema, é exibido na Tabela 2. Ambos os resultados encontrados respeitam as restrições, confirmando sua factibilidade.

Cabe destacar que esse sistema teste quando utilizado em Ma et al. (1997) apresentam resultados que não obedecem as restrições de balanço de potência (2). Da mesma forma, quando o mesmo sistema é utilizado em da Silva Junior (2008), a restrição de rampa (6) é desconsiderada.

5 Conclusões

A dificuldade de resolução do problema AUGT é evidenciada a medida que o número de restrições vão sendo adicionadas ao problema, proporcionando um aumento nas variáveis envolvidas e, consequentemente, na dimensão do problema.

O AG sugerido conseguiu converter de forma satisfatória esse problema, mostrando efetividade nos experimentos simulados. Porém, é importante observar que, nesse trabalho, os parâmetros do AG não foram sintonizados. Esse fator pode ser abordado em trabalhos futuros, junto com um aperfeiçoamento da inicialização da população inicial do AG e novas técnicas de busca local, com o objetivo de melhorar ainda mais o método.

Em suma, o AG modificado que foi sugerido nesse trabalho mostrou potencial para resolver problemas complexos de AUGT, apresentando boa convergência. Isso mostra que o conhecimento do problema e da ferramenta usada para resolvê-lo pode incorporar novas propostas, trazendo mais eficiência na busca por melhores soluções.

Agradecimentos

Os autores agradecem à Fundação de Apoio à Pesquisa e Inovação Tecnológica do Estado de Ser-

gipe, pelo apoio financeiro; e à UFS, ao DEL e ao PROEE, pelo apoio de infraestrutura física.

Referências

- Carvalho, M. F., Soares, S. and Ohishi, T. (1988). Optimal active power dispatch by network flow approach, *Power Systems, IEEE Transactions on* **3**(4): 1640–1647.
- da Silva Junior, I. C. (2008). *Planejamento da Operação de Sistemas Termoeletrônicos utilizando Análise de Sensibilidade Associada a Procedimentos Heurísticos*, PhD thesis, Universidade Federal do Rio de Janeiro.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence.*, U Michigan Press.
- Linden, R. (2008). *Algoritmos genéticos (2a edição)*, Brasport.
- Ma, H., Shahidehpour, S. and Marwali, M. (1997). Transmission constrained unit commitment based on benders decomposition, *American Control Conference, 1997. Proceedings of the 1997*, Vol. 4, IEEE, pp. 2263–2267.
- Oliveira, A. R. and Soares Filho, S. (2003). Métodos de pontos interiores para problema de fluxo de potência ótimo dc, *Sba: Controle & Automação Sociedade Brasileira de Automática* **14**(3): 278–284.
- Pavez-Lazo, B. and Soto-Cartes, J. (2011). A deterministic annular crossover genetic algorithm optimisation for the unit commitment problem, *Expert Systems with Applications* **38**(6): 6523–6529.
- Sheblé, G. B. and Maifeld, T. T. (1994). Unit commitment by genetic algorithm and expert system, *Electric Power Systems Research* **30**(2): 115–121.
- Sudhakaran, M. and Raj, P. (2010). Integrating genetic algorithms and tabu search for unit commitment problem, *International Journal of Engineering, Science and Technology* **2**(1): 57–69.
- Sun, D. I., Ashley, B., Brewer, B., Hughes, A. and Tinney, W. F. (1984). Optimal power flow by newton approach, *power apparatus and systems, ieee transactions on* (10): 2864–2880.




Figura 5: Melhor alocação encontrada.

Tabela 2: DE horário das unidades geradoeas.

Hora	1	2	3	4	5	6	7	8
Unidade 1	118,26	107,71	101,04	93,99	129,00	129,00	104,37	118,12
Unidade 2	87,02	80,16	75,82	71,23	0,00	0,00	0,00	0,00
Unidade 3	75,60	70,47	66,94	63,22	76,00	76,00	68,70	75,84
Unidade 4	74,12	68,66	65,20	61,56	76,00	76,00	66,93	74,04
Unidade 5	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 6	0,00	0,00	0,00	0,00	0,00	0,00	50,00	50,00
Unidade 7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 9	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Hora	9	10	11	12	13	14	15	16
Unidade 1	96,96	114,15	118,74	121,29	118,74	114,15	112,19	112,19
Unidade 2	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 3	64,79	73,87	75,90	76,39	75,90	73,87	72,84	72,84
Unidade 4	63,10	71,99	74,36	76,18	74,36	71,99	70,97	70,97
Unidade 5	89,15	90,00	90,00	90,00	90,00	90,00	90,00	90,00
Unidade 6	50,00	50,00	50,00	50,15	50,00	50,00	50,00	50,00
Unidade 7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 9	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Hora	17	18	19	20	21	22	23	24
Unidade 1	121,29	122,97	120,44	116,61	130,82	124,76	112,19	126,00
Unidade 2	0,00	90,08	88,43	85,95	95,18	91,24	0,00	0,00
Unidade 3	76,39	75,98	75,88	75,18	76,00	76,00	72,84	76,00
Unidade 4	76,18	75,96	75,24	73,26	76,00	76,00	70,97	76,00
Unidade 5	90,00	90,00	90,00	90,00	0,00	0,00	90,00	90,00
Unidade 6	50,15	0,00	0,00	0,00	50,00	50,00	50,00	0,00
Unidade 7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 8	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Unidade 9	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Wang, S., Shahidehpour, S., Kirschen, D., Mokhtari, S. and Irisarri, G. (1995). Short-term generation scheduling with transmission and environmental constraints using an augmented lagrangian relaxation, *Power Systems, IEEE Transactions on* **10**(3): 1294–1301.

Wood, A. J. and Wollenberg, B. F. (2012). *Power*

generation, operation, and control, John Wiley & Sons.