

Aplicação de Algoritmo Genético na Otimização da Operação de Unidades Termoelétricas a Ciclo Combinado

Sandoval Carneiro Jr, Ivo Chaves da Silva Jr, André L.M. Marcato, José Luiz R. Pereira,
Paulo A.N.Garcia, Paulo Maisonnave e Gilvan Rodrigues

Resumo - Este trabalho apresenta os resultados alcançados em projeto executado pela UFRJ/UFJF para a CGTF, dentro do Programa de P&D do Setor Elétrico Brasileiro coordenado pela ANEEL no ciclo 2004/2005 código 2934-009/2005 financiado pela CGTF. O projeto apresenta a aplicação de uma das técnicas de inteligência artificial denominada de Algoritmo Genético (AG) na resolução do problema referente à operação de unidades termoelétricas (UTE) de geração a ciclo combinado. Baseada na teoria evolutiva de Charles Darwin, o AG reproduz o comportamento evolutivo existente na natureza com o objetivo de encontrar, entre as inúmeras condições possíveis de operação e manutenção, a solução que minimize o custo total de operação da termoelétrica, solução esta denominada de ótimo global. Para tanto, o AG leva em consideração as restrições operacionais da UTE e os custos associados ao gás natural, a emissão de efluentes, horas de operação, entre outros. Os resultados obtidos apontam para uma satisfatória eficiência da metodologia utilizada.

Palavras-chave—Algoritmo Genético, Otimização da Operação, Termoelétricas de Ciclo Combinado.

I. INTRODUÇÃO

Devido à desregulamentação do setor elétrico brasileiro o número de usinas termoelétricas de ciclo combinado conectadas ao sistema aumentou de forma significativa. Este fato associado à crescente demanda cria a expectativa de aumento de investimentos neste setor.

A natureza operativa destes empreendimentos tem peculiaridades que exigem técnicas apuradas para alocar de maneira adequada os montantes de geração no tempo e entre as unidades geradoras, considerando as diversas restrições inerentes ao processo de geração termoelétrica a ciclo combinado [1]. As variáveis que compõem o custo total de produção de energia, tais como, custo de combustível, custo de emissão de efluentes, custo de água, custo referente às horas de operação, custo de parada e partida das turbinas a gás e o custo com recursos humanos, necessitam ser representadas no modelo.

Por outro lado, além das variáveis operativas, devem ser consideradas as variáveis relacionadas ao mercado, tais como, contratos bilaterais e as flutuações do câmbio. Desta forma, o estudo e o desenvolvimento de ferramentas que auxiliem na tomada de decisão é um campo relevante para os agentes geradores [2].

Matematicamente o problema apresenta as seguintes dificuldades: (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 operação, acarretando elevado tempo computacional; (iii) Natureza dinâmica do processo de decisão, que se por um lado limita as opções de decisão, por outro ocasiona antagonismo em relação ao despacho. Diante deste quadro, a utilização de um algoritmo genético para a resolução do problema torna-se uma opção atrativa [3].

Os algoritmos genéticos (AG's) são uma família de modelos computacionais inspirados na evolução das espécies, que incorporam uma solução potencial para um problema específico numa estrutura semelhante à de um cromossomo e aplicam operadores de seleção e "crossover" a essas estruturas de forma a preservar informações críticas relativas à solução do problema. Normalmente os AG's são vistos como otimizadores de funções, embora a quantidade de problemas para o qual os AG's se aplicam seja bastante abrangente.

Entre as principais vantagens para a utilização do Algoritmo Genético (AG) para o problema em questão pode-se citar a simplificação que o AG permite na formulação de problemas combinatoriais [4]. Além, do paralelismo implícito decorrente da avaliação independente de cada indivíduo, ou seja, pode-se avaliar a viabilidade de um conjunto de parâmetros para a solução do problema de otimização em questão [5].

O objetivo do problema de otimização é definir entre as inúmeras configurações de operação (dias de operação e consumo mensal de gás natural) qual a mais econômica de acordo com os seguintes parâmetros: (i) a quantidade de Gás Natural (GN) disponível; (ii) período em análise; (iii); (iv) consumo de água; (v) emissão de efluentes; (vi) contratos de fornecimento de gás natural. O trabalho aqui proposto é referente ao desenvolvimento de uma ferramenta computacional baseada em um algoritmo genético [6], visando a otimização da operação da unidade térmica de ciclo combinado, levando em consideração as variáveis acima mencionadas e

os custos associados.

II. FORMULAÇÃO DO PROBLEMA

O problema de otimização acima descrito pode ser formulado da seguinte forma:

$$\text{Min} \sum_{i=1}^{\text{meses}} (A \times (Vc_i + Va) + (B + C) \times Pg_i + D \times h_i + E + F) \quad (1)$$

$$\sum_{i=1}^{\text{meses}} (Vc_i^{UTE} + Va^{UTE}) = VC \quad (2)$$

$$\sum_{i=1}^{12} (Vc_i^{UTE} + Va^{UTE}) \geq 0,7 \times TAGN \quad (3)$$

$$Vc_i^{UTE} + Va^{UTE} \geq 0,56 \times TMGN \quad (4)$$

$$V_{\min} \leq Vc^{UTE} \leq V_{\max} \quad (5)$$

onde:

- i Mês de operação;
- A Custo do gás natural (R\$/m³);
- B Custo referente à emissão de efluentes em função da energia produzida (R\$/MWh);
- C Custo referente ao consumo de água em função da energia produzida (R\$/MWh) pela UTE;
- D Custo referente às horas de operação e manutenção (R\$/HOM) da UTE;
- E Custo fixo da UTE (R\$);
- F Custo referente às paradas e partidas das turbinas (R\$) a gás natural;
- Pg_i Potência média gerada pela UTE no mês i ;
- h_i Horas de operação da UTE no mês i ;
- Va^{UTE} Volume armazenado de gás natural (m³) pela UTE;
- Vc_i^{UTE} Volume consumido de gás natural (m³) pela UTE no mês i ;
- VC Volume disponível de gás natural (m³) para todo o período em análise (meta de consumo);
- V_{\min} Volume mínimo (m³) de consumo de gás natural pela UTE;
- V_{\max} Volume máximo (m³) de consumo de gás na-

tural pela UTE;

$TAGN$ Consumo máximo anual de gás natural pela UTE;

$TMGN$ Consumo máximo mensal de gás natural pela UTE.

A equação (1) é referente à Função Objetivo (FOB), ou seja, é a função composta por todos os custos que envolvem a operação da unidade termoeletrica de geração. A equação (2) corresponde à equação de balanço de gás natural. As inequações (3) e (4) são as restrições de contrato “take-or-pay” referente à aquisição de gás natural (70% anual e 56% mensal). A inequação (5) corresponde ao volume máximo e mínimo de consumo de gás natural da UTE.

III. ALGORITMO GENÉTICO

Os algoritmos genéticos pertencem a uma classe de algoritmos chamados de inteligência artificial, os quais reproduzem fenômenos observados na natureza para a resolução de problemas de otimização. O algoritmo genético utiliza a idéia da teoria da evolução das espécies, onde somente os indivíduos mais adaptados ao meio sobrevivem e assim, estão aptos a reproduzir e transmitir suas características aos descendentes [6-7-8]

Este tipo de algoritmo resolve problemas complexos (com muitas variáveis, funções descontínuas, derivadas complicadas, etc.), por se tratar de um método probabilístico. É um algoritmo que não impõe muitas limitações em relação à busca da solução ótima, sendo sua única referência o valor da função de aptidão ou função objetivo.

O algoritmo genético é iniciado com uma população aleatória ou não, respeitando alguns parâmetros como os limites das variáveis e a discretização das mesmas. O tamanho da população é fixa e deve ser tal que cubra o espaço de busca de maneira uniforme para não prejudicar o desempenho do mecanismo de otimização.

Com a população inicial gerada, calcula-se, através de uma função denominada função objetivo, o valor de aptidão de cada um dos indivíduos gerados e aplicam-se aos mesmos os operadores genéticos.

O primeiro operador genético é o de seleção. A seleção tem como objetivo determinar os indivíduos mais aptos à reprodução. O número de indivíduos selecionados é consequência de um parâmetro fixo denominado taxa de cruzamento.

Depois dos indivíduos serem selecionados, aplica-se o operador de cruzamento para a formação da nova população.

Por último aplica-se o operador de mutação em determinados indivíduos da nova população cujo número é dado pela taxa de mutação, também fixa.

Com a nova população gerada, são calculados os novos valores de aptidão para os novos indivíduos e assim se repete o processo até atingir a convergência do processo. Convergência esta, que será apresentada posteriormente. A solução final corresponde ao indivíduo que apresentar o melhor valor de aptidão entre todas as gerações.

A seguir serão apresentadas algumas características do algoritmo genético utilizado.

III.1 Representação do Indivíduo

Os algoritmos genéticos trabalham com os indivíduos codificados em uma estrutura cromossômica ou cadeia de caracteres, sendo esta uma de suas características. Cada cromossomo representa uma variável na formação do indivíduo. A codificação é necessária para a aplicação dos operadores genéticos. Atualmente, existem diversos tipos de codificação e a escolha do mesmo, vai depender do tipo de problema a ser utilizado.

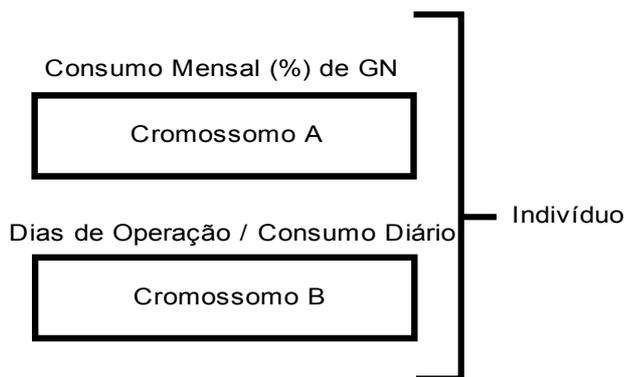


Figura 1. Representação de um indivíduo.

Neste trabalho utilizou-se a codificação decimal, onde o indivíduo é representado por duas cadeias de cromossomos: (i) Cromossomos tipo A - trazendo informações do percentual mensal de gás natural consumido e/ou armazenado; (ii) Cromossomos tipo B - trazendo informações do número de dias de operação da UTE e o consumido diário de gás natural pela UTE. A Figura 1 ilustra a representação de um indivíduo formado apenas por um único cromossomo do tipo A e do tipo B.

III.2 Parâmetros Genéticos

Alguns parâmetros influenciam diretamente no desempenho e até mesmo na convergência dos AGs. Dentre os diversos tipos de parâmetros, tem-se:

- (i) Tamanho da população;

- (ii) Taxa de cruzamento;
- (iii) Taxa de Mutação;
- (iv) Critério de Convergência.

A seguir serão descritas as principais características de cada parâmetro para uma melhor compreensão do algoritmo genético utilizado.

III.2.1 Tamanho da População

O tamanho da população influi diretamente no desempenho e eficiência do AG. Para populações muito pequenas, o algoritmo não abrange um espaço de busca satisfatório para a convergência do algoritmo e em consequência deste fato pode resultar em convergência prematura (solução de baixa qualidade). Para populações muito grandes, o espaço de busca fica muito bem representado no domínio do problema (solução de excelente qualidade), mas em compensação o algoritmo necessita de um elevado tempo de processamento. Portanto, o ajuste deste parâmetro é realizado por um operador com bastante experiência para que o algoritmo tenha um funcionamento adequado.

III.2.2 Taxa de Cruzamento

Este parâmetro indica quantos indivíduos da população irão reproduzir. Com uma taxa de cruzamento muito baixa, o algoritmo se torna pouco eficiente, pois existirá pouca diversidade da população a cada geração. Para uma taxa de cruzamento alta, a população poderá ter uma perda no seu material genético, já que quase toda a população será substituída pelos seus descendentes.

III.2.3 Taxa de Mutação

Este parâmetro indica a probabilidade de cada um dos indivíduos que compõe a população de sofrer mutação. Com uma taxa de mutação muito baixa, o algoritmo pode ficar estagnado a um determinado valor, não ótimo. Uma taxa de mutação alta faz com que o algoritmo fique muito aleatório, de modo que uma boa solução pode ser perdida durante o processo.

III.2.4 Critério de Convergência

A convergência é um parâmetro que indica quando o algoritmo chegou a uma solução próxima do ótimo global. Basicamente, existem três tipos de critério de convergência. O primeiro é designado pelo número máximo de gerações. Neste critério, o algoritmo evolui até um determinado número fixo de gerações. No segundo critério, são calculados, a cada geração, a média e o maior/menor, dependendo da aplicação, valor da função aptidão na população e se a diferença entre eles for menor que uma determinada tolerância, cujo valor deverá ser próximo de zero, o algoritmo convergiu, chegando assim em uma solução satisfatória. Por último, é

determinado um tempo fixo de parada, ou seja, este converge quando o tempo corrente se iguala ao tempo prefixado. No presente trabalho, através de testes, verificou-se que a convergência pelo número máximo de gerações mostrou-se satisfatória.

III.3 Operadores Genéticos

Os operadores genéticos são responsáveis pelo processo de otimização, o qual compreende a seleção e diversificação da espécie durante as várias gerações. Eles fazem com que os indivíduos mais aptos tenham uma maior probabilidade de cruzamento e desta forma conservem suas características de adaptação para seus descendentes, em consequência, indivíduos com baixa adaptabilidade se perdem durante as gerações. Esta diversificação faz com que os indivíduos se adaptem melhor ao seu meio e gerem uma população com valores de aptidão na maioria das vezes ótimos. Basicamente os operadores genéticos são divididos em três categorias, sendo estas descritas abaixo: (a) Seleção; (b) Cruzamento; (c) Mutação.

III.3.1 Operador de Seleção

O operador de seleção tem como objetivo selecionar os indivíduos mais aptos (valores baixos da função aptidão) ao seu meio ambiente para sofrer a ação dos operadores de cruzamento e mutação e conseqüentemente gerar uma população mais adaptada ao seu nicho ecológico. Para tanto, considerou-se um círculo dividido em “n” regiões (tamanho da população), onde a área de cada região é proporcional à aptidão do indivíduo. Sobre este círculo, coloca-se uma "roleta". Após um giro da roleta a posição dos cursores indica os indivíduos selecionados. Os indivíduos cujas regiões possuem maior área (no caso, menor valor da FOB) terão maior probabilidade de serem selecionados.

III.3.2 Operador de Cruzamento

O operador de cruzamento tem como objetivo realizar a troca do material genético dos progenitores escolhidos pelo operador de seleção durante o cruzamento. Seus descendentes herdarão parte das características de um progenitor e parte do outro. As características dos progenitores mais adaptados serão conservadas de geração em geração pelos seus descendentes, fazendo com que estes se adaptem melhor ao meio em que vive. Este operador é realizado em um número fixo de indivíduos regidos pela taxa de cruzamento adotada. Para tanto, utilizou-se o cruzamento em dois pontos de corte.

Neste tipo de cruzamento, os cromossomos tipo A dos progenitores são divididos em dois pontos de corte e seus descendentes recebem estes “pedaços” de modo alternado. Uma representação é mostrada na Figura 2 onde se tem dois indivíduos (progenitores), representados por um cromosso-

mo do tipo “A” composto por três genes, referentes aos percentuais de consumo de gás natural para os meses de janeiro, fevereiro e março. Foram sorteados dois pontos de corte, sendo o primeiro no início do mês de janeiro e o segundo no início de março.

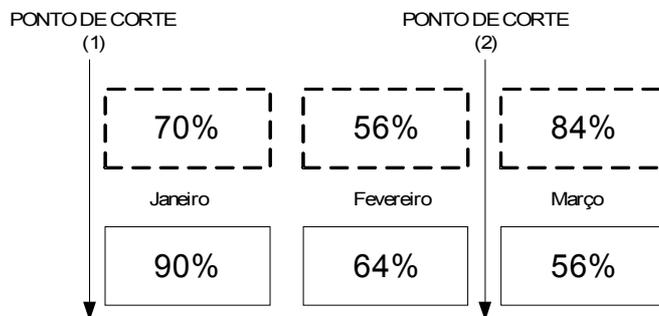


Figura 2. Progenitores – Sorteio dos pontos de corte.

A Figura 3 apresenta os descendentes oriundos do cruzamento entre os progenitores apresentados pela Figura 1, onde se percebe a troca de material genético na formação dos novos indivíduos.

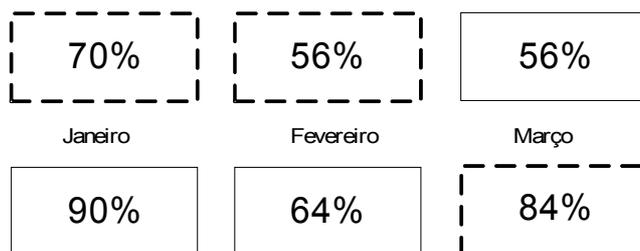


Figura 3. Descendentes.

De acordo com o procedimento adotado para o cruzamento entre os progenitores, uma situação não desejada pode ocorrer: o novo indivíduo pode não garantir a meta de consumo estabelecida para todo o período, equação (2), seja por excesso ou falta de gás natural. Para contornar tal situação utiliza-se a técnica de pequenos ajustes [7]. Esta técnica tem por objetivo a diminuição (no caso de excesso) ou o aumento (no caso de falta) do consumo mensal de gás natural de modo a respeitar a meta estabelecida para todo o período em análise. Os meses que sofrerão alterações (diminuição ou aumento do consumo de GN) são sorteados com probabilidades iguais.

Em relação aos cromossomos tipo B, referente aos dias de operação e ao consumo diário de gás natural, adotou-se a seguinte estratégia na etapa de cruzamento: (i) para os cromossomos fora do intervalo de corte, mantém-se o código genético inalterado; (ii) para os cromossomos dentro dos pontos de corte, refaz-se todo o material genético, conforme apresentado pela Figura 4.

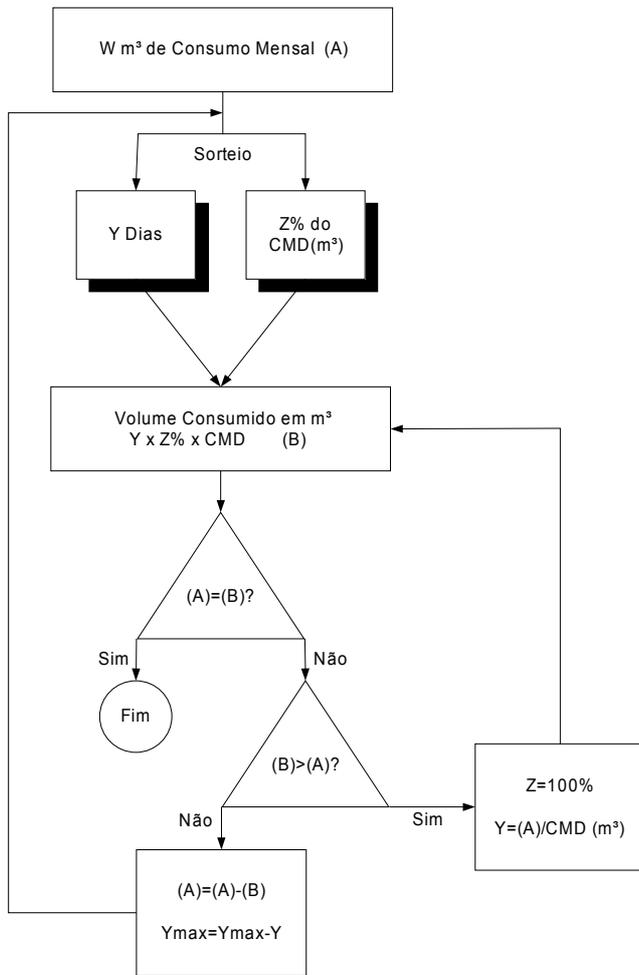


Figura 4. Formação do Cromossomo do Tipo B.

onde:

W Consumo mensal de gás natural (m^3);

Y Número de dias em operação da UTE;

Y_{max} Número máximo de dias que a UTE pode ficar em operação no mês;

Z Percentual consumido de gás natural em relação ao consumo máximo diário;

CMD Consumo máximo diário de gás natural (m^3);

III.3.3 Operador de Mutação

Na modelagem proposta o operador de mutação atua somente no cromossomo do tipo B. O operador de mutação tem como objetivo inserir novas características aos descendentes e até mesmo o de restaurar as características perdidas a cada geração. O processo adotado faz com que alguns descendentes de cada geração, regidos por um percentual denominado taxa de mutação, sofram uma troca completa no que diz respeito aos dias de operação e consumo diário de GN em alguns meses do período de operação. O processo adotado é realizado através dos seguintes passos: i) Sorteio do número e dos meses que sofreram o efeito do operador de mu-

tação; (ii) criação de uma “roleta” com as seguintes proporções: (a) 60% - imposição do consumo máximo diário de gás natural dentro do respectivo mês; (b) 40% - determinação aleatória do consumo diário de gás natural dentro do respectivo mês.

A Figura 5 apresenta o fluxograma geral do algoritmo genético proposto.

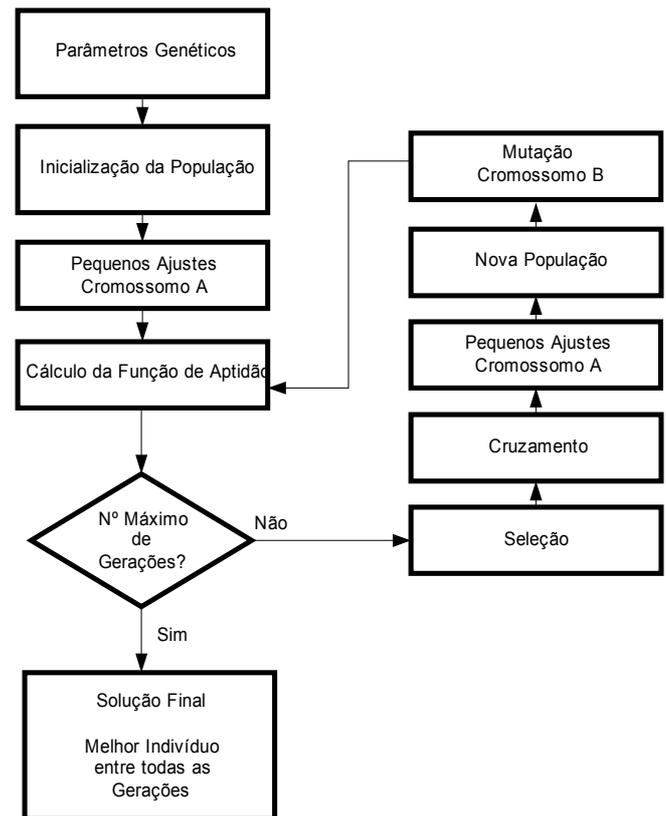


Figura 5. Fluxograma do AG proposto.

IV. ESTUDO DE CASOS

Para ilustrar os resultados obtidos pelo algoritmo genético proposto foram considerados: (i) período de estudo de um ano (doze meses); (ii) termoeétrica composta por duas turbinas a gás natural e uma a vapor; (iii) volume disponível de gás natural de 397.110.000 de m^3 (70% do consumo máximo anual) dentro do período de estudo. (iv) consumo máximo diário de cada turbina a gás de 775.000 m^3 . (v) geração máxima da UTE de 320 MW; (vi) geração mínima da UTE de 160MW. A figura 6 apresenta a interface gráfica do software desenvolvido para a entrada dos parâmetros de operação da unidade térmica.

Definidos os parâmetros, foram realizadas duas simulações: (i) considerando o consumo mensal sem variações ao longo do ano, consumo “Flat”. (ii) considerando a possibilidade de variações mensais de consumo ao longo do ano.

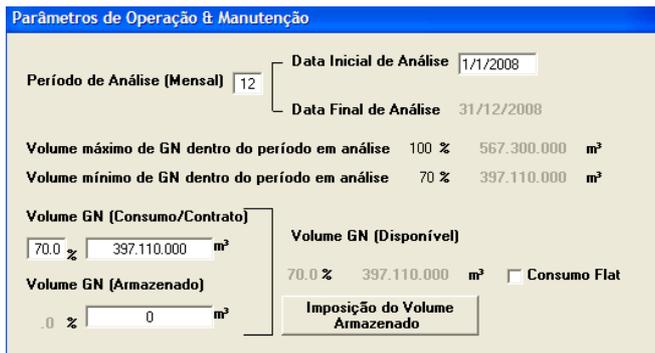


Figura 6- Interface: Parâmetros de Operação.

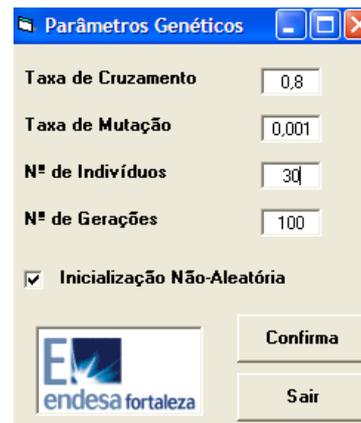


Figura 7- Interface: Parâmetros Genéticos.

Estas simulações têm por objetivo verificar a existência ou não de uma modulação de consumo mensal de gás natural mais econômica que a modulação constante, geralmente adotada. É importante mencionar que se trata de um problema de difícil solução devido ao grande número de opções de consumo existente para o mesmo volume de gás disponível (contratado e armazenado).

Para ambas as simulações foram utilizadas os seguintes parâmetros genéticos: Taxa de mutação de 0,1%; Taxa de cruzamento de 80%; População formada por 30 indivíduos; 100 gerações e inicialização de forma não aleatória. A figura 7 apresenta a janela referente à entrada dos parâmetros do algoritmo genético implementado.

Em relação aos custos inerentes a UTE foram adotados os seguintes valores: (i) Custo do gás natural de 2,581 \$/MBTU; Cotação do dólar de 1,70R\$; Custo fixo da UTE de R\$ 1.800.000,00; Custo da água 2,00 R\$/MWh; Custo de Efluentes de 0,81 R\$/MWh; Custo referente às horas de operação de R\$ 675,00; Custo de parada e partida das turbinas de R\$ 6750,00. A figura 8 apresenta a interface gráfica referente à entrada dos custos associados ao problema em questão.



Figura 8- Interface: Custos de Operação e Manutenção.

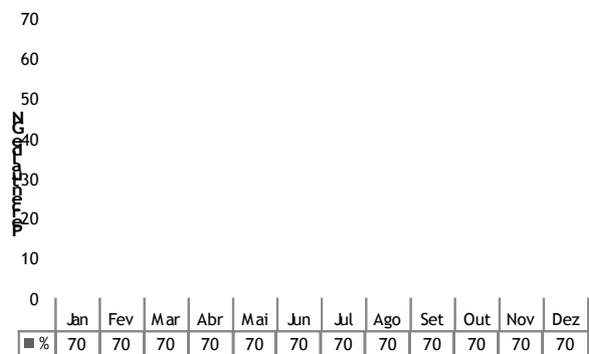


Figura 9. Consumo "Flat" - percentual mensal de GN pela UTE.

IV.1 Consumo mensal de GN sem variações

Para esta primeira simulação do algoritmo proposto, não foram permitidas variações mensais do consumo de GN dentro do período total de análise, de modo a representar a programação de operação usualmente adotada. Desta forma, tem-se para todo o período de operação um consumo mensal de 70% do consumo máximo mensal da UTE, Figura 9. Esta informação do consumo percentual mensal de GN é oriunda do cromossomo tipo A.

A Figura 10 apresenta os dias de operação da UTE, cuja informação é oriunda do cromossomo tipo B, para cada um dos meses de operação, sendo a potência média mensal de geração da UTE de 320MW, ou seja, máxima (ciclo combinado). O custo total para esta configuração de operação é de aproximadamente R\$ 92.110.440,00.

IV.2 Consumo mensal de GN com variações

Para esta segunda simulação do software desenvolvido foi permitido ao algoritmo de otimização a obtenção de soluções que apresentem variações do consumo mensal de gás natural entre os meses de estudo. Esta simulação é interessante, pois como já havia sido mencionado não é usual programações de operação que não tenham um consumo "flat"

de gás natural.

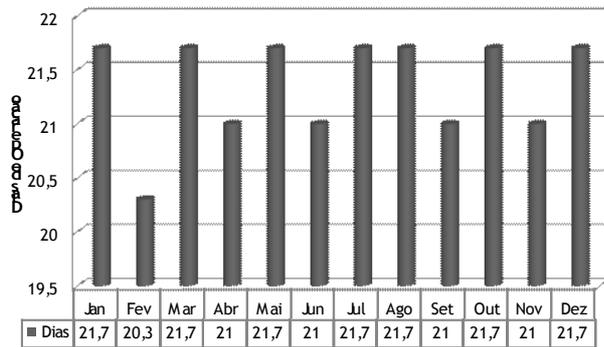


Figura 10. Consumo “Flat” - Dias de operação.

As Figuras 11 e 12, respectivamente, apresentam a melhor solução obtida à simulação em questão, sendo apresentado o consumo percentual mensal de gás natural (cromossomo tipo A) e os dias de operação da UTE (cromossomo tipo B) para cada um dos meses de operação, sendo a potência média mensal de geração da UTE de 320MW, ou seja, máxima (ciclo combinado)

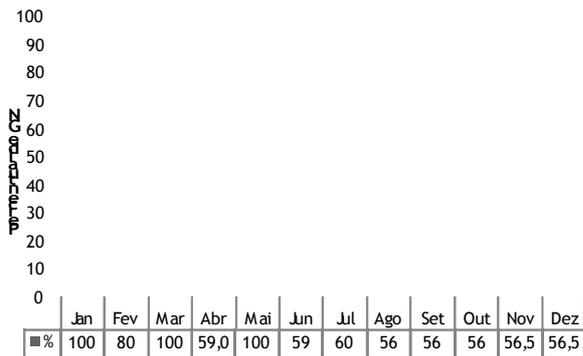


Figura 11. Consumo Variável - percentual mensal de GN pela UTE.

É importante notar, Figura 11, que as restrições do contrato ToP (*Take-or-Pay*) foram atendidas, ou seja, o mínimo de 70% anual e 56% mensal e que a equação (2) da meta de consumo de GN foram atendidas.

O custo total para a configuração de operação obtida para esta segunda simulação foi de aproximadamente R\$ 89.235.609,00. Esta solução mostra-se mais econômica do que a encontrada considerando a modulação constante do consumo de gás natural. Este fato pode ser explicado pelo fato de que a programação de operação obtida, nesta segunda simulação, ter como característica a operação em ciclo combinado (320 MW) e o consumo mensal de gás no menor intervalo de tempo (dias do mês).

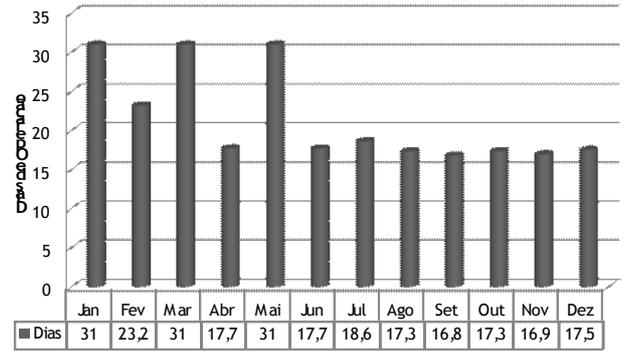


Figura 12. Consumo Variável - Dias de operação.

V. CONCLUSÕES

Este artigo apresentou a aplicação de uma das técnicas de inteligência artificial denominada Algoritmo Genético ao problema referente à otimização da operação de unidades termelétricas de ciclo combinado. Através dos resultados obtidos, pode-se enfatizar o fato da simulação considerando a possibilidade de variações mensais de consumo de gás natural ter gerado uma redução econômica superior a 3% (R\$ 2.874.831,00) em relação à operação obtida pela primeira simulação, modulação constante. Ou seja, podem existir modulações de consumo de gás mais econômicas do que as modulações constantes, geralmente adotadas. Além disso, pôde-se confirmar através dos resultados obtido que a maior eficiência de operação da UTE consiste na utilização do UTE em ciclo combinado, ou seja, o consumo máximo de gás natural através das turbinas a gás natural e da utilização da turbina a vapor (320 MW).

É importante mencionar que se trata de um problema de difícil solução devido ao grande número de opções de operação existente para o mesmo volume de gás disponível.

VI. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Santos, N.O., *Termodinâmica aplicada às termelétricas: teoria e prática*, 2nd ed., Interciência, Rio de Janeiro, 2006.
- [2] Wood, A.J and Wollenberg, B.F., *Power Generation, Operation & Control*. 1ª edição, editora John Wiley & Sons, 1996.
- [3] Wonk, K. P., Doan, K., “Artificial intelligence algorithm for daily scheduling of thermal generators”, *IEE Proceedings, part C – Gen. Transm. Distr.*, Vol. 138, nº. 6, pp. 518-534, Nov, 1991.
- [4] Goldberg, M.C e Luna, H.P., *Otimização Combinatória e Programação Linear*. 2ª edição, Rio de Janeiro, Editora Campus, 2000.
- [5] Falcão, D.M.; Borges, C.L.T.; Viveros, E.R.C.; A Parallel Genetic Algorithm based Methodology for Network Reconfiguration in the Presence of Dispersed Generation. In: International Conference on Electricity Distribution, 2004, Barcelona. Proceedings of 17th International Conference on Electricity Distribution, 2003.
- [6] Dasgupta, D. and Mcgregor, D.R., “Thermal unit commitment using genetic algorithms,” *Proc. Inst. Elect. Eng., Gen. Transm. Dist.*, Vol. 141, nº 3, pp. 459–465, Sept, 1994.
- [7] Soares G. L., “Algoritmos genéticos: estudo, novas técnicas e aplicações”, Universidade Federal de Minas Gerais, Tese de Mestrado, Junho 1997.

- [8] Goldberg D. E., "Genetic algorithms in search, optimization, and machine learning", Addison-Wesley Publishing Company Inc., January 1989.