



**SNPTEE  
SEMÍNÁRIO NACIONAL  
DE PRODUÇÃO E  
TRANSMISSÃO DE  
ENERGIA ELÉTRICA**

GPL 26  
14 a 17 Outubro de 2007  
Rio de Janeiro - RJ

## **GRUPO VII**

### **GRUPO DE ESTUDO DE PLANEJAMENTO DE SISTEMAS ELÉTRICOS – GPL**

#### **PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO VIA ESTRATÉGIAS DE EVOLUÇÃO CONSIDERANDO O VALOR DA CONFIABILIDADE E OS CUSTOS DE PERDAS**

**L.A.F. Manso\***  
UFSJ, São João del-Rei, MG

**C.E. Sacramento**  
CEMIG, Belo Horizonte, MG

**A.M. Leite da Silva    L.C. Resende    W.S. Sales    L.S. Rezende**  
UNIFEI, Itajubá, MG

## **RESUMO**

Este artigo apresenta uma nova metodologia para solucionar o problema da expansão da transmissão, a qual utiliza uma abordagem dinâmica e considera a busca pela solução de mínimo custo global, composto pelos custos de investimentos, pelos custos de interrupção, ou valor da confiabilidade (índice LOLC – *Loss of Load Cost*), e pelos custos de operação, restritos ao valor das perdas ôhmicas. O modelo adotado para o processo de busca das melhores alternativas de expansão utiliza Estratégias de Evolução em conjunto com outras heurísticas, tais como a empregada pelo método GRASP, para a construção de soluções iniciais. Estudos de casos com um sistema teste e um sistema real da CEMIG são apresentados e discutidos.

## **PALAVRAS-CHAVE**

Planejamento da expansão da transmissão, Estratégias de evolução, Valor da confiabilidade, Metaheurísticas.

## **1.0 - INTRODUÇÃO**

O planejamento da expansão da transmissão (PET) é uma tarefa de otimização complexa, pois deve assegurar o atendimento da demanda ao longo do horizonte de planejamento, com nível de confiabilidade adequado, e, ao mesmo tempo, minimizar os custos de investimento, de operação e de interrupção. O principal objetivo é definir onde, quando e quais reforços deverão ser implantados na rede elétrica. Para tal, deve-se considerar um horizonte plurianual, de modo a determinar as melhores seqüências de obras de reforço ano a ano. Geralmente, o horizonte de planejamento é dividido em curto, médio e longo prazo, de acordo com o tipo de decisão a ser tomada e com a qualidade das informações envolvidas no processo de planejamento. Vários artigos sobre o planejamento da expansão da transmissão podem ser encontrados na literatura [1]-[11].

Para contornar a natureza dinâmica do problema PET, estudos simplificados (conhecidos como planejamento estático) definem, para apenas um estágio, onde e quais reforços devem ser implantados. Uma outra simplificação aplicada ao problema PET está na utilização de métodos determinísticos, através dos quais são desconsideradas as incertezas associadas, tais como saídas forçadas de equipamentos, flutuações na carga, condições hidrológicas, cenários de projeção de carga, localização de novas fontes de geração, etc. Mesmo considerando apenas aspectos determinísticos, é muito difícil encontrar a solução ótima para problemas PET, uma vez que ela requer o uso de algoritmos combinatoriais, os quais apresentam grande dificuldade de execução, até mesmo para sistemas de porte médio. Com a inclusão de incertezas, a solução ótima destes problemas se torna praticamente inacessível.

Recentemente, os modelos metaheurísticos têm despertado grande interesse. Tais modelos utilizam técnicas de otimização que, passo a passo, realizam um processo de geração, avaliação e seleção de opções de expansão. Estes modelos são mais atrativos, pois podem obter boas (i.e. economicamente competitivas) soluções factíveis a

\* DEPEL – UFSJ – Universidade Federal de São João del-Rei – Praça Frei Orlando, 170, São João del-Rei, MG  
Tel.: (32) 3379-2583 – Fax: (32) 3379-2306 – E-mail: lmanso@ufs.edu.br

um baixo custo computacional. Ao mesmo tempo, o processo de otimização pode utilizar estratégias que procuram evitar o aprisionamento em *vales* da função objetivo e, conseqüentemente, reduzem o risco de obtenção de ótimos locais de baixa qualidade. Portanto, tais métodos têm demonstrado um excelente potencial para encontrar boas soluções factíveis, mas não necessariamente ótimas [12]. Várias metaheurísticas foram empregadas na última década para resolver problemas PET, tais como: Recozimento Simulado (SA – *Simulated Annealing*) [5], Busca Tabu (TS – *Tabu Search*) [6], Algoritmos Genéticos (GA – *Genetic Algorithms*) [7], Procedimento de Busca Aleatória Gulosa (GRASP – *Greedy Randomized Search Procedure*) [8], Sistema de Colônia de Formigas (ACS – *Ant Colony System*) [9] e Estratégias de Evolução (ES – *Evolution Strategies*) [10].

Este artigo apresenta uma nova metodologia para solucionar o problema PET, utilizando uma abordagem dinâmica e considerando a busca pela solução de mínimo custo global, composto pelos custos de investimentos, pelos custos de interrupção, ou valor da confiabilidade (índice LOLC – *Loss of Load Cost*, [11],[13],[14]), e pelos custos de operação, restritos ao valor das perdas ôhmicas. O modelo adotado para o processo de busca das melhores alternativas de expansão utiliza Estratégias de Evolução em conjunto com outras heurísticas, tais como a empregada pelo GRASP, para a construção de soluções iniciais. Estudos de casos com um sistema teste e um sistema real da CEMIG são apresentados e discutidos.

## 2.0 - ESTRATÉGIAS DE EVOLUÇÃO

Métodos de Computação Evolucionária (EC – *Evolutionary Computation*) se baseiam no princípio da representação aproximada da evolução natural. Estes algoritmos alteram a população de indivíduos (soluções) ao longo de uma seqüência de gerações, utilizando-se de analogias estatísticas com o processo de evolução natural. Apesar de existirem atualmente muitas variedades de EC, historicamente é possível identificar três abordagens gerais: GA, ES e programação evolucionária. Estas abordagens diferem entre si nos mecanismos de alteração, aplicados de geração para geração, e na forma de representação computacional dos indivíduos. Contudo, atualmente todas as classes de algoritmos EC são bastante similares, sendo que cada área de EC copiou e modificou idéias apresentadas pelas demais áreas.

A metodologia GA é mais popular entre pesquisadores e engenheiros de sistema de potência [12]. As principais diferenças entre ES e GA referem-se à representação da população e aos mecanismos de evolução. Em geral, GA utilizam *strings* binárias para caracterizar um indivíduo. Já através dos algoritmos ES, a **representação** é realizada de forma direta, i.e. cada gene de um indivíduo é representado por uma variável real do problema, denominada parâmetro objeto. Também de maneira diferente em relação aos GA, o algoritmo ES, em geral, utiliza apenas os mecanismos de **seleção** e **mutação** para simular o processo evolutivo.

### 2.1 Representação

Como já foi observado, os algoritmos ES utilizam a representação direta. Então, em problemas de expansão da transmissão, cada gene de um indivíduo corresponderá a uma das opções de reforço (i.e. ramo onde novos circuitos poderão ser instalados) e será preenchido por um número inteiro, variando de zero até o número máximo de reforços por gene. Portanto, a representação básica de um indivíduo terá o seguinte aspecto:

$$X^k = [X_1^k, X_2^k, \dots, X_i^k, \dots, X_n^k]^T \quad (1)$$

onde:  $X_i^k$  representa o número de circuitos adicionados ao ramo  $i$ , na decisão  $k$ ; e  $n$  é o número de genes (i.e. ramos que poderão receber reforços).

### 2.2 Seleção

Os diversos modelos de ES derivam do modelo geral  $(\mu, \kappa, \lambda, \rho)$ ES [15], cujos parâmetros têm os seguintes significados:  $\mu$  é o no. de progenitores numa geração;  $\kappa$  é o no. de gerações que um indivíduo sobrevive;  $\lambda$  é o no. de descendentes criados numa geração; e  $\rho$  é o no. de progenitores de um indivíduo. Neste trabalho é utilizado o modelo  $(\mu+\lambda)$ ES. Portanto,  $\kappa$  e  $\rho$  são feitos iguais a 1, e os novos  $\mu$  progenitores são selecionados do conjunto  $\mu+\lambda$ . Esta forma de seleção garante que, no conjunto, os indivíduos da geração futura nunca serão piores que os seus progenitores.

### 2.3 Mutação

A mutação traz diversidade para as populações, garantindo assim, que diferentes regiões, dentro do espaço de busca, sejam exploradas. Nas ES a mutação consiste em adicionar, a cada indivíduo, uma perturbação  $Z^k$  normalmente distribuída, de dimensão  $(n \times 1)$ , conforme Eqs. (2) e (3).

$$\tilde{X}^k = X^k + Z^k \quad (2)$$

$$Z^k = \sigma \times [N_1(0,1), \dots, N_i(0,1), \dots, N_n(0,1)]^T \quad (3)$$

onde:  $\tilde{X}^k$  representa um novo indivíduo, o qual é obtido através da mutação de  $X^k$ ;  $\sigma$  é a amplitude de mutação ou passo *mutacional*, que deve ser vista como um parâmetro estratégico;  $N_i(0,1)$  corresponde a uma distribuição Gaussiana com média zero e variância unitária.

A amplitude de mutação,  $\sigma$ , pode ser individualizada e, então, ficar sujeita à mutação e seleção, caracterizando o modelo ES *auto-adaptativo*. Neste modelo, cada indivíduo fica governado por parâmetros, objetos e estratégicos (amplitudes de mutação), os quais estão sujeitos à evolução. Para o caso em que  $\sigma$  é mantido constante durante todo o processo evolutivo, e apenas os parâmetros objetos ficam sujeitos à mutação e seleção, tem-se o ES *não-adaptativo*. Para o problema da expansão da transmissão, que é discreto, o modelo *não-adaptativo* teve melhor desempenho, sendo adotado neste trabalho.

Como pode ser visto, a perturbação  $Z^k$  é contínua. Então, cada novo indivíduo (produzido por mutação) deve ter seus genes *discretizados*. Isto pode ser feito através de uma função de arredondamento como a utilizada em [10].

#### 2.4 Geração Inteligente da População Inicial

Após uma série de testes preliminares foi constatado que a convergência do algoritmo ES é fortemente influenciada pela escolha da população inicial. Então, para melhorar o desempenho do algoritmo é fundamental a utilização de heurísticas para a construção de *boas* soluções iniciais, as quais farão parte da chamada *População Inicial Inteligente*. Para tal, este artigo se baseou na chamada *fase construtiva*, utilizada pelo método de busca GRASP [8]. Assim, metade da *População Inicial Inteligente* é gerada aleatoriamente e a outra metade é gerada com base em uma função *gulosa*, obtida a partir da seguinte otimização linear:

$$\text{Min } z = \alpha^T r \quad (4)$$

s.a.

$$g + r + B\theta = d \quad (4.1)$$

$$0 \leq g \leq g_{max} \quad (4.2)$$

$$0 \leq r \leq d \quad (4.3)$$

$$|f| \leq f_{max} \quad (4.4)$$

onde:

$\alpha$  - Vetor de custo unitário de carga não suprida;  
 $g$  - Vetor de geração;  
 $r$  - Vetor de carga não suprida (ou geração fictícia);  
 $B$  - Matriz susceptância;  
 $\theta$  - Vetor ângulo de tensão;  
 $d$  - Vetor de carga;  
 $g_{max}$  - Vetor limite de geração na barra;  
 $f$  - Vetor fluxo de potência;  
 $f_{max}$  - Vetor limite de fluxo de potência.

Este problema de programação linear pode ser eficientemente resolvido por um código dual simplex e os multiplicadores de Lagrange associados a cada restrição são obtidos como subproduto da solução. Dentre estes multiplicadores, aqueles associados com as restrições da Eq. (4.1) são os de interesse, pois medem os benefícios para os índices de carga não suprida decorrentes de alterações nas susceptâncias dos circuitos. Denotando estes multiplicadores de Lagrange pelo vetor  $\pi^d$ , tais benefícios podem ser estimados por [8]:

$$\pi_{kl}^d = (\pi_k^d - \pi_l^d)(\theta_k - \theta_l) \quad (5)$$

onde:  $\pi_{kl}^d$  é o multiplicador de Lagrange associado com a susceptância do circuito que conecta as barras  $k$  e  $l$ . A fim de considerar também os custos associados ao reforço de um dado circuito, a função *gulosa* é definida como:

$$h_{kl} = -\frac{\pi_{kl}^d}{c_{kl}} \quad (6)$$

sendo  $c_{kl}$  o custo do investimento necessário para adicionar um novo circuito entre as barras  $k$  e  $l$ .

Agora é possível construir uma lista de reforços candidatos formados a partir dos circuitos mais promissores, ordenados pela função *gulosa*. O algoritmo de 5 passos a seguir fornece um conjunto de boas soluções factíveis a serem utilizadas para compor metade da *População Inicial Inteligente*:

- (i) Para uma dada carga prevista, executar um fluxo ótimo DC, isto é Eq. (4), considerando o sistema elétrico sem nenhum reforço (caso base);
- (ii) Avaliar a função *gulosa*, isto é Eq. (6) e ordenar os circuitos usando os parâmetros  $h_{kl}$ ;
- (iii) Através de uma distribuição uniforme, amostrar, dentre os  $n$  melhores circuitos ordenados, apenas 1 reforço para ser adicionado à rede e executar um novo fluxo de potência ótimo DC;
- (iv) Se a nova solução é factível deve-se ir para o passo (v), senão deve-se retornar ao passo (ii);
- (v) Se o tamanho pré-especificado (50% da *População Inicial Inteligente*) for alcançado deve-se iniciar a busca, senão deve-se retornar ao passo (i).

## 2.5 Custos de Perdas Ôhmicas

Para a incorporação das perdas ao modelo de fluxo de potência DC foi utilizada a metodologia apresentada em [16] e mais alguns procedimentos como, por exemplo, a adoção de uma folga nos circuitos de transmissão, a qual deve ser suficiente para acomodar a parcela de fluxo devido às perdas. Tais procedimentos visam evitar que o algoritmo de otimização seja executado mais que uma vez para cada alternativa de expansão analisada. Após serem determinadas as perdas, o seu custo ( $C_{perdas}$ ) é obtido através da Eq. (7).

$$C_{perdas} = 8736 \times C_{kWh} \times FP \times \sum (P_{ij}) \quad (7)$$

onde:

$C_{kWh}$  - custo unitário de perdas, dado em R\$/kWh;

$FP$  - fator de perdas;

$P_{ij}$  - perdas ôhmicas, para a condição de carga pico, no circuito entre as barras  $i$  e  $j$  (existente ou novo).

Com a inclusão das perdas ôhmicas, o custo de expansão de uma dada seqüência  $k$  para um determinado ano  $i$  ( $S_i^k$ ) pode ser obtido através da Eq. (8).

$$S_i^k = \sum_{j=1}^{nt} C_{inv_j} M_{i,j}^k + C_{perdas_i^k} \quad (8)$$

onde:

$C_{inv_j}$  - custo de investimento por unidade de transmissão (circuito) nova  $j$ ;

$M_{i,j}^k$  - número de unidades alocado no ramo  $j$  no ano  $i$  da seqüência  $k$ ;

$nt$  - número de ramos que poderão receber novos circuitos;

$C_{perdas_i^k}$  - custo das perdas ôhmicas no ano  $i$  da seqüência  $k$ .

A utilização da constante 8736 na Eq. (7), visa transformar o custo incremental de perdas em custos anuais. Desta forma, as parcelas do custo total referentes ao investimento e às perdas são todas obtidas em uma base anual. Portanto, a função objetivo dada pela Eq. (8) fica formulada de maneira consistente.

## 3.0 - PLANEJAMENTO DINÂMICO

A metodologia proposta para solucionar problemas PET segue alguns princípios básicos. Primeiramente, o algoritmo ES é aplicado a uma *População Inicial Inteligente*, para encontrar as  $n_b$  melhores soluções associadas com o último ano do horizonte de planejamento. Uma vez obtidas as  $n_b$  melhores soluções associadas ao último ano, uma abordagem para se encontrar as  $n_b$  melhores soluções para os níveis de carga dos anos precedentes  $n_b-1$ ,  $n_b-2$ , ..., 1 é descrita a seguir. A idéia básica é coordenar as soluções encontradas para cada ano precedente com o conjunto de reforços ótimos obtidos a partir do último ano. Finalmente, os custos de interrupção associados com as  $n_b$  melhores seqüências são avaliados e considerados juntamente com os custos de perdas e os investimentos.

### 3.1 Cronologia dos Reforços

Para um dado horizonte,  $N_Y$ , o problema PET pode ser definido como:

$$\text{Min}_k \{S^k\} = \text{Min}_k \left\{ \sum_{i=1, N_Y} S_i^k \right\} \quad (9)$$

onde  $S^k$  representa o custo total (investimento e perdas) associado com a seqüência  $k$  de reforços realizados no período de análise, e  $S_i^k$  é obtido conforme Eq. (8).

Usando um algoritmo ES, iniciado pela função *gulosa*, pode-se acessar as  $n_b$  melhores soluções para o patamar de carga do último ano do horizonte, isto é  $L(N_Y)$ . Para cada solução, um conjunto de reforços é encontrado e será utilizado para definir a melhor solução para o ano anterior, isto é  $N_Y-1$ . Portanto, pode-se encontrar a melhor solução condicionada ao conjunto de reforços obtido para cada uma das  $n_b$  melhores soluções do ano  $N_Y$ , e também condicionada ao nível de carga do ano  $N_Y-1$ , isto é  $L(N_Y-1)$ . Este processo continua para os anos  $N_Y-2$ ,  $N_Y-3$ , ..., 1. No final deste processo, existirão  $n_b$  seqüências de boas soluções coordenadas e aquela cujo valor presente dos totais de investimento e perdas seja mínimo é escolhida como a melhor opção.

Na descrição anterior da metodologia, o último ano foi escolhido como o mais importante, uma vez que toda a seqüência é obtida a partir deste ano. Contudo, é possível escolher qualquer ano como o mais importante, devido, por exemplo, a alguma informação relevante sobre o sistema. Adicionalmente, uma ordem de priorização qualquer (e.g.  $N_Y-5$ ,  $N_Y-2$ ,  $N_Y$ , ..., 1) pode ser adotada para a obtenção das melhores seqüências. Assim, a escolha do ano mais importante e a definição de uma ordem de priorização dos anos, tornam mais flexível o processo de busca.

Para realizar a busca pela melhor solução em um determinado ano, sempre partindo de uma *População Inicial Inteligente*, o algoritmo ES deve utilizar a Eq. (10), dada a seguir:

$$z = c^T x + \alpha^T r + C_{perdas} \quad (10)$$

onde  $c$  representa o vetor de custo de investimento unitário e  $x$  é o vetor de decisão de reforços (indivíduo), cujos componentes são os genes do processo ES para um ano, ou nível de carga, particular. A Eq. (10) resulta da inclusão dos custos de investimento e de perdas à Eq. (4), e está sujeita às mesmas restrições: Eqs. (4.1) a (4.4).

### 3.2 Valor da Confiabilidade

Geralmente, se um horizonte é definido ( $N_Y$ ), o processo de otimização global tenta encontrar uma boa (ou mesmo ótima) solução  $S^*$ , a qual tem margens muito pequenas de capacidade no final do período de análise. Como o planejamento, mesmo que futuramente, também será realizado para os anos subsequentes,  $N_Y+1$ ,  $N_Y+2$ , ..., a solução encontrada tende a não ser uma opção tão boa quanto parece.

A fim de solucionar os problemas anteriores, as margens de capacidade, associadas às boas soluções encontradas em cada estágio da otimização, têm que ser medidas e incluídas neste processo. Isto pode ser conseguido através da avaliação da LOLC. Deste modo, a busca pela solução final ótima  $S^*$  penalizará a falta de margem de reserva, a fim de que os efeitos percebidos, principalmente no último ano, sejam minimizados.

### 3.3 Algoritmo Proposto

Os passos a seguir resumem o algoritmo proposto, considerando uma dada ordem de priorização dos anos (estágios) do horizonte de planejamento ( $N_Y$ ):

- (i) Utilizando a metodologia apresentada na subseção 2.4, gerar uma *População Inicial Inteligente* para o primeiro ano priorizado;
- (ii) Encontrar todas as  $n_b$  melhores soluções para o primeiro ano priorizado utilizando um algoritmo ES baseado na Eq. (10). Calcular os custos de interrupção (LOLC) associados com estas soluções;
- (iii) Definir os reforços candidatos para o próximo ano, dado pela ordem de priorização. Neste caso, os reforços candidatos são definidos pela solução do ano posterior mais próximo (em ordem cronológica), quando existir. Caso contrário, os reforços candidatos são os mesmos definidos para o horizonte de planejamento. Por outro lado, quando houver soluções para pelo menos um dos anos anteriores (em ordem cronológica), realiza-se a expansão partindo do ano anterior mais próximo;
- (iv) Utilizando o mesmo algoritmo ES do passo (ii), encontrar as  $n_b$  melhores soluções coordenadas para o ano em expansão (dado pela ordem de priorização). Para tal, assim como no passo (i), deve ser gerada uma *População Inicial Inteligente*. Calcular os custos de interrupção para o ano em análise;
- (v) Repetir os passos (iii) e (iv) até que todos os anos do horizonte de planejamento tenham sido considerados;
- (vi) Calcular o valor presente dos custos (investimento, perdas e interrupção) para a taxa de desconto especificada. Assim, a solução ótima  $S^*$  é encontrada.

Obviamente, o algoritmo anterior não fornece, necessariamente, a melhor solução para o problema PET, mas uma solução de alta qualidade com aceitável tempo de CPU. Este algoritmo pode ser mais *refinado* para explorar várias trajetórias do espaço de soluções.

## 4.0 - APLICAÇÃO

Os estudos aqui apresentados correspondem a aplicações do algoritmo proposto, utilizando a técnica ES, na expansão de um sistema teste e de um sistema de subtransmissão da CEMIG.

### 4.1 Sistema Teste

A Figura 1 ilustra o sistema teste, o qual possui 6 barras (3 de geração e 3 de carga) e 11 circuitos duplos. No ano de referência ou ano base, a capacidade instalada é de 260 MW e a demanda máxima é de 210 MW. O horizonte de planejamento é de 8 anos e a cada ano a carga e a capacidade de geração são aumentadas em 25% dos valores apresentados no ano de referência. Assim, a carga e a capacidade instalada no final do período de análise serão de 630 MW e 780 MW, respectivamente. Para este sistema, não é permitida a criação de novos ramos (conexões entre barras), e o número de novos circuitos a serem acrescentados aos ramos existentes é limitado a 3 circuitos simples. A potência base adotada para esse sistema é 100 MVA.

A Tabela 1 apresenta 5 casos considerando diferentes ordens para o processo de busca das melhores seqüências de reforços. A coluna "PRIORIZAÇÃO" fornece a ordem dos anos priorizados para cada estudo. Considerando o primeiro ano priorizado de cada caso, as 5 melhores soluções são obtidas, isto é  $n_b = 5$ . Portanto, 5 seqüências de reforços serão criadas para cada um dos 5 casos. A avaliação da confiabilidade composta, via simulação Monte Carlo não-sequencial, é realizada separadamente no final do processo de busca, para o qual a função de adaptação é basicamente o custo de investimento somado ao custo de perdas.

As Tabelas 2 e 3 mostram os dados determinísticos e estocásticos, de geração e de circuitos, respectivamente. Na Tabela 2, a capacidade máxima por unidade de geração é definida para o ano de referência. Na Tabela 3, os valores de resistência, reatância, capacidade, custos de investimento e taxa de falha são fornecidos para cada circuito simples. Portanto, cada circuito existente no ano base (circuito duplo) terá o dobro da capacidade e a metade da resistência e reatância apresentadas na Tabela 3, para o respectivo circuito simples. Todos os circuitos têm um MTTR de 10 horas. As cargas, conectadas às barras 4, 5 e 6, são iguais e atingem 70 MW no ano de referência. Para o cálculo do custo de perdas foram adotados: um custo unitário de perdas igual a 0,10 R\$/kWh e um fator de perdas de 0,6144. Para a obtenção da LOLC, um custo unitário de interrupção de 1,50 R\$/kWh e a curva de carga horária do IEEE-RTS [17] são adotados.

Para o emprego da técnica ES são utilizados um passo de mutação  $\sigma = 0,4$  e uma população de 10 indivíduos, sendo a população inicial gerada usando a metodologia descrita na subseção 2.4. O processo evolucionário é interrompido se o número de 150 gerações é atingido ou se a melhor solução obtida permanece inalterada após 20 gerações. O algoritmo ES é executado 10 vezes para cada ano de estudo, a fim de capturar a melhor solução. O valor de 3.000 R\$/kW é adotado para a penalidade ( $\alpha$ ) do corte de carga.

A Tabela 4 mostra os custos obtidos pelo algoritmo proposto, para as 5 melhores seqüências de cada caso estudado. Todos os custos estão expressos em termos de seu valor presente, sendo utilizada uma taxa de desconto de 10% ao ano. A melhor seqüência de cada caso aparece em negrito. Como pode ser observado, se apenas os custos de investimento fossem considerados, a *Seqüência C<sub>2</sub>* seria a vencedora, pois apresenta o menor montante de investimentos: R\$201,07×10<sup>6</sup>. Esta situação não é alterada após a inclusão do custo de perdas. Contudo, quando também a LOLC é incluída, a *Seqüência B<sub>3</sub>* se torna a melhor solução de maneira destacada, apresentando um custo total de R\$283,45×10<sup>6</sup>. Nota-se, para este sistema, que os custos de perdas são muito próximos ao longo das seqüências. Por se tratar de um sistema muito estressado, principalmente nos anos finais do planejamento, há uma grande coincidência de reforços, acarretando em pontos de operação semelhantes.

A Tabela 5 mostra o plano ótimo de investimentos para a *Seqüência B<sub>3</sub>*. São incluídos apenas os ramos que receberam novos circuitos. Por exemplo, considerando o último ano do horizonte, apenas 2 circuitos são adicionados, um no ramo 8 e outro no ramo 10. Estas adições custam R\$35 milhões. Este e também os investimentos realizados nos demais anos são convertidos para o valor presente, cujo total atinge R\$201,47 milhões. Os custos de perdas e a LOLC são também apresentados na Tabela 5, tanto em valores anuais, como através do valor presente total.

O tempo médio de CPU gasto para obter as 5 melhores soluções de cada caso, com o algoritmo proposto, incluindo a geração da *População Inicial Inteligente*, foi de 59 minutos, em um Pentium IV com processador de 2,4 GHz. A avaliação da confiabilidade de cada seqüência gastou, em média, 15 minutos no mesmo PC. O algoritmo ES foi acionado 1800 vezes durante todo o processo de busca (i.e. para os 5 casos analisados) e um total de 567.030 otimizações lineares foram executadas, incluindo aquelas necessárias para gerar as *Populações Iniciais Inteligentes*. A avaliação da confiabilidade composta analisou um total de 46.377.500 estados através da simulação Monte Carlo não-sequencial.

#### 4.2 Sistema de Subtransmissão da CEMIG

Um sistema de subtransmissão da CEMIG, localizado na Região Norte de Minas Gerais, foi utilizado para um segundo teste da metodologia proposta. Este sistema é composto por 12 barras, incluindo 6 pontos de carga, uma interligação e uma barra de geração. O seu pico de carga atinge 780,05 MW e a máxima capacidade de geração local é 226,76 MW. O restante de potência é fornecido pela barra de interligação. Existem 20 circuitos de transmissão operando em dois níveis: 138 e 230 kV.

Um horizonte de expansão de 10 anos é considerado, sendo adotada uma taxa de crescimento de carga igual a 5% ao ano. Para o reforço da subtransmissão, todas as possíveis interligações entre as barras de 138 kV são consideradas. Deste modo, 22 pontos de alocação de reforços (ramos) são definidos. É permitido alocar no máximo 3 circuitos por ramo. Portanto, se já existe uma linha de transmissão entre duas barras, somente duas novas linhas poderão ser adicionadas neste ramo.

As seqüências de expansão são obtidas para cada 2 anos do período de estudo, o que define 6 estágios. Também são considerados 5 casos de priorização dos estágios. Uma população de 20 indivíduos é utilizada pelo algoritmo ES proposto. Os outros parâmetros utilizados neste sistema são os mesmos do Sistema Teste. O tempo médio de processamento gasto pela metodologia proposta, para obter as 5 melhores soluções (seqüências) de cada caso de priorização dos estágios, incluindo as análises de confiabilidade, foi de 3 horas e 28 minutos, utilizando o mesmo Pentium IV com processador de 2,4 GHz. Envolvendo todos os 5 casos, o algoritmo ES foi executado 1.300 vezes. Já a simulação Monte Carlo não-sequencial analisou um total de 43.715.080 estados.

Novos testes estão sendo realizados com um sistema de maior porte, da própria CEMIG, considerando a inclusão de linhas de transmissão com diferentes níveis de tensão e a modelagem AC para estudos de fluxo de potência. Outras metaheurísticas estão sendo testadas. Além das Estratégias de Evolução, a Busca Tabu tem apresentado excelente desempenho.

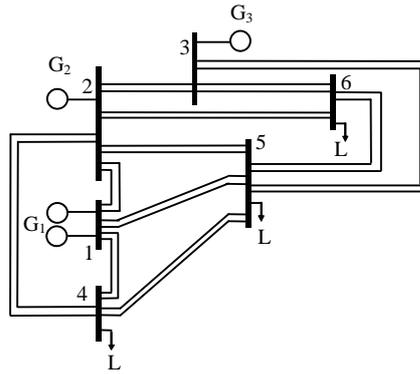


Figura 1. Sistema Teste – Ano Base.

Tabela 1. Casos Estudados.

Caso	Ordem de Priorização dos Anos
1	8, 7, 6, 5, 4, 3, 2, 1 e 0
2	7, 8, 6, 5, 4, 3, 2, 1 e 0
3	6, 8, 7, 5, 4, 3, 2, 1 e 0
4	5, 8, 7, 6, 4, 3, 2, 1 e 0
5	4, 8, 7, 6, 5, 3, 2, ,1 e 0

Tabela 2. Dados de Geração – Determinísticos e Estocásticos.

Barras	No. de Unidades	Cap. Max. por Unidade (MW)	$\lambda$ (/ano)	MTTR (h)
1	2	60,0	7,0	20,0
2	1	70,0	10,0	40,0
3	1	70,0	10,0	40,0

Tabela 3. Dados de Circuitos – Determinísticos e Estocásticos.

Barras	No. do Circuito	R (pu)	X (pu)	Cap. (pu)	Custo (10 <sup>6</sup> R\$)	$\lambda$ (/ano)	
1	2	1	0,10	0,40	0,25	25	1,00
1	4	2	0,10	0,40	0,25	25	1,00
1	5	3	0,15	0,60	0,20	20	1,50
2	3	4	0,13	0,50	0,20	20	1,25
2	4	5	0,05	0,20	0,40	40	0,50
2	5	6	0,15	0,60	0,20	20	1,50
2	6	7	0,10	0,40	0,25	25	1,00
3	5	8	0,13	0,52	0,20	20	1,18
3	6	9	0,05	0,20	0,40	40	0,50
4	5	10	0,20	0,80	0,15	15	2,00
5	6	11	0,15	0,60	0,20	20	1,50

Tabela 4. Valor Presente para as 5 Melhores Sequências.

Seq.-CASO	Inv. (10 <sup>6</sup> R\$)	Perdas (10 <sup>6</sup> R\$)	LOLC (10 <sup>6</sup> R\$)	Total (10 <sup>6</sup> R\$)
<b>A<sub>1</sub></b>	<b>202,00</b>	<b>27,61</b>	<b>63,88</b>	<b>293,49</b>
B <sub>1</sub>	202,43	27,53	65,49	295,45
C <sub>1</sub>	204,76	27,47	65,95	298,18
D <sub>1</sub>	204,53	27,50	67,16	299,19
E <sub>1</sub>	204,53	27,52	66,02	298,07
A <sub>2</sub>	204,53	27,50	67,16	299,19
B <sub>2</sub>	202,43	27,53	65,49	295,45
<b>C<sub>2</sub></b>	<b>201,07</b>	<b>27,72</b>	<b>60,92</b>	<b>289,71</b>
D <sub>2</sub>	204,17	27,55	59,19	290,92
E <sub>2</sub>	224,09	27,55	55,92	307,57
A <sub>3</sub>	201,47	27,67	59,55	288,68
<b>B<sub>3</sub></b>	<b>201,47</b>	<b>27,71</b>	<b>54,27</b>	<b>283,45</b>
C <sub>3</sub>	202,00	27,61	63,88	293,49
D <sub>3</sub>	202,94	27,68	58,81	289,43
E <sub>3</sub>	202,94	27,72	53,74	284,40
A <sub>4</sub>	202,10	27,61	60,57	290,27
B <sub>4</sub>	202,00	27,60	60,22	289,82
C <sub>4</sub>	202,00	27,61	63,88	293,49
<b>D<sub>4</sub></b>	<b>202,38</b>	<b>27,60</b>	<b>57,30</b>	<b>287,28</b>
E <sub>4</sub>	202,94	27,57	63,61	294,12
A <sub>5</sub>	202,00	27,61	63,88	293,49
B <sub>5</sub>	202,66	27,42	66,11	296,19
<b>C<sub>5</sub></b>	<b>205,09</b>	<b>27,58</b>	<b>59,76</b>	<b>292,43</b>
D <sub>5</sub>	203,25	27,47	63,00	293,72
E <sub>5</sub>	204,80	27,31	65,77	297,88

Tabela 5. Plano Ótimo de Expansão – Sequência B<sub>3</sub>.

Ano	Circuitos Adicionados							Custo Anual (10 <sup>6</sup> R\$)		
	2	3	5	7	8	9	10	INV.	PERDAS	LOLC
8	0	0	0	0	1	0	1	35,00	7,39	27,26
7	0	0	1	0	1	1	0	100,00	6,47	18,20
6	1	0	0	1	0	0	0	50,00	6,31	11,65
5	1	1	0	0	0	0	0	45,00	5,57	11,12
4	0	0	0	0	0	1	0	40,00	4,83	10,50
3	1	1	0	0	0	0	0	45,00	4,31	4,69
2	0	1	0	0	0	0	0	20,00	3,37	5,65
1	0	0	0	0	0	0	0	0,00	2,67	3,55
0	0	0	0	0	0	0	0	0,00	2,17	0,14
<b>Valor Presente Total (10<sup>6</sup> R\$) =</b>								<b>201,47</b>	<b>27,71</b>	<b>54,27</b>

## 5.0 - CONCLUSÃO

Nos últimos anos, várias metaheurísticas têm sido propostas para resolver o problema do planejamento da expansão da transmissão (PET), considerando apenas um estágio, dado pelo ano horizonte. Até mesmo neste caso, o problema é extremamente complexo, e várias simplificações foram empregadas, como a desconsideração de incertezas. Uma outra característica importante do problema PET é a sua natureza dinâmica, o que requer a consideração de múltiplos estágios de tempo, para que sejam determinadas as seqüências de alocação de reforços ao longo do horizonte de planejamento.

Este artigo apresentou uma nova metodologia para a aplicação de Estratégias de Evolução no planejamento da expansão da transmissão, considerando a sua natureza dinâmica, o valor da confiabilidade e os custos de perdas. O algoritmo proposto foi aplicado, com sucesso, em estudos envolvendo um sistema teste e um sistema da CEMIG. Nestes estudos foi possível observar que os efeitos da confiabilidade e das perdas no desempenho das seqüências de expansão são bastante relevantes e, em muitos casos, são decisivos na escolha do melhor plano. Além disto, os resultados obtidos apontam que, ao se assegurar um bom desempenho em termos de confiabilidade, é possível obter uma melhor continuidade da solução após o horizonte de planejamento. Novos estudos, aplicados a um outro sistema da CEMIG, de maior porte, estão em andamento e os resultados obtidos têm sido muito favoráveis em termos da qualidade da solução e do tempo de computação correspondente.

## 6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- [1] L.L. Garver, "Transmission network estimation using linear programming", *IEEE Trans. on PAS*, Vol. 89, Nº 7, Sept. 1970.
- [2] M. Munasinghe, "A new approach to power system planning", *IEEE Trans. on PAS*, Vol. 99, May/June 1980.
- [3] B.G. Gorenstin, N.M. Campodonico, J.P. Costa, M.V.F. Pereira, "Power system expansion planning under uncertainty", *IEEE Trans. on Power Systems*, Vol.8, Nº 1, Feb. 1993.
- [4] G. Latorre, R.D. Cruz, J.M. Areiza, A. Villegas, "Classification of Publications and Models on Transmission Expansion Planning", *IEEE Trans. on Power Systems*, Vol. 18, No. 2, pp. 938 – 946, May 2003.
- [5] R.A. Gallego, A.B. Alves, A. Monticelli, R. Romero, "Parallel simulated annealing applied to long term transmission network expansion planning", *IEEE Trans. on Power Systems*, Vol. 12, pp. 181-187, Feb. 1997.
- [6] R.A. Gallego, R. Romero, A. Monticelli, "Tabu search algorithm for network synthesis", *IEEE Trans. on Power Systems*, Vol. 15, No. 2, pp. 490-495, May 2000.
- [7] A.H. Escobar, R.A. Gallego, R. Romero, "Multistage and coordinated planning of the expansion of transmission systems", *IEEE Trans. on Power Systems*, Vol. 19, No. 2 , pp. 735-74, May 2004.
- [8] S. Binato, G.C. Oliveira, J.L. Araújo, "A greedy randomized adaptive search procedure for transmission expansion planning", *IEEE Trans. on Power Systems*, Vol. 16, No. 2, pp. 247-253, May 2001.
- [9] L.S. Rezende, A.M. Leite da Silva, L.A.F. Manso, W.S. Sales, L.C. Resende, "Planejamento da Expansão da Transmissão Utilizando Colônia de Formigas", XVI CBA - Congresso Brasileiro de Automática, Salvador, CD-ROM, 3-6/Outubro, 2006.
- [10] A.M. Leite da Silva, W.S. Sales, L.C. Resende, L.A.F. Manso, C.E. Sacramento, L.S. Rezende, "Evolution strategies to transmission expansion planning considering unreliability costs", Proceedings of the 9<sup>th</sup> PMAPS – Probabilistic Methods Applied to Power Systems, Estocolmo, Suécia, 11-15/Junho 2006.
- [11] J.R.P. Barros, A.C.G. Melo, A.M. Leite da Silva, "An approach to the explicit consideration of unreliability costs in transmission expansion planning", Proceedings of the 8<sup>th</sup> PMAPS – Probabilistic Methods Applied to Power Systems, Ames, USA, Sept. 2004.
- [12] K.Y. Lee, M.A. El-Sharkawi (Editors), "Tutorial on modern heuristic optimization techniques with applications to power systems", IEEE PES, IEEE Pub. No. 02TP160, Jan. 2002.
- [13] A.M. Leite da Silva, L.A.F. Manso, J.C.O. Mello, R. Billinton, "Pseudo-chronological simulation for composite reliability analysis with time varying loads", *IEEE Trans. on Power Systems*, Vol. 15, No. 1, pp. 73-80, Feb. 2000.
- [14] L.A.F. Manso and A.M. Leite da Silva, "Probabilistic criteria for power system expansion planning", *Electric Power Systems Research*, Vol. 69, No. 1, pp. 51-58, April 2004.
- [15] H.-P. Schwefel, G. Rudolph, "Contemporary evolution strategies" in F. Morán, A. Moreno, J.J. Merelo and P. Chacón, eds., "Advances in Artificial Life, 3rd Int. Conference on Artificial Life, Vol. 929 of Lecture Notes in Artificial Intelligence, Springer, Berlin, pp. 893-907, 1995.
- [16] A.J. Monticelli, "Fluxo de Carga em Redes de Energia Elétrica", Edgard Blücher, São Paulo, 1983.
- [17] IEEE APM Subcommittee, "IEEE reliability test system", *IEEE Trans. on PAS*, Vol. PAS-99, pp. 2047-2054, Nov/Dec. 1979.