

ALGORITMO EVOLUTIVO ADAPTATIVO VIA MULTIOPERADORES APLICADO AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

MURIELL R. FREIRE¹, ARMANDO M. LEITE DA SILVA², LEONARDO M. HONÓRIO³, FERNANDO A. ASSIS²

¹Instituto Federal de São Paulo, Campus São João da Boa Vista, SP, Brasil

²Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, RJ, Brasil

³Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, Brasil

E-mails: muriell@ifsp.edu.br, armando@ele.puc-rio.br,
leonardo.honorio@ufjf.edu.br, fernandoassis@ufsj.edu.br

Abstract— This paper proposes a new evolutionary algorithm to solve the transmission expansion planning problem in electric power systems. In order to increase the robustness of the search process and to facilitate its use by planners on different systems and operation conditions, the algorithm uses multi-operators and a mechanism for dynamic adaptation of the selection probabilities of the operators. Two sets of search operators are tested: evolutionary and specialized. The problem formulation considers a DC network model, including the transmission losses, and a relaxed version for the “N-1” security criterion. The proposed method is applied to the IEEE RTS-79 test system and the associated results are adequately discussed.

Keywords— Evolutionary algorithms, multi-operators, adaptive operators selection, transmission expansion planning.

Resumo— Este trabalho propõe um novo algoritmo evolutivo para solução do problema de planejamento da expansão da transmissão em sistemas elétricos de potência. Visando aumentar a robustez do processo de busca e facilitar sua utilização por planejadores em diferentes sistemas e condições de operação, o algoritmo proposto utiliza multioperadores e um mecanismo para adaptação dinâmica das probabilidades de seleção dos mesmos. Dois conjuntos de operadores de busca são testados: evolutivos e especialistas. A formulação do problema considera um modelo de rede DC, incluindo as perdas de transmissão, e uma versão relaxada do critério de segurança “N-1”. O método proposto é aplicado ao sistema teste IEEE RTS-79 e os resultados obtidos são amplamente discutidos.

Palavras-chave— Algoritmos evolutivos, multioperadores, planejamento da expansão da transmissão, seleção adaptativa de operadores.

1 Introdução

A partir de um cenário futuro de demanda e geração de energia elétrica, o principal objetivo do Planejamento da Expansão da Transmissão (PET) é encontrar o melhor conjunto de reforços para o sistema de transmissão que garanta um adequado fornecimento de energia aos consumidores. Assim, a solução de um problema PET estático deve especificar onde e quantos equipamentos de transmissão devem ser instalados na rede elétrica, de forma a satisfazer as necessidades do mercado de energia. Contudo, além de possuir o menor custo de investimento possível, a solução de um problema PET real deve atender a certas especificações de qualidade e segurança nos serviços (Leite da Silva *et al.*, 2011).

Tradicionalmente, de forma a garantir os critérios de segurança, os problemas PET têm sido resolvidos através de modelos determinísticos tais como os conhecidos “N-1” e “N-2” (Leite da Silva *et al.*, 2011). Em muitos casos, entretanto, o plano obtido por estes modelos pode levar a altos custos de investimento. Por outro lado, embora modelos probabilísticos sejam capazes de medir adequadamente a qualidade de um sistema de transmissão (Manso e Leite da Silva, 2004), ainda não existe uma definição de quanto confiável um sistema deve ser baseado em índices de confiabilidade tais como LOLE, EPNS, e LOLC, principalmente porque estes índices são dependentes do modelo de carga. Uma vez que as companhias elétricas não chegam a um consenso sobre este assunto, os modelos determinísticos têm sido preferidos em relação aos probabilísticos.

Atualmente, a resolução de problemas PET para sistemas de transmissão reais é uma tarefa de otimização combinatória estocástica altamente complexa. Devido às grandes dimensões dos atuais sistemas, ao mercado de energia competitivo e às incertezas envolvidas na modelagem (e.g., crescimento da carga e da geração, novos tipos e a localização de geradores, comportamento aleatório dos equipamentos de transmissão e geração, etc.), a solução ótima do PET se torna quase inacessível. Mesmo quando as incertezas são desconsideradas, a complexidade em termos de dados, modelos e custo computacional ainda se mostra bastante elevada, especialmente se a cronologia da adição dos reforços é considerada (Leite da Silva *et al.*, 2011).

Técnicas de otimização baseadas em metaheurísticas têm demonstrado ser uma excelente ferramenta na resolução de problemas PET para sistemas de médio e grande porte, encontrando soluções de alta qualidade com um custo computacional relativamente baixo (Leite da Silva *et al.*, 2011). A grande vantagem destas técnicas é a capacidade de realizar busca global, evitando ótimos locais e explorando eficientemente o espaço de busca do problema. Diversos algoritmos têm sido propostos para o problema PET, como por exemplo: *Genetic Algorithms* (GA) (Silva *et al.*, 2005; Sousa e Asada, 2015), *Evolution Strategies* (ES) (Leite da Silva *et al.*, 2006), *Differential Evolution* (DE) (Dong *et al.*, 2006), *Artificial Immune Systems* (AIS) (Rezende *et al.*, 2009), e *Adaptive Evolutionary Systems* (AES) (Leite da Silva *et al.*, 2016). Metaheurísticas baseadas nos GA, ES, DE, AIS e AES fazem parte da família dos Algoritmos Evolutivos (EA), pois utilizam algum método probabilístico

para simular o processo de evolução natural das espécies (Eiben e Smith, 2003).

Apesar do sucesso que os EAs têm demonstrado na resolução de problemas complexos de otimização, o desempenho computacional destes métodos depende fortemente do ajuste correto dos parâmetros de controle e mecanismos de funcionamento, tais como: tamanho da população, tipo dos operadores de busca e suas respectivas taxas de aplicação, estratégia de seleção e substituição, etc. (Eiben e Smith, 2003). Particularmente em relação às probabilidades de seleção e aplicação dos operadores, além de ser um trabalho demorado e tedioso, o ajuste correto exige que os usuários já possuam alguma experiência com EAs e também algum conhecimento sobre o problema a ser resolvido (Silva *et al.*, 2014).

Dado que cada operador de busca encapsula uma determinada estratégia, manter um conjunto de operadores diversificados num mesmo algoritmo contribui para a robustez do processo de busca; o algoritmo será capaz de resolver uma maior quantidade de problemas. A decisão de quais operadores de busca devem ser utilizados e com qual taxa de seleção é um desafio no desenvolvimento dos EAs, o que tem incentivado a pesquisa de técnicas e estratégias adaptativas para os parâmetros de controle (Thierens, 2005; Gong, 2011). Neste sentido, a principal justificativa para a adaptação dinâmica das probabilidades de seleção dos operadores é que, dentre os operadores utilizados pelo EA, o operador ótimo depende do tipo do problema a ser resolvido e do estágio em que se encontra o processo evolutivo. Além disso, a adaptação dos parâmetros de um EA facilita sua utilização por um usuário inexperiente (Silva *et al.*, 2014).

Este trabalho propõe uma nova metaheurística para resolução de problemas PET estáticos e de longo prazo. Baseada nos conceitos dos EAs, o algoritmo proposto utiliza multioperadores de busca e um mecanismo de adaptação dinâmica das probabilidades de seleção e aplicação destes operadores. Dois conjuntos de operadores estocásticos são utilizados: evolutivos e especialistas. A formulação matemática adotada para o PET inclui a definição de um problema de programação linear (PL), baseado no modelo de fluxo DC com perdas, e um algoritmo para avaliação do critério de segurança “N-1”, utilizado para garantir certo nível de segurança do sistema. O desempenho do algoritmo proposto é avaliado através de sua aplicação na resolução de problemas PET para o sistema teste IEEE RTS-79.

2 Formulação do Problema PET

A abordagem adotada para o PET é baseada nas modelagens estática e determinística (Leite da Silva *et al.*, 2011): dado um horizonte de planejamento com um único estágio e uma previsão para a geração e a demanda de energia, determinam-se quais ramos do sistema devem ser reforçados e quantos reforços devem ser adicionados. Tradicionalmente, o problema PET utilizando o modelo de rede DC é definido como um problema de programação não linear inteiro

misto (PNLIM). Contudo, visando sua resolução através de um EA, o problema original é desacoplado em dois subproblemas: subproblema de investimento (SPI) e subproblema de operação (SPO).

2.1 Subproblema de Investimento

Os reforços são equipamentos a serem construídos/instalados no sistema e não podem ser fracionados, motivo pelo qual as variáveis de um plano de expansão candidato n devem assumir apenas valores inteiros. Logo, o SPI é classificado com um problema de otimização combinatória e restrito, onde o objetivo é encontrar um plano de expansão ótimo que minimize o custo do investimento e atenda completamente demanda futura por energia, tanto para a rede intacta como para em caso de contingência simples. Desta forma, o SPI é definido como:

$$\text{Minimizar:} \quad f(n) = \sum_{(i-j) \in \Omega} c_{ij} n_{ij} \quad (1)$$

$$\text{Sujeito a:} \quad \begin{cases} cc(n) = 0 \\ sc(n) = 0 \\ 0 \leq n_{ij} \leq n_{ij, \max} \end{cases} \quad (2)$$

onde o plano n é um vetor de números inteiros e seu elemento n_{ij} representa o número de reforços adicionados ao ramo $i-j$; $f(n)$ é a função objetivo do problema (custo do investimento); c_{ij} é o custo unitário para adição de reforços ao ramo $i-j$; Ω é o conjunto de todos os nl ramos candidatos a expansão; $n_{ij, \max}$ é o número máximo permitido para adição de reforços ao ramo $i-j$; $cc(n)$ é o total de corte de carga para a rede intacta; e $sc(n)$ será definido na Subseção 2.3.

2.2 Subproblema de Operação

Para um dado plano de expansão n , o SPO é definido como um problema PL cujo objetivo é encontrar o despacho econômico dos geradores, minimizando o custo operacional do sistema (custo da geração mais custo do corte de carga), $c_{op}(n)$, tal que:

$$\text{Minimizar:} \quad c_{op}(n) = \sum_{k \in T} (\gamma_k g_k + \lambda_k r_k) \quad (3)$$

$$\text{Sujeito a:} \quad \begin{cases} g + r + B\theta = d \\ |f_{ij}| \leq (n_{ij}^0 + n_{ij}) f_{ij, \max} \\ g_{\min} \leq g \leq g_{\max} \\ 0 \leq r \leq d \end{cases} \quad (4)$$

onde g é o vetor de despacho e seu elemento g_k é o valor da geração na barra k ; r é o vetor de geradores fictícios e seu elemento r_k representa o valor do corte de carga na barra k , tal que: $cc(n) = \Sigma(r_k)$; B é a matriz de susceptância; θ é o vetor de ângulos das tensões nodais e seu elemento θ_k é o ângulo na barra k ; d é o vetor de demanda e seu elemento d_k é a carga da barra k ; f_{ij} é o fluxo de potência ativa total do ramo $i-j$, dado por: $f_{ij} = (\theta_i - \theta_j)/x_{ij}$; x_{ij} é a reatância equivalente do ramo $i-j$; $f_{ij, \max}$ é a capacidade máxima de um simples elemento do ramo $i-j$; n_{ij}^0 é o número

elementos no ramo $i - j$ presentes no caso base; g_{max} e g_{min} são os valores de capacidade máxima e mínima dos geradores; γ_k e λ_k são, respectivamente, o custo de geração e o custo do corte de carga para a barra k ; e Γ é o conjunto de todas as nb barras ativas do sistema.

De forma a considerar as perdas ôhmicas da transmissão no SPO, um modelo especial de fluxo de potência DC é utilizado (Leite da Silva *et al.*, 2011). Basicamente, as perdas são calculadas a partir do vetor θ obtido com a solução do SPO para uma dada configuração n . Posteriormente, estas perdas são distribuídas como cargas fictícias, onde para cada ramo ativo do sistema (i.e., ramo que possui pelo menos um elemento), as barras i e j recebem metade das perdas estimadas para o circuito $i - j$ que as conecta. Em seguida, um novo SPO é resolvido considerando esta nova carga: um novo vetor θ é encontrado, o qual corresponde à solução final de rede intacta para o plano n . A inclusão das perdas na modelagem do SPO visa prover mais precisão à análise do fluxo de potência, gerando assim mais benefícios para os aspectos operativos da rede elétrica, como o nível de carregamento dos circuitos.

2.3 Critério de Segurança “N-1”

O objetivo do problema PET não é somente obter um plano que minimize os custos de investimento, mas também garantir um adequado nível de qualidade de energia aos consumidores. Neste sentido, o critério determinístico “N-1” define que o sistema deve suportar a remoção ou contingência simples de qualquer elemento de transmissão, mantendo o fornecimento de energia aos consumidores e sem qualquer sobrecarga nos equipamentos da rede. A estratégia adotada neste trabalho é considerar o “N-1” como uma restrição durante todo o processo de otimização, onde os melhores planos encontrados não têm somente que satisfazer o critério de rede intacta, mas também ao “N-1”. Entretanto, observa-se que para sistemas de grande porte esta estratégia demanda um elevado esforço computacional (Leite da Silva *et al.*, 2011).

No cálculo do nível total de sobrecarga $sc(n)$ para o critério “N-1”, cada ramo ativo $i - j$ na rede intacta deve ter um de seus elementos removidos, de forma que o valor de $sc(n)$ é obtido somando-se, ramo a ramo, a sobrecarga total $sc_{ij}(n)$ obtida após a contingência $i - j$; $sc_{ij}(n)$ é obtido a partir da solução encontrada para a rede intacta: 1) atualiza-se a matriz B para a contingência no ramo $i - j$; 2) resolve-se um fluxo DC utilizando o vetor de despacho g encontrado para o SPO (rede intacta); e 3) para cada ramo deste novo sistema, verifica-se a ocorrência de sobrecarga, acumulando-se em $sc_{ij}(n)$ os valores de sobrecarga gerada pela contingência $i - j$. Assim, $sc(n)$ irá depender dos reforços presentes no plano n e deverá ser nulo quando o plano satisfizer o critério “N-1”.

Para sistemas reais, sabe-se que, após uma contingência, é permitido que alguns equipamentos continuem a operar sobrecarregados por um determinado tempo, desde que essa sobrecarga não ultrapasse um determinado limite e não permaneça por um longo período

de tempo. Desta forma, visando reduzir o custo dos planos encontrados para o PET com o critério “N-1”, no cálculo de $sc(n)$, despreza-se sobrecargas que sejam inferiores a um determinado limite máximo sc_{max} . Por exemplo, considerando um $sc_{max} = 10\%$, após uma contingência simples no sistema, apenas as sobrecargas superiores a 10% da capacidade máxima do equipamento serão consideradas no cálculo de $sc(n)$.

3 Algoritmo Proposto

O algoritmo proposto para resolução do PET está baseado no AES (Leite da Silva *et al.*, 2016): EA utilizando múltiplos operadores de busca e um mecanismo dinâmico para adaptação das probabilidades de seleção destes operadores. Cada indivíduo da população representa uma possível solução para o problema (plano de expansão). A codificação do indivíduo é feita através de um vetor inteiro, com dimensão igual ao número de ramos candidatos a expansão. A avaliação de aptidão é feita através do SPI (Eqs. 1 e 2); para manusear as restrições de igualdade utiliza-se o método de comparação lexicográfica ε -constrained. Cada gene n_{ij} do indivíduo n representa o número de reforços adicionados ao ramo $i - j$, podendo variar de zero até um número máximo $n_{ij,max}$. Assim, de acordo com a Figura 1, a partir de um conjunto com K operadores (evolutivos ou especialistas), definem-se os passos do algoritmo proposto (AES-PET) como:

1) Gere uma população Pop com N_{pop} indivíduos, inicializados de forma totalmente aleatória; avalie e ordene a Pop inicial em função das aptidões dos indivíduos; o indivíduo incumbente n_{bs} é definido como o melhor indivíduo da Pop atual;

2) Inicialize as variáveis de controle do mecanismo de seleção adaptativa de operadores (*Adaptive Pursuit* - AP) (Thierens, 2005); os parâmetros α e β da AP deverão ser previamente ajustados pelo usuário; inicialize o contador de gerações t e o contador de gerações estagnadas q , tal que: $t = 0$ e $q = 0$;

3) Verifique o critério de parada do algoritmo: se $t > T_{max}$ (número máximo de gerações) ou $q > Q_{max}$ (número máximo de gerações sem melhora do n_{bs} , onde $Q_{max} = 0,2 \times T_{max}$), então o algoritmo será finalizado e as 10 melhores soluções encontradas para o problema serão apresentadas ao usuário; caso contrário, t será incrementado e o algoritmo seguirá ao próximo passo;

4) Realize um processo evolutivo com N_{pop} iterações, de forma que para cada iteração tem-se: a) sorteio do operador i em função da atual distribuição de probabilidades; b) seleção aleatória de um par de indivíduos distintos, n_{p1} e n_{p2} , da Pop atual; c) aplicação do operador i aos indivíduos n_{p1} e n_{p2} , resultando em um novo indivíduo n_F (filho); d) busca pelo indivíduo n_{pp} da Pop atual que esteja mais próximo de n_F (métrica: distância euclidiana); e) se n_F for diferente e melhor que o n_{pp} , então n_F substituirá n_{pp} na Pop ; caso contrário, n_F será descartado; f) atribuição de recompensa ao operador i , proporcional ao ganho de aptidão gerado por n_F em relação a n_{pp} ;




Figura 1. Fluxograma do algoritmo proposto para o PET.

5) Ordene a *Pop* atual em função das aptidões dos indivíduos; se o melhor indivíduo da *Pop* for melhor que o atual n_{bs} , então n_{bs} será atualizado e $q = 0$; caso contrário, o contador q será incrementado;

6) A cada duas gerações, execute a estratégia AP para adaptar as probabilidades de seleção dos operadores, retornando então ao passo 3).

3.1 Operadores Evolutivos

O grupo de operadores estocásticos chamado de Operadores Evolutivos (Evol) é formado pelas possíveis combinações dos operadores genéticos propostos por (Leite da Silva *et al.*, 2016), onde cada combinação utiliza um operador de recombinação (UNX, SPX, IRX ou LRX) associado a um de mutação (SWM, UNM ou BDM). Assim, Evol será composto de 12 operadores: UNX-SWM, UNX-UNM, UNX-BDM, SPX-SWM, SPX-UNM, SPX-BDM, etc. Estes operadores foram modificados de tal forma que, a partir de dois indivíduos pais, geram um único indivíduo filho.

3.2 Operadores Especialistas

Como o objetivo de aumentar a eficiência na busca pelas melhores soluções do PET, este trabalho utiliza o grupo dos Operadores Especialistas (Exp) propostos por (Leite da Silva *et al.*, 2016). Nestes operadores, heurísticas específicas de sistemas elétricos são utilizadas para guiar os mecanismos estocásticos de busca na identificação dos ramos mais interessantes para adição ou remoção de reforços (i.e.,

aqueles que produzirão impactos mais significativos sobre os aspectos operacionais do sistema). Dois índices de desempenho são utilizados: 1) Índice de abertura angular; e 2) Índice de carregamento. Para um determinado plano, ramos que possuem grandes valores para os índices de desempenho são bons candidatos para adição de reforços; por outro lado, ramos com pequenos valores são bons candidatos para remoção de reforços. Assim, o grupo Exp é composto pelas oito possíveis associações de um operador de mutação especialista (RMA, RMC, SMA ou SMC) com um operador genético de recombinação (UNX ou SPX): UNX-RMA, UNX-RMC, UNX-SMA, UNX-SMC, SPX-RMA, SPX-RMC, SPX-SMA e SPX-SMC.

4 Resultados para o IEEE RTS-79

Nesta seção apresentam-se os resultados obtidos com a aplicação do AES-PET em problemas PET para o sistema teste IEEE RTS-79 (IEEE, 1979). Este sistema é composto por 24 barras e 41 ramos candidatos à expansão (34 ramos existente na topologia base mais sete ramos novos), onde: cada ramo pode receber no máximo três reforços; a demanda total é de 8.550 MW; e a capacidade máxima de geração é de 10.215 MW (sistema modificado - Silva *et al.*, 2005). O algoritmo foi implementado na linguagem C# e utiliza a biblioteca GLPK para resolver os problemas de PL. Todos os tempos computacionais se referem a um CPU Intel Core i7-3770 (3.40GHz).

Para cada uma das versões testadas, realizou-se 100 execuções do algoritmo; uma execução é considerada como sucesso quando encontra pelo menos um dos 10 melhores planos conhecidos para o problema. Ao final de cada execução, calcula-se o índice de qualidade I_Q para o melhor indivíduo e para os 10 melhores indivíduos, tal que: $I_Q = 100\% \times (f_{gb} / f_{bs})$; onde f_{gb} é o custo do melhor plano conhecido; e f_{bs} é o custo do melhor plano ou o custo médio para os 10 melhores planos, encontrados pela execução. Assim, quatro índices foram adotados para avaliação do desempenho: a) I_Q , que é o índice médio de qualidade para a melhor solução; b) ITT , que é o índice médio de qualidade para as 10 melhores soluções; c) TS , que é a taxa de sucesso (relação percentual entre o número de execuções de sucesso e o número total de execuções) e d) TM , que é o tempo computacional médio demandado para a convergência do algoritmo (segundos).

4.1 Caso 1: PET com perdas e “N-1” a 0%

Neste caso, a modelagem do problema PET para o sistema IEEE RTS-79 considera as perdas na transmissão e o critério de segurança “N-1” sem relaxamento ($sc_{max} = 0\%$), que é a versão tradicional do critério. Os 10 melhores planos conhecidos para este caso estão apresentados na Tabela 1 (ordenados pelo valor das perdas). A Tabela 2 apresenta os resultados obtidos com versões distintas do AES-PET: a coluna “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos operadores especialistas (“Exp”); já na coluna “Adap”, “Não” indica o uso da versão estática

Tabela 1. Os 10 melhores planos conhecidos para o Caso 1.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	Total Refs.	Planos de Expansão - Reforços Adicionados por Ramo															
				3	4	6	10	11	14	15	16	17	18	20	33	39			
1	681	138,9	17	1	1	2	2	3		1	2		2	1	1	2			
2	681	139,0	17	1	1	2	2	3		1	1	1	1	1	1	2			
3	681	139,0	17	1	1	2	2	3	1		2	1	1	1	1	2			
4	681	139,2	17	1	1	2	2	3	1		2		2			1			
5	681	139,2	17	1	1	2	2	3	1		1	1	2			1			
6	681	139,2	17	1	1	2	2	3		1	2		2			1			
7	681	139,4	17	1	1	2	2	3	1		1	1	1	1	1	2			
8	681	139,5	17	1	1	2	2	3		1	2			1	1	1			
9	681	139,8	17	1	1	2	2	3		1	1	1		2	1	2			
10	681	139,9	17	1	1	2	2	3	1		2		2	1	1	2			

Tabela 2. Comparação entre as versões Adaptativa e Estática com operadores Evolutivos ou Especialistas – Caso 1 ($sc_{max} = 0\%$).

N_{Pop}	Ops	Adap	IQ(%)	ITT(%)	TS(%)	TM(s)
100	Evol	Não	92,87	88,08	8,00	62,85
		Sim	93,35	89,21	4,00	61,22
	Exp	Não	99,34	96,76	79,0	55,03
		Sim	99,80	97,99	94,0	49,60
200	Evol	Não	93,67	89,49	6,00	125,4
		Sim	95,48	91,35	17,0	123,0
	Exp	Não	99,83	98,09	91,0	108,3
		Sim	100,0	99,11	99,0	96,42

(sem adaptação de probabilidades), e “Sim” indica o uso da versão adaptativa, onde os parâmetros $\alpha = 0,25$ e $\beta = 0,50$ (estratégia AP). Para todas as versões utilizou-se: dois tamanhos de população, $N_{Pop} = 100$ ou 200, inicialização aleatória dos indivíduos, e número máximo de gerações $T_{max} = 300$.

Na Tabela 2 pode-se observar a superioridade da versão AES-PET utilizando os operadores especialistas, com resultados significativamente melhores que os obtidos com o uso dos operadores evolutivos: soluções de melhor qualidade, a um custo computacional inferior. Pode-se observar ainda que, na maioria dos casos, a utilização da estratégia adaptativa (“Adap = Sim” – estratégia AP) gera uma redução do custo computacional do algoritmo (redução do TM) e melhora da qualidade das soluções encontradas (aumenta IQ , ITT e TS). Além disso, independentemente da versão do algoritmo, pode-se observar que o aumento do tamanho da população melhora a qualidade das soluções e, consequentemente, aumenta o custo computacional (avaliações adicionais são realizadas). No gráfico de convergência da Figura 2 apresenta-se uma comparação entre versões AES-PET adaptativas via multioperadores (“Evol” ou “Exp”, onde $\alpha = 0,25$ e $\beta = 0,50$) e versões AES-PET estáticas com um único operador (vide Subseções 3.1 e 3.2). Estas versões estáticas são equivalentes aos tradicionais EAs utilizando um único operador de busca: e.g., a versão “SPX-UNM” pode ser comparada ao GA proposto por (Silva *et al.*, 2005), e a versão “SPX-SWM” ao GA proposto por (Sousa e Asada, 2015). Em todas as versões, utiliza-se $N_{Pop} = 100$ e $T_{max} = 300$. Pode-se observar neste gráfico que a versão “Exp” apresentou o melhor desempenho entre todas as versões testadas, indicando assim que existe vantagem na utilização de multioperadores de busca em um único EA.




Figura 2. Comparação entre versões adaptativas multioperadores e versões estáticas com um único operador – Caso 1 ($sc_{max} = 0\%$).

4.2 Caso 2: PET com perdas e “N-1” a 10%

Para este caso, a modelagem para o PET do sistema IEEE RTS-79 considera as perdas ôhmicas e o critério de segurança “N-1” relaxado a 10% ($sc_{max} = 10\%$). A Tabela 3 apresenta os 10 melhores planos conhecidos para este problema, ordenados pelo custo de investimento: pode-se observar que, em relação ao Caso 1, houve redução de até 19% no custo de investimento. De maneira análoga à Tabela 2, a Tabela 4 apresenta os resultados obtidos com a aplicação do algoritmo AES-PET para o Caso 2 (parâmetros: $\alpha = 0,25$; $\beta = 0,50$; $N_{Pop} = 100$ ou 200; e $T_{max} = 300$). Novamente, pode-se observar a superioridade da versão AES-PET utilizando os operadores especialistas: grande ganho de eficiência computacional. Ademais, pode-se notar que, em todos os casos, a utilização da estratégia adaptativa melhora a eficiência do algoritmo, reduzindo o custo computacional e aumentando a qualidade das soluções encontradas.

Semelhante ao gráfico da Figura 2, a Figura 3 apresenta um gráfico de convergência para o Caso 2, comparando versões AES-PET adaptativas multioperadores (com $\alpha = 0,25$ e $\beta = 0,50$) e versões AES-PET estáticas com um único operador. Todas as versões utilizam $N_{Pop} = 100$ e $T_{max} = 300$. Outra vez, os resultados indicam que a utilização de multioperadores em um único EA, juntamente com uma estratégia adaptativa AP, gera melhoras na eficiência computacional do algoritmo, especialmente para a versão utilizando os operadores especialistas.

5 Conclusões

Neste trabalho, um algoritmo evolutivo adaptativo via multioperadores (AES-PET) é proposto e aplicado a problemas de planejamento da expansão da transmissão (PET) para o sistema teste IEEE RTS-79. A formulação do PET considera um modelo DC com perdas e uma versão relaxada para o critério de segurança “N-1”. Os resultados obtidos indicam que existe grande vantagem na utilização de vários operadores de busca em um único algoritmo evolutivo, aumentando a robustez do processo de busca. A utilização de um mecanismo para adaptação para as probabilidades de seleção dos operadores pode melhorar a eficiência do algoritmo, reduzindo o custo computacional.

Tabela 3. Os 10 melhores planos conhecidos para o Caso 2.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	Total Refs.	Planos de Expansão - Reforços Adicionados por Ramo																		
				3	4	6	7	8	9	10	11	15	16	17	18	20	23	26	33	38	39	
1	551	148,5	14	1	1					2	3		1		1			1	1	1	1	
2	589	158,8	15	1	1	2				2	3	1		1	2				1	1		
3	591	154,4	16	1	1	2	1			2	3	1		1		1			1	1	1	
4	591	158,3	16		1	1			1	2	3		2	1	1				2	1	1	
5	594	155,0	16		2	1	1			1	2	3		2		1			1	1	1	
6	596	165,0	16	2		1	1	1		2	3	1		1				1	2	1		
7	597	165,1	17	2		1	1	1		2	3		1		1			2	2	1		
8	598	150,3	16	2		1	1	1		2	3	1		1				1	1	1	1	
9	599	150,4	16	1	1	2				2	3	2		2		1			1	1		
10	599	150,7	16	1	1	2				2	3	1	1		1	1	1				1	

Tabela 4. Comparação entre as versões Adaptativa e Estática com operadores Evolutivos ou Especialistas – Caso 2 ($sc_{max} = 10\%$).

N _{Pop}	Ops	Adap	IQ(%)	ITT(%)	TS(%)	TM(s)
100	Evol	Não	92,38	86,21	40,0	61,03
		Sim	93,95	87,59	54,0	59,49
	Exp	Não	98,85	91,53	85,0	54,04
		Sim	99,26	91,86	99,0	45,11
200	Evol	Não	95,23	88,54	46,0	123,8
		Sim	96,47	89,63	65,0	119,7
	Exp	Não	99,55	92,11	90,0	103,3
		Sim	99,79	92,43	99,0	88,00

cional e aumentando a qualidade dos planos de expansão encontrados. Além disso, os resultados indicam que o uso dos operadores especialistas proporciona uma eficiência computacional muito superior aos tradicionais operadores evolutivos: a utilização de heurísticas específicas de sistemas elétricos, incorporadas aos operadores estocásticos, parece ser uma estratégia bastante vantajosa na resolução de problemas PET. Futuramente, pretende-se avaliar o desempenho do AES-PET em problemas PET para sistemas reais de grande porte.

Agradecimentos

Os autores agradecem às agências CAPES e CNPq pelo apoio dado ao desenvolvimento deste trabalho, e ao Prof. Luiz Antonio da Fonseca Manso da UFSJ, MG, por sugestões nos modelos de otimização utilizados.

Referências Bibliográficas

- Dong, Z. Y., Lu, M., Lu, Z., Wong, e K. P. (2006). A differential evolution based method for power system planning. In Proc. IEEE Congress on Evolutionary Computation, CEC'06, p. 2699-2706.
- Eiben, A. E., e Smith, J. E. (2003). Introduction to evolutionary computing. Springer-Verlag, Berlin Heidelberg, v. 53.
- Gong, W., Fialho, A., Cai, Z., e Li, H. (2011). Adaptive strategy selection in differential evolution for numerical optimization: an empirical study. Information Sciences, v. 181, n. 24, p. 5364-5386.
- IEEE APM Subcommittee (1979). IEEE Reliability Test System. IEEE Transactions on Power Apparatus and Systems, v. 1, n. 6, p. 2047-2054.




Figura 3. Comparação entre versões adaptativas multioperadores e versões estáticas com um único operador – Caso 2 ($sc_{max} = 10\%$).

- Leite da Silva, A. M., Sales, W. S., Resende, L. C., Manso, L. A. F., Sacramento, C. E., e Rezende, L. S. (2006). Evolution strategies to transmission expansion planning considering unreliability costs. In Proc. Ninth Int. Conf. on Prob. Methods Applied to Power Systems, PMAPS'06, IEEE.
- Leite da Silva, A. M., Rezende, L. S., e Manso, L. A. F. (2011). Transmission Expansion Planning: A Methodology to Include Security Criteria and Uncertainties Using Optimization Techniques. In Innovations in Power Systems Reliability, p. 191-220, Springer London.
- Leite da Silva, A. M., Freire, M. R., e Honório, L. M. (2016). Transmission expansion planning optimization by adaptive multi-operator evolutionary algorithms. Electric Power Systems Research, v. 133, p. 173-181.
- Manso, L. A. F., e Leite da Silva, A. M. (2004). Probabilistic criteria for power system expansion planning. Electric Power Systems Research, v. 69, n. 1, p. 51-58.
- Rezende, L. S., Leite da Silva, A. M., e Honório, L. M. (2009). Artificial immune system applied to the multi-stage transmission expansion planning. In Artificial Immune Systems, Springer Berlin Heidelberg, p. 178-191.
- Silva, I. J., Rider, M. J., Romero, R., Garcia, A. V., e Murari, C. A. (2005). Transmission network expansion planning with security constraints. IEEE Proc. Generation, Transmission and Distribution, IET, v. 152, n. 6, p. 828-836.
- Silva, R. C., Lopes, R., Freitas, A. R., e Guimaraes, F. G. (2014). A study on self-configuration in the differential evolution algorithm. In IEEE Symposium on Differential Evolution (SDE), p. 1-8.
- Sousa, A. S., e Asada, E. N. (2015). Long-term transmission system expansion planning with multi-objective evolutionary algorithm. Electric Power Systems Research, v. 119, p. 149-156.
- Thierens, D. (2005). An adaptive pursuit strategy for allocating operator probabilities. In Proc. of the 7th Conf. on Genetic and Evolutionary Computation, ACM, p. 1539-1546.