

# Fluxo de Potência Ótimo com Restrições de Segurança via Algoritmos de Otimização Natural Multiobjetivos

V.H. Ferreira, R.C. Freire

Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações (PPGEET - UFF)  
Niterói, Brazil

vitor@vm.uff.br, renefreire@ig.com.br

**Resumo--** A obtenção de um ponto de operação seguro em um sistema elétrico de potência reside na definição de um conjunto de controles que otimiza determinados critérios ao mesmo tempo que garante a estabilidade do sistema durante cada contingência pré-estabelecida. Trata-se de um problema que pode ser descrito como um caso de abordagem multiobjetiva do Fluxo de Potência Ótimo com Restrições de Segurança (FPORS). Este trabalho apresenta algoritmos de otimização natural multiobjetivos como uma ferramenta para obter esse ponto de operação seguro sob o ponto de vista estático. Os métodos foram implementados em MATLAB® e testados utilizando dados de um sistema-teste que simula as condições do Sistema Interligado Nacional.

**Palavras-chave--**fluxo de potência ótimo com restrições de segurança, despacho seguro e econômico, otimização natural multiobjetivo, algoritmo NSGA-II, algoritmo MOEPSO.

## I. INTRODUÇÃO

A Operação econômica e segura de sistemas elétricos de potência é um dos principais objetivos dos responsáveis pela operação desses sistemas. No caso do Brasil, a missão do Operador Nacional do Sistema Elétrico (ONS) é “operar o Sistema Interligado Nacional de forma integrada, com transparência, equidade e neutralidade, de modo a garantir a segurança, a continuidade e a economicidade do suprimento de energia elétrica do país” [1]. Neste contexto, ferramentas computacionais de análise, controle e otimização de sistemas elétricos de potência são necessárias para a definição de estratégias operacionais seguras e econômicas.

Os estudos para avaliar a segurança do sistema de potência podem ser divididos em dois grupos principais, baseados na escala de tempo dos eventos: análise de segurança estática e dinâmica. A análise de segurança estática avalia o estado operacional do sistema excluindo os eventos transitórios envolvidos na ocorrência de cada contingência. Estes estudos consideram o desempenho da rede no estado estacionário após a perturbação. Já a análise de segurança dinâmica considera a evolução temporal do estado operacional do sistema,

avaliando principalmente questões relativas à estabilidade da rede. Existem vários estudos sobre a análise de segurança estática ([2]-[5]) e dinâmica ([6]-[8]). As principais questões e ferramentas envolvidas na análise de segurança de sistemas de potência são discutidas em [3], [4] e [9].

A determinação de um ponto de operação ótimo e seguro consiste na definição de um conjunto de controles que minimize um dado critério de operação (por exemplo, custos de operação) enquanto garante o funcionamento dos equipamentos da rede dentro de seus limites operativos. Este problema pode ser formulado como um caso de otimização conhecido como Fluxo de Potência Ótimo com Restrições de Segurança (FPORS) [4], com vários métodos clássicos de solução propostos na literatura, tais como: Programação Não-Linear ([4] e [10]) e Algoritmo dos Pontos Interiores ([11]-[13]). Apesar dos resultados satisfatórios, os métodos clássicos ainda apresentam algumas limitações, como a estagnação em mínimos locais em problemas de otimização não-convexas [5]. Técnicas de inteligência computacional inspiradas na natureza, como algoritmos genéticos [5] e otimização por enxame de partículas [6], foram anteriormente aplicadas como uma solução para o problema do FPORS com o objetivo de superar as desvantagens dos métodos clássicos.

Este trabalho tem como objetivo estudar algumas técnicas de otimização naturais (inspiradas na natureza) como uma alternativa para a obtenção do despacho seguro de sistemas de potência. As funções objetivo consideradas visam fornecer as alterações mínimas a serem realizadas em um dado ponto de operação para torná-lo seguro à luz de uma dada lista de contingências. Neste estudo apenas restrições de segurança estática serão consideradas, sendo relacionadas com os seguintes parâmetros: limites de fluxo de potência nas linhas de transmissão, magnitude de tensão nos barramentos e limites de geração.

## II. FLUXO DE POTÊNCIA ÓTIMO COM RESTRIÇÕES DE SEGURANÇA

Os estudos de Fluxo de Potência Ótimo (FPO) visam determinar um conjunto de controles para sistemas elétricos de potência que otimizem um dado critério ao mesmo tempo que respeitem uma série de restrições operacionais, tais como limites de geração, de magnitude de tensão e de carregamento das linhas de transmissão. Este problema de otimização, adaptado para o caso multiobjetivo, pode ser assim formulado:

$$\begin{aligned} \min_{\underline{x}} \left( \underline{f}(\underline{x}) = [f_1(\underline{x}), f_2(\underline{x}), \dots, f_{n_{obj}}(\underline{x})] \right) \quad (1) \\ \text{s. a. } \begin{cases} \underline{g}(\underline{x}) = [g_1(\underline{x}), g_2(\underline{x}), \dots, g_{n_{igual}}(\underline{x})] = \underline{0} \\ \underline{h}(\underline{x}) = [h_1(\underline{x}), h_2(\underline{x}), \dots, h_{n_{desig}}(\underline{x})] \geq \underline{0} \end{cases} \end{aligned}$$

Onde  $\underline{f}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$  são os  $n_{obj}$  critérios a serem otimizados,  $\underline{x} \in \mathbb{R}^n$  é o vetor com as  $n$  variáveis de controle a serem especificadas,  $\underline{g}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$  são as  $n_{igual}$  restrições de igualdade e  $\underline{h}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{desig}}$  são as  $n_{desig}$  restrições de desigualdade. Este conjunto de restrições inclui as equações de fluxo de potência e os limites operacionais a serem respeitados. A inclusão de restrições de segurança relacionados às contingências ocorridas no problema do FPO origina o chamado Fluxo de Potência Ótimo com Restrições de Segurança (FPORS) [14].

### A. Determinação do Despacho Seguro como um Problema de Fluxo de Potência Ótimo

Um ponto de operação é considerado seguro se, tanto para a rede completa quanto para uma lista de contingências, o suprimento de energia é assegurado sem violar limites operativos. A busca por este ponto de operação pode ser formulada como um problema de otimização, onde o objetivo é a especificação de um conjunto de controles que minimiza o número de restrições não atendidas, com o ponto de operação seguro sendo obtido quando todas as restrições são satisfeitas. Matematicamente, este problema pode ser formulado como segue:

$$\min_{\underline{x}} \sum_{i=1}^{N_{rest}} rest_i(\underline{x}) \quad (2)$$

Onde  $rest_i(\underline{x}): \mathbb{R}^n \rightarrow [0,1]$  é igual a zero se a  $i$ -ésima restrição for atendida e igual a um em caso contrário. Como a função objetivo dada em (2) não é continuamente diferenciável, métodos clássicos de programação não-linear não podem ser utilizados para resolver este problema. Considerando como variáveis de controle somente as tensões em barras de geração e os despachos de potência ativa, e como restrições os limites de carregamento em linhas de transmissão, os limites de geração de potência ativa e reativa das unidades geradoras, os limites de tensão nos barramentos e o comportamento em regime permanente da rede, a solução do problema formulado em (2) permite a obtenção de um ponto de operação seguro sob o ponto de vista de segurança estática.

Entretanto, a busca por um ponto de operação visando somente aspectos de segurança pode dar origem a despachos

que não atendam outros critérios, por exemplo, questões econômicas. Na verdade, segurança e economicidade constituem objetivos conflitantes que devem ser balanceados. Neste ponto é percebida a importância de uma abordagem multiobjetivo do problema do FPORS, que permite encontrar um ponto de operação seguro sem deixar de observar o quão custoso o mesmo pode ser. Considerando que o ponto de operação inicial do caso base (rede completa, sem contingências) foi previamente especificado via despacho econômico, ou seja, foi escolhido o despacho de menor custo dentre os possíveis, o problema de obtenção do despacho seguro pode ser reformulado da seguinte maneira:

$$\min_{\underline{x}} \left\{ F(\underline{x}) = [\Delta_{ponto}(\underline{x}), \Delta_{rest}(\underline{x}), \Delta_{conv}(\underline{x})]^T \right\} \quad (3)$$

Onde:

$$\Delta_{ponto}(\underline{x}) = \sum_{i=1}^{N_{cont}} \frac{|x_i - x_i^{esp}|}{x_i^{esp}} \quad (4)$$

$$\Delta_{rest}(\underline{x}) = \sum_{j=1}^{N_{rest}} \Omega_j(\underline{x}) \quad (5)$$

$$\Delta_{conv}(\underline{x}) = \sum_{k=1}^{N_{casos}} (2N - 1)c_k(\underline{x}) \quad (6)$$

Nas expressões acima,  $\Delta_{ponto}(\underline{x})$  representa o desvio percentual do novo ponto de operação  $\underline{x}$  em relação ao ponto de operação pré-especificado  $\underline{x}^{esp}$ . Uma vez estabelecida a premissa de que  $\underline{x}^{esp}$  é o ponto de operação de menor custo possível, é fácil perceber que quanto maior o desvio entre  $\underline{x}$  e  $\underline{x}^{esp}$ , maior é o custo do ponto de operação encontrado. Daí conclui-se que  $\Delta_{ponto}(\underline{x})$  é a função que indica o quão custoso é o ponto de operação  $\underline{x}$  encontrado.  $\Delta_{rest}(\underline{x})$  representa o desvio da variável monitorada em relação aos seus limites, sendo calculado como:

$$\Omega_j(\underline{x}) = \begin{cases} 0, w_j^{min}(\underline{x}) \leq w_j(\underline{x}) \leq w_j^{max}(\underline{x}) \\ \frac{|w_j(\underline{x}) - w_j^{lim}(\underline{x})|}{w_j^{lim}(\underline{x})}, \text{ caso contrário} \end{cases} \quad (7)$$

Onde  $w_j^{lim}(\underline{x})$  responde pelo limite violado, por exemplo,  $w_j^{lim}(\underline{x}) = w_j^{max}(\underline{x})$  se  $w_j(\underline{x}) \geq w_j^{max}(\underline{x})$ . Por fim,  $\Delta_{conv}(\underline{x})$  representa a penalidade atribuída devido à não-convergência do fluxo de potência para um determinado caso, com a função  $c_k(\underline{x})$  dada por:

$$c_k(\underline{x}) = \begin{cases} 0, & \text{ caso o fluxo de potência convirja} \\ 1, & \text{ caso contrário} \end{cases} \quad (8)$$

Assim, despachos onde o fluxo de potência não convirja para um determinado caso são considerados como violações de 100% das restrições de igualdade do problema original. Sua função é atribuir um alto valor de *fitness* para os casos divergentes, fazendo com que os mesmos sejam descartados ao longo das gerações do algoritmo evolutivo em questão, de modo que ao fim da execução hajam apenas soluções convergentes compondo a população final.

### III. OTIMIZAÇÃO NATURAL MULTI OBJETIVO

A função objetivo dada pela equação (3) utiliza a estratégia de combinar as avaliações de cada objetivo para obter uma avaliação global de cada solução. Dentre as formas de execução desta estratégia, destacam-se a agregação de objetivos e as soluções Pareto-ótimas.

Ao combinar as avaliações, a técnica de agregação de objetivos foge de um dos problemas fundamentais da otimização multiobjetivo: o fato de que nenhuma das soluções encontradas é melhor do que as demais com respeito a todos os objetivos. Para lidar apropriadamente com esse obstáculo, é necessário compreender a relação de dominância entre essas soluções. Uma solução  $x$  domina outra solução  $y$  se:

- Para nenhum objetivo é verificado que a avaliação de  $x$  seja pior que a avaliação de  $y$ .
- Para pelo menos um objetivo a avaliação de  $x$  é superior à avaliação de  $y$ .

O conjunto das soluções que não são dominadas por nenhuma outra solução é definido como conjunto Pareto-ótimo. Qualquer que seja o critério para a avaliação global, é garantido que a melhor solução fará parte desse conjunto.

Neste trabalho, é feita uma abordagem multiobjetivo baseada nas soluções Pareto-ótimas das técnicas de otimização natural, visando obter o despacho seguro e econômico de um determinado sistema de potência. As técnicas de otimização natural constituem uma linha de pesquisa da área de Inteligência Computacional que engloba um conjunto de metodologias inspiradas no comportamento de sistemas da natureza para solução de problemas de otimização. Como exemplos de técnicas de otimização natural podem ser citadas técnicas de busca local como recozimento simulado [15] e técnicas de busca global como algoritmos genéticos [16], [18] e enxame de partículas [17], dentre outros. Estas técnicas realizam uma busca estocástica pelo espaço de soluções tendo como objetivo localizar regiões com soluções promissoras, evitando assim a convergência prematura em mínimos locais.

#### A. Algoritmo NSGA-II

O algoritmo NSGA-II (do inglês *Non-dominated Sorting Genetic Algorithm*) é uma adaptação do algoritmo genético (AG) clássico para a otimização multiobjetivo através da relação de dominância entre as soluções encontradas. Esse método foi desenvolvido por Deb e colaboradores em 2002 [19] sendo aplicado para resolução de uma gama de problemas multiobjetivo [20]. O algoritmo consiste na mesma estrutura do AG clássico, diferenciando-se apenas no método com o qual os indivíduos são selecionados (operador de seleção). Nesta etapa é implementada uma metodologia de classificação das chamadas fronteiras baseada em dois procedimentos básicos: o primeiro ordena as soluções não-dominadas (*ranking*), e o segundo estima a densidade de soluções no entorno de um indivíduo (*sharing*) [21].

As fronteiras nada mais são que camadas do espaço de busca do problema que limitam uma região de dominância. Diversos objetivos  $f_m(x)$ ,  $m = 1, 2, \dots, M$ , onde  $x \in \mathbb{R}^n$  podem ser considerados, ocupando diversas dimensões no

espaço e ainda, sem perda de generalidade, pode-se considerar que todos os objetivos são de minimização [21]:

$$\min_x \{Fitness(x) = [f_1(x), f_2(x), \dots, f_m(x)]^T\} \quad (9)$$

Na prática, as fronteiras podem ser descontínuas e formar camadas irregulares, sendo que a camada mais importante é a que forma o envelope do espaço de soluções dos diversos objetivos, chamada de fronteira de Pareto [21]. As soluções Pareto-ótimas são aquelas que não podem ser melhoradas em nenhum dos objetivos e que formam o espaço de soluções não-dominadas.

Seja uma população  $P_i$  de tamanho  $N$  formada por indivíduos gerados aleatoriamente e ordenados usando o *ranking*. Os outros  $N$  indivíduos da população inicial  $Q_i$  são obtidos a partir de operadores genéticos, tais como cruzamento e mutação, utilizando indivíduos escolhidos aleatoriamente do conjunto  $P_i$ . A população completa  $R_i$  é dada por  $R_i = P_i \cup Q_i$ , onde  $|R_i| = 2N$ .

Os procedimentos *ranking* e *sharing* são aplicados à população  $R_i$  para classificar as fronteiras  $(F_1, F_2, \dots, F_j)$ . Os primeiros  $N$  elementos sobrevivem e compõem  $P_{i+1}$ , operadores genéticos são novamente aplicados gerando  $Q_{i+1}$  e assim sucessivamente, até satisfazer o critério de parada do algoritmo.

Sendo um indivíduo  $j$ , o *ranking*  $r_j$  é o número de soluções que dominam  $j$  na geração  $i$ . Assim, todas as soluções que possuem  $r_j = 0$  são armazenadas na fronteira  $F_j$ ;  $r_j = 1$  em  $F_2$  e assim por diante, de modo que ao final da iteração todos os indivíduos estejam classificados em uma fronteira. E então estima-se a quantidade de soluções no entorno de  $j$  através do cálculo da distância dos pontos na sua vizinhança. Esse cálculo é realizado como:

$$d_j = \sum_{m=1}^M \left[ \frac{f_m^{suc(j)} - f_m^{pred(j)}}{f_m^{max} - f_m^{min}} \right] \quad (10)$$

Onde  $f_m^{suc(j)}$  e  $f_m^{pred(j)}$  são respectivamente os valores do sucessor e predecessor de  $j$ , enquanto  $f_m^{max}$  e  $f_m^{min}$  são os valores máximo e mínimo da função objetivo  $m$ . Portanto, quanto maior for o valor de  $d_j$ , mais distantes estão os pontos, indicando a necessidade de gerar mais soluções nessa região.

Esse valor, conhecido como *crowding distance*, colabora de modo que a população convirja rumo à  $F_j$ , uniformizando a fronteira de Pareto. Calculados *ranking* e *crowding distance*, é realizado um reordenamento da população da seguinte forma: sendo duas soluções  $j$  e  $k$ ,  $j$  domina  $k$  se  $(r_j < r_k)$ , ou então se  $[(r_j = r_k) \text{ e } (d_j > d_k)]$ . Então a nova população é composta pelos  $N$  primeiros indivíduos selecionados, formando o conjunto  $P_{i+1}$ , enquanto os  $N$  indivíduos seguintes, pertencentes ao conjunto  $Q_{i+1}$ , são resultado da ação dos operadores genéticos sobre  $P_{i+1}$ .

#### B. Algoritmo MOEPSO

Analogamente ao NSGA-II, o algoritmo MOEPSO (do inglês *Multi Objective Evolutionary Particle Swarm Optimization*) também é inspirado em uma heurística de

otimização pré-existente, o enxame de partículas (do inglês *Particle Swarm Optimization* - PSO). O PSO clássico é um método de otimização natural inspirado no comportamento de enxame de algumas espécies de animais, criado na década de 90 por Russ Eberhart e James Kennedy [22]. Além das soluções iniciais, o PSO requer a definição da velocidade inicial de cada partícula. A partícula é equivalente ao cromossomo no PSO e representa as soluções candidatas, já o conceito de população possui o mesmo significado em ambos os métodos.

O algoritmo MOEPSO na verdade é uma combinação de duas diferentes abordagens do PSO clássico: o MOPSO (do inglês *Multi Objective Particle Swarm Optimization*), que foi proposto por Carlos Coello e colaboradores em 2002 ([23] e [24]) e adapta o PSO clássico utilizando o conceito de dominância de Pareto para a manipulação do problema de otimização multiobjetivo; e o EPSO (do inglês *Evolutionary Particle Swarm Optimization*), proposto por Vladimiro Miranda e colaboradores em 2002 ([25] e [26]) e que combina a abordagem tradicional do PSO com as estratégias evolutivas de autoadaptação (mutação, recombinação e seleção).

Assim, o algoritmo MOEPSO [27] avalia as melhores soluções de Pareto. Tomados isoladamente, o MOEPSO tem a desvantagem de se limitar a avaliar as soluções de Pareto locais, enquanto o PSO tradicional frequentemente estagna em mínimos locais. Logo, a estrutura evolutiva tem papel essencial no funcionamento do algoritmo, uma vez que suas propriedades de auto-ajuste adaptativo fornecem meios para que o método escape de soluções locais. Isso amplia a busca de uma dada partícula para várias direções, provocando um movimento das partículas replicadas para outras soluções através das mutações sofridas nas várias posições ótimas possíveis do enxame. Os parâmetros das partículas replicadas são mutantes e considerados como prole.

Depois da movimentação e avaliação de pais e filhos, a solução de um dos pais é comparada com as soluções da prole. Se a solução do pai é dominada pela sua descendência, a prole torna-se o pai da geração seguinte. Caso contrário, se as soluções da prole forem dominadas pelo seu progenitor, a prole é excluída. Resumindo, os melhores sobrevivem. Além disso, se as soluções de ambos, pais e filhos, forem não-dominadas, todas são guardadas e os pais da próxima geração serão determinados aleatoriamente. Estas operações dão ao MOEPSO a capacidade de realizar um auto-ajuste adaptativo de seus parâmetros. A movimentação no MOEPSO é mostrada a seguir:

$$v_i^{k+1} = w_{i0}^* v_i^k + w_{i1}^* (p_{best_i} - s_i^k) + w_{i2}^* [g_{best}^*(h) - s_i^k] \quad (11)$$

$$s_i^{k+1} = s_i^k + v_i^{k+1} \quad (12)$$

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (13)$$

Onde  $v_i^k$  e  $s_i^k$  são, respectivamente, a velocidade e a posição da partícula  $i$  durante a  $k$ -ésima iteração,  $p_{best_i}$  é a melhor solução da partícula  $i$ ,  $g_{best}(h)$  é a melhor solução de um enxame  $h$ ,  $w_{ik}$  é o  $(k+1)$ -ésimo fator de ponderação da partícula  $i$ ,  $N(0,1)$  é um número aleatório de distribuição normal e  $\tau$  é o parâmetro de aprendizado do enxame. Deve-se

observar que a presença do símbolo \* significa que a variável em questão sofre mutação. Além disso,  $g_{best}(h)$  realiza a mutação para avaliar melhor as soluções, como mostrado abaixo:

$$g_{best}^*(h) = g_{best}(h) + w_{i3}^* N(0,1) \quad (14)$$

$$w_{i3}^* = w_{i3} + \tau' N(0,1) \quad (15)$$

Onde  $\tau'$  é o parâmetro de tamanho da vizinhança de  $g_{best}(h)$ . O parâmetro de (14) é o tamanho da vizinhança que permite às partículas melhorar  $g_{best}(h)$ , sendo atualizado em (15).

#### IV. RESULTADOS

As técnicas de otimização anteriormente descritas foram avaliadas para a obtenção do despacho ótimo, segundo os critérios desejados, do Sistema-Teste Brasileiro de 107 barras (STB – 107 Barras). Este sistema compreende segmentos do Sistema Interligado Nacional (SIN) e seus dados podem ser encontrados em [28], incluindo os limites dos equipamentos.

A lista de contingências é definida considerando a saída individual das cinco linhas mais carregadas do caso base, que naturalmente estão entre as que mais prejudicam o sistema em caso de queda, daí a importância da rede estar preparada para a sua ocorrência (em sistemas de potência, o termo “contingência” é compreendido como uma falha ou defeito em algum equipamento que compõe a rede elétrica, tal como geradores, transformadores, linhas de transmissão, dentre outros, sendo que neste trabalho foram consideradas apenas contingências de linhas de transmissão). A Tabela I apresenta a lista das contingências consideradas, onde são apresentadas as identificações das linhas defeituosas, seus barramentos de origem e destino e o carregamento inicial que cada uma possuía. Já as Tabelas II e III apresentam os parâmetros dos algoritmos de otimização que foram utilizados neste estudo. Estes parâmetros foram escolhidos após diversas simulações iniciais. Cabe observar que os operadores genéticos usados no MOEPSO são os mesmo do NSGA-II.

TABELA I  
LISTA DE CONTINGÊNCIAS

Contingência	Linha	Origem	Destino	S (MVA)
1	97	856	933	1960,336
2	105	933	895	1280,854
3	107	933	959	1184,858
4	132	995	1060	976,7270
5	134	1030	955	962,9778

O cromossomo utilizado como solução para o problema abordado nesse trabalho foi codificado em números reais, representando o despacho de potência ativa nas unidades geradoras, bem como o controle de tensão nas barras PV. Sendo assim, temos dois tipos de genes, representados na Tabela IV.

TABELA II  
PARÂMETROS ESPECIFICADOS PARA O NSGA-II

Parâmetro	Atribuição
Gerações	100
Tamanho da população	40 indivíduos
Criação da população inicial	Distribuição gaussiana centrada no caso base
Tamanho do <i>mating pool</i>	20 indivíduos
Método de seleção	Torneio
Tamanho do torneio	2 indivíduos
Método de cruzamento	Cruzamento Binário Simulado (SBX)
Probabilidade de cruzamento	90%
Método de mutação	Mutação Polinomial
Probabilidade de mutação	10%

TABELA III  
PARÂMETROS ESPECIFICADOS PARA O MOEPSO

Parâmetro	Atribuição
Gerações	100
Tamanho do exame	40
$w_{i3}$	1
$\tau$	0,02
$\tau'$	0,01

TABELA IV  
TIPOS DE GENE DO CROMOSSOMO-SOLUÇÃO

Gene	Descrição
Despacho de potência ativa ( $P_g$ )	Este gene é representado por números reais no intervalo $[P_g^{min}, P_g^{max}]$ , onde $P_g^{max}$ e $P_g^{min}$ são os limites de geração para cada unidade geradora $g$ em pu.
Tensão nas barras PV ( $V_g$ )	Este gene é representado por números reais no intervalo $[V_g^{min}, V_g^{max}]$ , onde $V_g^{max}$ e $V_g^{min}$ são os limites da magnitude de tensão para a unidade geradora $g$ .

Neste trabalho foram executadas, para dar relevância estatística ao resultado, 10 simulações de cada heurística de otimização, sendo que os melhores resultados de cada uma dessas simulações, para cada heurística, foram comparados entre si de modo a escolher o melhor e o pior resultado. Por exemplo, foram feitas 10 execuções do NSGA-II e os 10 pontos de operação retornados foram comparados entre si de acordo com os critérios de otimização. Desses 10 pontos, são apresentados os resultados do melhor e do pior ponto. O mesmo foi feito para o MOEPSO.

No caso da otimização multiobjetivo, foi escolhido como melhor resultado (mínimo) de uma simulação isolada o elemento da fronteira de Pareto que possuísse a menor distância euclidiana em relação à origem, considerando que o ideal seria obter zero em todos os critérios, solução esta que não é viável uma vez que o ponto de operação fornecido

apresenta violações para algumas das contingências selecionadas.

Os resultados obtidos aqui serão comparados também com os resultados da otimização mono-objetivo do mesmo problema, descrito em [29]. Neste trabalho também foram testadas diversas heurísticas de otimização, sendo que os melhores resultados foram obtidos pela aplicação do Algoritmo Memético (AM), que nada mais é que um AG híbrido com refinamentos (baseados em recozimento simulado) inseridos antes e depois da atuação dos operadores genéticos. O AM neste caso trabalha com as mesmas funções objetivo descritas nas equações (4), (5) e (6), entretanto utiliza um esquema de agregação de objetivos para avaliá-las, ou seja, o seu algoritmo é voltado para a minimização da soma dos resultados retornados pelas funções objetivo em questão.

Antes da análise dos resultados, uma observação: a função objetivo  $\Delta_{conv}(\underline{x})$ , referente à penalização recebida por um ponto de operação cujo cálculo do fluxo de potência seja divergente, não precisa ser analisada, uma vez que a população final de todos os três métodos de otimização estudados contam apenas com indivíduos cujo cálculo do fluxo de potência convergiu, ou seja, para todos os casos o valor retornado por essa função objetivo será nulo, não sendo necessário avaliá-la.

As simulações foram realizadas numa máquina Dell com processador Intel® Core™ i7 vPro™ dois núcleos de 3,4 GHz, 8 GB de memória RAM e Windows 7 64-bits.

TABELA V  
SIMULAÇÃO E COMPARAÇÃO ENTRE AS HEURÍSTICAS DE OTIMIZAÇÃO

Simulação		Tempo (h)	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$
NSGA-II	Mínimo	1,0430	4,8645	0,1073
	Máximo	1,0915	6,0219	0,5167
	Média	1,0656	5,4289	0,2723
	Desvio	0,0162	0,3249	0,1328
	Padrão			
MOEPSO	Mínimo	0,9396	5,1677	0,3109
	Máximo	0,9861	7,1258	0,5923
	Média	0,9762	5,8953	0,4812
	Desvio	0,0128	0,7507	0,0952
	Padrão			
AM	Mínimo	0,9253	4,3220	0,2207
	Máximo	1,0060	7,4793	0,6263
	Média	0,9672	5,9538	0,4128
	Desvio	0,0280	1,0244	0,1389
	Padrão			

Analisando a tabela V verifica-se que a heurística de otimização com o melhor resultado para o desvio mínimo em relação ao ponto de operação de referência ( $\Delta_{ponto}(\underline{x})$ ) foi o AM, que também obteve o menor tempo de simulação, enquanto que o NSGA-II obteve o melhor resultado para a mínima violação percentual das variáveis monitoradas ( $\Delta_{rest}(\underline{x})$ ). Entretanto analisando-se sob o aspecto estatístico

conclui-se que o NSGA-II possui os melhores valores médios e os menores desvios-padrão para ambas as funções objetivo em questão, o que significa que possui os resultados mais consistentes, ou seja, melhores em média e com uma baixa variação entre as amostras.

## V. CONCLUSÕES

Este trabalho teve como objetivo comparar o desempenho de duas heurísticas evolutivas multiobjetivo na resolução do FPORS considerando a economicidade: NSGA-II e MOEPSO. As funções objetivo avaliadas consistiam no desvio mínimo em relação ao ponto de operação de referência ( $\Delta_{\text{ponto}}(\underline{x})$ ), que é a variável que representa a economicidade do sistema), na mínima violação percentual das variáveis monitoradas ( $\Delta_{\text{rest}}(\underline{x})$ , que representa a segurança) e na penalização recebida por um ponto de operação cujo cálculo do fluxo de potência seja divergente ( $\Delta_{\text{conv}}(\underline{x})$ ). Para atestar a eficácia da abordagem multiobjetivo, os resultados obtidos foram comparados com os resultados da aplicação do AM mono-objetivo descritos em [29].

Dos métodos de otimização avaliados o que obteve o melhor desempenho foi o NSGA-II, que obteve os melhores resultados do ponto de vista estatístico, necessitando apenas de um maior tempo de simulação em relação aos outros dois métodos. O MOEPSO teve um desempenho levemente pior, entretanto com um menor tempo de simulação, fazendo do mesmo também um método promissor. O AM mono-objetivo chegou a ser o melhor em alguns momentos, entretanto na avaliação estatística ficou clara a superioridade do NSGA-II, ou seja, considerando a média e o desvio padrão a tendência é que o NSGA-II produza sempre as melhores soluções para o problema ao longo de várias simulações.

O ponto negativo fica por conta do elevado custo computacional para a aplicação destes métodos em ambiente de operação, uma vez que foram necessários cerca de uma hora para cada execução das técnicas. Assim, são necessários métodos para aceleração do processo de busca, seja pela identificação de regiões promissoras ou pela redução do espaço de busca por meio de métodos de seleção e/ou transformação de variáveis.

## VI. REFERÊNCIAS

- [1] ONS, Operador Nacional do Sistema Elétrico. “Planejamento Estratégico - Missão”. Acessado em 11/04/2014. [Online]. Disponível: [http://www.ons.org.br/institucional\\_linguas/orientacoes\\_estrategicas.asp\\_x](http://www.ons.org.br/institucional_linguas/orientacoes_estrategicas.asp_x).
- [2] Dommel, H.W. and Tinney, W.F. “Optimal Power Flow Solutions”, *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-87, pp. 1866-1876, 1968.
- [3] Balu, N., Bertram, T., Bose, A., Brandwajn, V., Cauley, G., Curtice, D., Fouad, A., Fink, L., Lauby, M., Wollenberg, B.F. e Wrubel, J.N. “Online Power System Security Analysis”, *Proceedings of the IEEE*, vol. 80, no. 2, pp. 262-280, 1992.
- [4] Stott, B., Alsac, O. e Monticelli, J.A. “Security Analysis and Optimization”, *Proceedings of the IEEE*, vol. 75, no. 12, pp. 1623-1644, 1987.
- [5] Barkitzis, A.G., Biskas, P.N., Zoumas, C.E. e Petridis, V. “Optimal Power Flow by Enhanced Genetic Algorithm”, *IEEE Trans. on Power Systems*, vol. 17, no. 2, pp. 229-236, 2002.
- [6] Esmín, A.A.A., Lambert-Torres, G. e Zambroni de Souza, A.C. “A Hybrid Particle Swarm Optimization Applied to Loss Power Minimization”, *IEEE Transactions on Power Systems*, vol. 20, no.2, pp. 859-866, 2005.
- [7] Voumvoulakis, E. M. e Hatziaargyriou, N.D. “A Particle Swarm Optimization Method for Power System Dynamic Security Control”, *IEEE Transactions on Power Systems*, vol. 25, no. 2, pp. 1032-1041, 2010.
- [8] Xin, H., Gan, D., Huang, Z., Zhuang, K. e Cao, L. “Applications of Stability-Constrained Optimal Power Flow in the East China System”, *IEEE Transactions on Power Systems*, vol. 25, no.3, pp. 1423-1433, 2010.
- [9] Shahidehpour, M., Tinney, W.F. e Fu, Y. “Impact of Security on Power Systems Operation”, *Proceedings of the IEEE*, vol. 93, no. 11, pp. 2013-2025, 2005.
- [10] Burchett, R.C., Happ, H.H. e Wirgau, K.A. “Large-scale Optimal Power Flow”, *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, pp. 3722-3732, 1982.
- [11] Lambert-Torres, G. e Quintana, V.H. “An Interior-point Method for Nonlinear Optimal Power Flow using Voltage Rectangular Coordinates”, *IEEE Transactions on Power Systems*, vol. 13, pp. 1211-1218, 1998.
- [12] Momoh, J.A. e Zhu, J.Z. “Improved Interior Point Method for OPF Problems”, *IEEE Transactions on Power Systems*, vol. 14, pp. 1114-1120, 1999.
- [13] Jiang, Q., Geng, G., Gu, C. e Cao, Y. “An Efficient Implementation of Automatic Differentiation in Interior Point Optimal Power Flow”, *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 147-155, 2010.
- [14] Wood, A.J. and Wollenberg, B.F. *Power Generation, Operation and Control*, 2<sup>nd</sup> Edition, New York, John Wiley & Sons, 1996.
- [15] Monticelli, A., Romero, R. e Asada, E. “Fundamentals of Simulated Annealing”, in: *Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems*, ed. Wiley Inc, 2006.
- [16] Holland, J. “Adaptation in Natural and Artificial Systems”, Ann Arbor, MI: Univ. Michigan Press, 1975.
- [17] Kennedy, J.; Eberhart, R. “Particle Swarm Optimization”, In: *Proceedings of IEEE International Conference on Neural Networks*, vol. IV, pp 1942-1948, Perth, Australia, 1995.
- [18] Zoumas, C. E., Bakirtzis, A.G., Theocharis, J.B. e Petridis, V. “A Genetic Algorithm Solution Approach to the Hydrothermal Coordination Problem”, *IEEE Trans. Power Syst.*, vol.19, pp. 1356- 1364, 2004.
- [19] Deb, K., Pratap, A., Agarwal, S. e Meyarivan, T. “A Fast and Multiobjective Algorithm Genetic: NSGA-II”, *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182-197, 2002.
- [20] Zhou, A., Qu, B.-Y., Li, H., Zhao, S.-Z., Sunganthan, P. N. e Zhang, Q. “Multiobjective Evolutionary Algorithm: A Survey of the State of the Art”, *Swarm and Evolutionary Computation*, vol. 1, no. 1, pp. 32-49, 2011.
- [21] Lima, D. R., Santos, A. C. e Aloise, D. J. “Um Algoritmo Evolucionário NSGA-II para Resolver o Problema Biobjetivo da Árvore Geradora de Custo e Diâmetro Mínimos”, *XLVI Simpósio Brasileiro de Pesquisa Operacional*, pp. 689-699, Set 2012.
- [22] Kennedy, J.; Eberhart, R. “Particle Swarm Optimization”, In: *Proceedings of IEEE International Conference on Neural Networks*, vol. IV, pp 1942-1948, Perth, Australia, 1995.
- [23] Coello, C. A. C. “MOPSO: A Proposal for Multiple Objective Particle Swarm Optimization,” *Proc. Congr. Evolutionary Computation (CEC'2002)*, vol. 1, pp. 1051-1056, Mai 2002.
- [24] Coello, C. A. C., Pulido, G. T. e Lechuga, M. S. “Handling Multiple Objectives With Particle Swarm Optimization,” *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 3, pp. 256-279, 2004.
- [25] Miranda, V. e Fonseca, N. “EPSO – Best-of-Two-words Meta-Heuristic Applied to Power System Problem”, *Proc. of the IEEE Congress on Evolutionary Computation 2002*, vol. 2, pp. 1080-1085, Jun 2002.
- [26] Miranda, V. e Fonseca, N. “EPSO – Evolutionary Particle Swarm Optimization, a New Algorithm with Applications in Power Systems”, *Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES*, vol. 2, pp. 745-750, 2002.
- [27] Mori, H. e Okawa, K. “Advanced MOEPSO-based Multiobjective Environmental Economic Load Dispatching”, *Power and Energy Society General Meeting - 2010 IEEE*, pp. 1-7.
- [28] Alves, W. F. “Proposição de Sistemas-Teste para Análise Computacional de Sistemas de Potência”. *Dissertação de Mestrado*. UFF. Mestrado em Computação de Potência. RJ. Ago. 2007.
- [29] Freire, R. C. “Obtenção do Despacho Seguro de Sistemas Elétricos do Ponto de vista Estático via Algoritmos Evolutivos”. *Projeto de Graduação*. UFF. Bacharelado em Engenharia Elétrica. RJ. Jul. 2011.