

ALGORITMO EVOLUTIVO MULTI-OBJETIVO BASEADO EM TABELAS DE SUBPOPULAÇÕES DE SOLUÇÕES NÃO DOMINADAS E FORÇA DE PARETO PARA TRATAR DO PROBLEMA DE RESTABELECIMENTO DE ENERGIA EM SISTEMAS DE DISTRIBUIÇÃO

D.S. SANCHES* S.C MAZUCATO JR.* M.F. CASTOLDI* A.C.B. DELBEM† J.B.A. LONDON JR.†

**Av. Alberto Carazzai, 1640
Universidade Tecnológica Federal do Paraná
Cornélio Procópio, Paraná, Brasil*

†*Av. Trabalhador São carlense, 400
Universidade de São Paulo
São Carlos, São Paulo, Brasil*

Email: danilosanches@utfpr.edu.br, sergiomazucato@gmail.com
marcastoldi@utfpr.edu.br, acbd@icmc.usp.br, jbalj@sc.usp.br

Abstract— The network reconfiguration for service restoration (SR) in distribution systems is a combinatorial complex optimization problem since it involves multiple non-linear constraints and objectives. For large networks, no exact algorithm has found adequate SR plans in real-time. On the other hand, methods combining Multiobjective Evolutionary Algorithms (MOEAs) with the Node-depth encoding (NDE) have shown to be able to efficiently generate adequate SR plans for large distribution systems (with thousands of buses and switches). This paper presents a new method that combining NDE with three MOEAs: (i) NSGA-II; (ii) SPEA 2; and (iii) a MOEA based on subpopulation tables. The idea is to obtain a method that cannot-only obtain adequate SR plans for large scale distribution systems, but can also find plans for small or large networks with similar quality. The proposed method, called AEMT-SP, explores the space of the objectives solutions better than the other MOEAs with NDE, approximating better the Pareto-optimal front. This statement has been demonstrated by several simulations with DSs ranging from 632 to 1,277 switches.

Keywords— Multi-objective Evolutionary Algorithms, Node-Depth Encoding, Distribution Systems, Service Restoration

Resumo— A reconfiguração de redes para restauração de serviço (RS) em sistemas de distribuição é um problema complexo de otimização combinatória, uma vez que envolve várias restrições não-lineares e objetivos. Para grandes redes, nenhum algoritmo exato encontrou uma RS com planos adequados, em tempo real. Por outro lado, métodos combinam algoritmos evolutivos multi-objetivo (AEMOs) com representação nó-profundidade (RNP) têm mostrado serem capazes de gerar eficientemente planos RS adequados para grandes sistemas de distribuição (com milhares de barramentos e chaves). Este trabalho apresenta um novo método que combina RNP com três AEMOs: (i) NSGA-II, (ii) SPEA 2, e (iii) um AEMO com base em tabelas de subpopulações. A ideia é obter um método capaz de obter planos de RS adequados para sistemas de distribuição em grande escala e também encontrar planos para redes menores com qualidade semelhante. O método proposto, denominado AEMT-SP, explora melhor o espaço de soluções objetivo do que os outros AEMOs com RNP, aproximando melhor a fronteira ótima de Pareto. Esta afirmação é demonstrada por várias simulações com sistemas de distribuição variando de 632 a 1.277 chaves.

Palavras-chave— Algoritmos Evolutivos Multi-Objetivo, Representação Nó-Profundidade, Sistemas de Distribuição, Restabelecimento de Energia

1 Introdução

Problemas de Sistema de Distribuição (SD), tais como restauração de serviço (RS), geralmente envolvem reconfiguração de rede, isto é, o processo de mudança de topologia dos sistemas de distribuição abrindo ou fechando chaves (normalmente fechada (NF)) e (normalmente aberta (NA)). Quando a reconfiguração da rede é aplicada ao problema de RS, os principais objetivos são isolar as áreas com faltas, para fornecer energia para as áreas sem faltas e minimizar o número de operações de manobras sem violar certas restrições operacionais (configurações radiais e os limites de queda de tensão, carga da rede e carga do sistema). Enquanto possível, as cargas devem ser transferidas de áreas não energizadas, através de reconfiguração da rede, a outra distribuição ali-

mentada sem violar as restrições.

Reconfiguração de rede para RS é um problema computacionalmente complexo, uma vez que é: i) Altamente combinatória devido ao grande número de elementos de chaveamento, ii) Não linear, uma vez que as equações que regem o sistema elétrico são em geral não lineares, iii) Não diferenciável pois uma mudança de estado de uma chave pode resultar em variações nítidas nos objetivos e restrições; iv) Restrita devido às restrições elétricas e operacionais, v) Multi-objetivo pois o plano de RS deve maximizar o número de clientes restaurados e minimizar o número de operações de manobras e, quando não conflitante com os dois objetivos anteriores, minimizar as perdas de energia. Assim, o desenho de uma configuração de rede ideal para RS é um problema de otimização

combinatorial que pode exigir a investigação de vários vetores de estado das chaves para encontrar uma nova configuração adequada.

Nas últimas décadas foram desenvolvidos algoritmos evolutivos (AEs) para problemas de Reconfiguração de Sistemas de Distribuição (RSD) (Augugliaro et al., 2000), (Tsai and Hsu, 2010). O desempenho de AEs aplicados a RSD, é em geral superior a abordagens baseadas em programação matemática ou técnicas tradicionais de inteligência artificial, uma vez que a aplicação de programação matemática está limitada a problemas de pequeno porte. Devido a grande quantidade de variáveis envolvidas na modelagem matemática por programação matemática de problemas de RSD de grande porte, o problema torna-se computacionalmente intratável. Deve-se lembrar que esse problema é combinatorial no número de chaves seccionadoras do sistema, isso significa que o número de soluções possíveis aumenta exponencialmente com o número de chaves. Face ao exposto, a maioria dos AEs para RSD ainda exigem tempo de execução quando aplicada a sistemas de distribuição de grande escala (SDs) (SDs com milhares de barras e chaves) modelados considerando todos as as barras e chaves (Delbem et al., 2005).

Nesse sentido, o algoritmo evolutivo multi-objetivo (AEMO) utilizando a representação Nó-Profundidade (RNP), denominada AE Multi-objetivo com tabelas de subpopulações (AEMT) (Santos et al., 2010), superaram tal desvantagem, uma vez que pode gerar exclusivamente soluções factíveis considerando todas (em milhares) as barras e chaves de um grande SDs em tempo real com baixo tempo de execução. Importa destacar que, a partir da RNP, dois operadores foram desenvolvidos para manipular de maneira eficiente a floresta produzindo uma nova solução. O primeiro operador proposto PAO (do inglês, *Preserve Ancestor Operator*) e o segundo operador proposto CAO (do inglês, *Change Ancestor Operator*), sendo que cada operador realiza modificações em uma RNP que são equivalentes a podar e enxertar uma floresta gerando uma nova floresta. O CAO produz modificações mais complexas do que o PAO na floresta, conforme descrito em (Santos et al., 2010).

No entanto, outros métodos usando RNP, como NSGA-II com RNP (NSGA2-RNP a seguir) (Mansour et al., 2010) e AEMT com tabelas de soluções não dominadas (AEMT-SND a seguir) (Sanches et al., 2011) foram investigados. Embora sejam baseados em tabelas de subpopulações de soluções não-dominadas e RNP, o NSGA2-RNP usa uma versão modificada do NSGA II (Deb et al., 2002) enquanto o AEMT-SND inclui características dos métodos AEMT e NSGA II. Neste sentido o NSGA2-RNP e AEMT-SND têm mostrado serem capazes de resolver os problemas combinatoriais com dois ou mais objetivos.

Como mostrado em (Santos et al., 2010; Man-

sour et al., 2010; Sanches et al., 2011), o RNP pode melhorar o desempenho de AEMOs em problemas de reconfigurações SD devido às seguintes propriedades: (i) Os operadores da RNP produzem exclusivamente configurações factíveis, isto é, as configurações radiais capazes de fornecer energia para todo o sistema reconectável, (ii) a RNP pode gerar mais configurações factíveis em relação a outras codificações no mesmo tempo de funcionamento pois a sua complexidade média de tempo é $O(\sqrt{n})$, onde n é o número de nós no grafo (cada nó do grafo corresponde a um setor¹), (iii) a formulação baseada em RNP permite uma varredura mais eficiente do algoritmo de fluxo de carga direta-inversa (do inglês, *forward-backward Sweep Load Flow Algorithm* (SLFA)). Normalmente este tipo de fluxo de carga aplicada a redes radiais requer uma rotina para classificar barras da rede na Ordem Terminal-Subestação (OTS) antes de calcular as tensões das barras (Srinivas, 2000). Felizmente, os barramentos de cada configuração produzida pelos operadores da RNP são naturalmente dispostos no OTS, por conseguinte o SLFA pode ser melhorado através de uma formulação baseada em RNP.

Este trabalho propõe um novo método (derivado do AEMT, NSGA2-RNP e AEMT-SND) que não só pode obter planos adequados de RS para grandes SDs, mas também pode encontrar planos para redes pequenas ou grandes com qualidade similar. Para se obter um conjunto ótimo de Pareto com melhor convergência preservando a diversidade, o método proposto denominado AEMT com Tabela de Força de Pareto (AEMT-SP a seguir), estende-se a estratégia das tabelas de subpopulações do AEMT-SND e incorpora uma tabela de soluções não-dominadas baseado no SPEA2 (Zitzler et al., 2001). Nesta nova tabela de cada indivíduo está associado a um valor de força, isto é, a força da dominância de um indivíduo em relação aos outros indivíduos. Os indivíduos com um maior valor de força são preservadas e mantidos na tabela para melhorar a capacidade de investigar o espaço de objetivos. Além de obter planos adequados de RS para grandes SDs, o AEMT-SP também encontra planos para redes pequenas ou grandes, com qualidade similar. Os resultados utilizando redes relativamente pequenas (com 3.860 barras) e grandes (com 7.720 barras) indicam que o AEMT-SP pode encontrar planos de RS para pequenas redes de pequeno e grande porte.

2 Problema de Restabelecimento de Energia

Após a localização de uma falta ter sido identificada e isolada, as áreas fora de serviço precisam

¹Um setor é um conjunto de barras conectadas por linhas sem chaves seccionadoras.

ser ligadas a um outro alimentador pela abertura e, ou, fechamento de chaves. A Fig. 1(a) mostra um exemplo de RS em um SD com três alimentadores. Nós 1, 2 e 3 representam as fontes de potência em um alimentador, linhas contínuas e linhas pontilhadas representam, respectivamente, chaves NC e NO. Cada um dos círculos representa um setor (Santos et al., 2010). Suponha que o setor 4 está em falta (Fig. 1(a)). Em seguida, o setor 4 deve ser isolado do sistema através da abertura das chaves A e B. Os Setores 7 e 8 estão em uma área fora de serviço. Uma maneira de restaurar a energia destes setores é pelo fechamento da chave C (Fig. 1(b)).

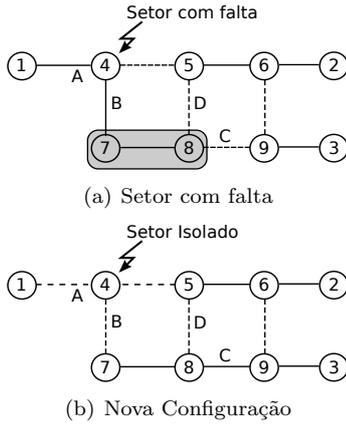


Figura 1: Ilustração de um SD representado por um grafo e o seu processo de restauração de serviço:(a) uma configuração original com falta; e (b) uma nova configuração após a restauração do serviço.

2.1 Formulação Matemática

O problema de RS pode ser formulado como:

$$\begin{aligned}
 & \text{Min. } \phi(G), \psi(G, G^0) \text{ and } \gamma(G) \\
 & \text{s.a.} \\
 & \quad Ax = b \\
 & \quad X(G) \leq 1 \\
 & \quad B(G) \leq 1 \\
 & \quad V(G) \leq 1 \\
 & \quad G \text{ uma floresta,}
 \end{aligned} \tag{1}$$

onde G é uma floresta geradora do grafo que representa uma configuração do sistema (cada árvore da floresta (Diestel, 2005) corresponde a um alimentador ou uma área fora-de-serviço, os vértices correspondem aos setores e arestas as chaves); $\phi(G)$ é o número de consumidores que estão fora de serviço na configuração G (considerando somente o sistema reconectável); $\psi(G, G^0)$ é o número de operações de manobras para atingir uma determinada configuração G a partir da configuração após o isolamento da falta G^0 ; $\gamma(G)$ é a perda de potência, em p.u. da configuração G ; A é

a matriz de incidência de G (Ahuja et al., 1993); x é o vetor da linha de fluxo corrente; b é um vetor contendo as correntes complexas de carga (constante) nas barras com $b_i \leq 0$ ou as correntes complexas injetadas nas barras com $b_i < 0$ (subestação); $X(G)$ é chamado de carga da rede de configuração G , isto é, $X(G)$ é a maior razão x_j/\bar{x}_j , onde \bar{x}_j é o limite superior da magnitude da corrente para cada magnitude de corrente de linha x_j na linha j ; $B(G)$ é chamado de carga de subestação da configuração G , isto é, $B(G)$ é a maior razão b_s/\bar{b}_s , onde \bar{b}_s é o limite superior da magnitude da corrente de injeção provida pela subestação (s significa uma barra na subestação); $V(G)$ é chamado de máxima queda de tensão relativa da configuração G , isto é, $V(G)$ é o maior valor de $|v_s - v_k|/\delta$, onde v_s é a magnitude da tensão no nó na barra da subestação s em p.u. e v_k é a magnitude da tensão no nó na barra da rede k em p.u. obtida a partir do SLFA, e δ é a maior queda de tensão aceitável (neste trabalho $\delta = 10\%$).

A formulação da equação 1 pode ser sintetizada a partir das seguintes considerações:

- i*) Penalidade para restrições violadas $X(G)$, $B(G)$ e $V(G)$;
- ii*) O uso da RNP (Santos et al., 2010), isto é, um resumo dos tipos de dados (Cormen et al., 2001) para grafos que podem manipular a configuração da rede de maneira eficiente e garantir que as modificações realizadas sempre produzem uma nova configuração G que também é uma árvore geradora (uma configuração factível);
- iii*) Os nós estão arranjados na OTS para cada configuração G produzida de forma a solucionar $Ax = b$ usando um SLFA eficiente para SDs. A RNP armazena os nós na OTS;
- v*) $\phi(G) = 0$. A RNP sempre gera um floresta que corresponde a redes sem os consumidores fora de serviço no sistema reconectável.

A equação 1 pode ser reescrita como:

$$\begin{aligned}
 & \text{Min. } \psi(G, G^0), \gamma(G) \text{ e} \\
 & \quad \omega_x X(G) + \omega_b B(G) + \omega_v V(G) \\
 & \text{s.a.} \\
 & \quad \text{Fluxo de Carga calculado usando RNP,} \\
 & \quad G \text{ representa uma floresta,}
 \end{aligned} \tag{2}$$

onde ω_x , ω_b e ω_v são pesos de balanceamento entre as restrições operacionais da rede. Neste trabalho estes pesos são definidos como:

$$\omega_x = \begin{cases} 1, & \text{se } X(G) > 1 \\ 0, & \text{caso contrario} \end{cases} \tag{3}$$

$$\omega_b = \begin{cases} 1, & \text{se } B(G) > 1 \\ 0, & \text{caso contrario} \end{cases} \tag{4}$$

$$\omega_v = \begin{cases} 1, & \text{se } V(G) > 1 \\ 0, & \text{caso contrario} \end{cases} \quad (5)$$

3 Abordagem Proposta

O método proposto, chamado Algoritmo Evolutivo Multi-Objetivo com RNP e Força de Pareto (AEMT-SP), combina as características principais dos métodos AEMT, AEMT-SND e SPEA2.

O AEMT-SP explora o espaço de objetivos usando o conceito de tabelas de subpopulações como o AEMT. Cada tabela de subpopulação armazena as melhores soluções encontradas de acordo com um objetivo, uma restrição ou uma função de agregação de objetivos e restrições. No entanto, o AEMT-SP possui tabelas de subpopulações adicionais que armazenam as soluções (i) de diferentes níveis de não-dominância, como o AEMT-SND usa o conceito de *ranking* de dominância usado pelo NSGA-II, e (ii) da força de dominância de um indivíduo em relação a outros indivíduos baseado no SPEA2.

O AEMT-SP compreende as seguintes tabelas de subpopulações:

1. Tabelas associadas a cada objetivo e restrição (estas tabelas são comuns para o AEMT, AEMT-SND e AEMT-SP):
 - (a) T_1 - soluções com o menor $\gamma(G)$ encontrado;
 - (b) T_2 - soluções com o menor $V(G)$ encontrado;
 - (c) T_3 - soluções com o menor $X(G)$ encontrado;
 - (d) T_4 - soluções com o menor $B(G)$ encontrado;
 - (e) T_5 - soluções com o menor valor de uma função agregação encontrado, como o seguinte:

$$f_{agg}(G) = \psi(G, G^0) + \gamma(G) + \omega_x X(G) + \omega_b B(G) + \omega_v V(G),$$

onde $\psi(G, G^0)$, $\gamma(G)$, $X(G)$, $B(G)$, $V(G)$, ω_b , ω_v e ω_x foram definidos na Seção 2 ².

2. Tabelas para incrementar a diversidade no espaço de objetivos organizadas por *ranking* de dominância usadas pelo NSGA-II (Deb et al., 2002) (estas tabelas são comuns para o AEMT-SND e AEMT-SP). Suas estratégias consistem em dividir um conjunto de M soluções em muitas fronteiras ($\mathcal{F}_1, \mathcal{F}_2, \dots, \mathcal{F}_k$) de acordo com o grau de dominância de cada solução. Uma solução G_i domina outra G_j se G_i é melhor que G_j de

acordo com pelo menos um objetivo e G_i não é pior que G_j em todos os outros objetivos. \mathcal{F}_1 fronteira (chamada Fronteira de Pareto) contém as soluções não dominadas do conjunto de soluções M . \mathcal{F}_2 contém o conjunto de soluções não dominadas $M \setminus \mathcal{F}_1$, \mathcal{F}_3 armazena as soluções não dominadas $M \setminus (\mathcal{F}_1 \cup \mathcal{F}_2)$. Assim há três tabelas deste tipo:

- (a) Tabela T_6 - soluções a partir de \mathcal{F}_1 ;
- (b) Tabela T_7 - soluções a partir de \mathcal{F}_2 ;
- (c) Tabela T_8 - soluções a partir de \mathcal{F}_3 .

3. A tabela de Força de Pareto T_9 (esta tabela existe apenas para o método proposto - AEMT-SP): é preenchida de acordo com a força de aptidão de cada indivíduo, que é determinada pela força de seus dominadores na tabela (similar ao SPEA2). A solução (indivíduo) que domina mais soluções é considerado a melhor.

O tamanho destas tabelas e o número de gerações são parâmetros do AEMT-SP:

- S_{T_i} é o tamanho da tabela de subpopulações, T_i indica quantos indivíduos podem ser armazenados em T_i , para $i = 1, \dots, 9$;
- G_{max} é o número máximo de indivíduos gerados pelo AEMT-SP. Também usado como critério de parada do algoritmo.

Os operadores de reprodução usados para gerar novos indivíduos são o PAO e CAO. Primeiro uma solução é selecionada de uma tabela de subpopulações da seguinte maneira: uma subpopulação T_i é selecionada aleatoriamente, então, um indivíduo é selecionado aleatoriamente. Em sequência, o PAO ou CAO (de acordo com a probabilidade dinâmica (Santos et al., 2010)) é aplicada a este indivíduo, gerando um novo, I_{new} . A tabela de subpopulações T_i recebe I_{new} se T_i não estiver completa (desde que T_i tenha tamanho de fronteira S_{T_i}) ou se I_{new} é melhor (de acordo com o critério associado a T_i) então a pior solução em T_i , reocupa este espaço.

É importante ressaltar que T_6 , T_7 , T_8 e T_9 são relacionados por não-dominância e necessitam de ser completados de acordo com o *ranking* de dominância. Também é importante ressaltar que dois critérios são usados pelo AEMT-SP para verificar a dominância: i) número de operações de manobras ($\psi(G, G^0)$) e ii) a função de agregação $f_{agg}(G)$.

4 Resultados Experimentais

Com o objetivo de analisar como os métodos AEMT, NSGA2-RNP, AEMT-SND e AEMT-SP se comportam para o problema de RS, o sistema

²Note que todas as configurações geradas são factíveis, isto é, elas são redes radiais aptas a fornecer energia para todo o sistema reconectável.

de distribuição real da cidade de São Carlos (chamado aqui de Sistema 1) foi usado para compor outro sistema de distribuição, chamado Sistema 2, que é composto por dois Sistemas 1 interconectados por 13 novas NO chaves adicionais. Estes sistemas tem a seguinte característica: **Sistema 1 (S1)**: 3.860 barramentos, 532 setores, 632 chaves (509 NF e 123 NA), três subestações, e 23 alimentadores; **Sistema 2 (S2)**: 7.720 barramentos, 1.064 setores, 1.277 chaves (1.018 NF e 259 NA), seis subestações, e 46 alimentadores.

Foram feitas simulações para uma falta nos maiores alimentadores dos Sistemas 1 e 2. Estas faltas interrompem o serviço para os alimentadores, incrementado a complexidade da busca pela melhor solução devido ao tamanho do sistema. Os métodos AEMT, NSGA2-RNP, AEMT-SND e AEMT-SP foram executados 50 vezes (50000 avaliações de cada vez) para encontrar planos RS para estas faltas. Importa destacar que, inicialmente, somente três operações de manobras são necessárias para isolar as áreas em falta nos Sistemas 1 e 2.

As Tabelas 1 e 2 sintetizam os resultados encontrados nos métodos analisados, em termos de operações de manobras, para os Sistemas 1 e 2 respectivamente. Importa destacar que as soluções encontradas pelo AEMT-SP foram melhores, alcançando um menor número de operações de manobras para os Sistemas 1 e 2. Ainda nas Tabelas 1 e 2, são apresentados outros aspectos das melhores soluções encontradas pelos quatro métodos testados para os Sistemas 1 e 2 respectivamente. Nestas tabelas as seguintes nomenclaturas são usadas: PP (Perdas de Potência); QT (Queda de Tensão); CR (Carregamento da Rede); CS (Carregamento da Subestação); OM (Operações de Manobras); TE (Tempo de Execução) e DP (Desvio Padrão).

Tabela 1: Resultados - Falta única no Sistema 1

| | AEMT | NSGA2 RNP | AEMT SND | AEMT SP |
|--------------------|--------|--------------|-------------|------------|
| ¹ Média | 299.13 | 361.79 | 356.71 | 370.54 |
| ¹ DP | 7.38 | 38.96 | 33.65 | 36.68 |
| ² Média | 3.25 | 4.21 | 3.89 | 4.15 |
| ² DP | 0.01 | 0.83 | 0.84 | 0.86 |
| ³ Média | 77.79 | 86.57 | 82.24 | 80.52 |
| ³ DP | 3.23 | 8.18 | 5.71 | 5.82 |
| ⁴ Média | 55.15 | 52.77 | 52.93 | 53.24 |
| ⁴ DP | 7.38 | 3.02 | 2.20 | 2.21 |
| ⁵ Média | 21 | 13 | 8 | 6 |
| ⁵ DP | 2.27 | 12.21 | 2.73 | 2.11 |
| ⁶ Média | 14.38 | 9.11 | 13.17 | 14.68 |
| ⁶ DP | 1.32 | 0.23 | 0.13 | 1.27 |

¹Referente a PP em kW, ²Referente a QT (%),

³Referente a CR (%), ⁴Referente a CS (%),

⁵Referente a OM, ⁶Referente a RT (s).

Tabela 2: Resultados - Falta única no Sistema 2

| | AEMT | NSGA2 RNP | AEMT SND | AEMT SP |
|--------------------|--------|--------------|-------------|------------|
| ¹ Média | 299.13 | 361.79 | 356.71 | 370.54 |
| ¹ DP | 7.38 | 38.96 | 33.65 | 36.68 |
| ² Média | 3.28 | 4.04 | 3.93 | 4.11 |
| ² DP | 0.08 | 0.87 | 0.85 | 0.85 |
| ³ Média | 77.16 | 87.18 | 84.27 | 83.27 |
| ³ DP | 5.25 | 8.39 | 7.74 | 5.79 |
| ⁴ Média | 54.55 | 54.13 | 54.89 | 55.47 |
| ⁴ DP | 10.03 | 1.40 | 1.76 | 5.79 |
| ⁵ Média | 36 | 19 | 14 | 11 |
| ⁵ DP | 6.84 | 11.22 | 9.53 | 7.76 |
| ⁶ Média | 20.63 | 17.44 | 18.46 | 18.89 |
| ⁶ DP | 3.26 | 0.39 | 0.59 | 0.99 |

¹Referente a PP em kW, ²Referente a QT (%),

³Referente a CR (%), ⁴Referente a CS (%),

⁵Referente a OM, ⁶Referente a RT (s).

Finalmente, nas Figs. 2 e 3 são ilustradas as Fronteiras não-dominadas obtidas por todos os métodos analisados para os Sistemas 1 e 2 e indicam que o método AEMT-SP é capaz de envolver indivíduos próximos a Fronteira de referência composta por soluções encontradas em todos os métodos nos 50 ensaios para cada método, quando comparado com aproximações do AEMT, NSGA2-RNP e AEMT-SND.

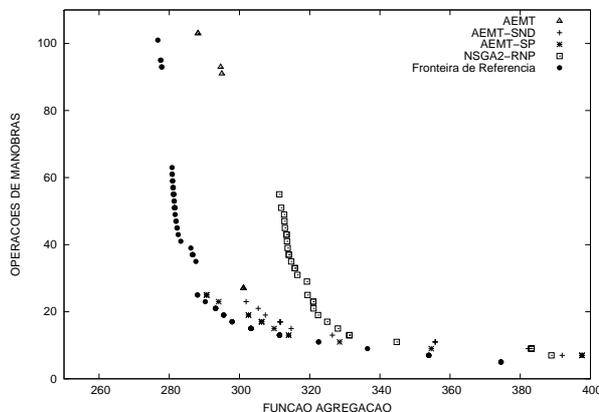


Figura 2: Fronteiras não-dominadas obtidas com o Sistema 1.

5 Conclusões

Foi proposto um novo AEMO utilizando RNP para resolver o problema de RS em grande escala SDs (isto é, com milhares de barramentos e chaves). O procedimento proposto, chamado AEMT-SP, combina as características principais dos métodos AEMT, NSGA2 e SPEA2. De forma similar ao AEMT, o AEMT-SP é baseado na ideia de tabelas de subpopulações. No entanto possui tabelas de subpopulações adicionais que ar-

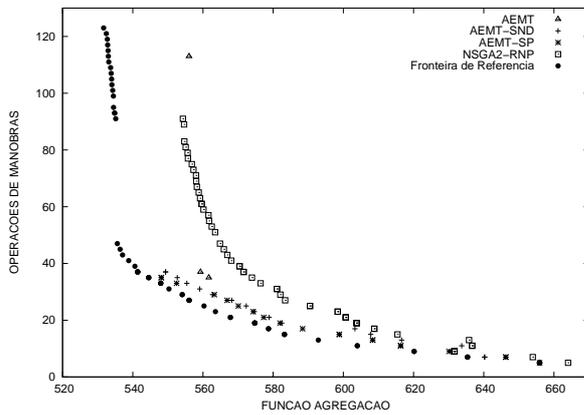


Figura 3: Fronteiras não-dominadas obtidas com o Sistema 2.

mazenam soluções não dominadas, chamadas tabelas de subpopulações não dominadas (similar ao AEMT-SND), e incorpora a tabela de soluções não dominadas baseado em SPEA2, onde cada indivíduo esta associado ao seu valor de força. O valor de força é o valor da dominância de um indivíduo em relação aos outros indivíduos. Estas tabelas asseguram a diversidade entre as soluções melhorando o desempenho dos AEMOs para problemas de RS.

Nas simulações, os métodos NSGA2-RNP, AEMT, AEMT-SND e AEMT-SP foram submetidos a dois SDs de grande escala (Sistemas 1 e 2 conforme descrito na Seção IV). Uma análise estatística foi elaborada para cada método e uma comparação apresentou o AEMT-SP com melhores resultados que os outros métodos para o problema de RS, assim o AEMT-SP encontrou a melhor resultado para a média de operações de manobras e a melhor aproximação para a Fronteira não-dominada conservando a diversidade das soluções.

Este estudo apresentou uma boa base para para combinar aspectos promissores de diferentes AEMO em um novo método que apresentou bons resultados em simulações realizadas nos Sistemas 1 e 2.

6 Agradecimentos

Os autores gostariam de agradecer a CAPES, CNPq, FAPESP e a Fundação Araucária pelo apoio financeiro dado a pesquisa.

Referências

- Ahuja, R. K., Magnanti, T. L. and Orlin, J. B. (1993). *Network Flows: Theory, Algorithms, and Applications*, Printce Hall, Englewood Cliffs.
- Augugliaro, A., Dusonchet, L. and Sanseverino, E. R. (2000). Multiobjective service restoration in distribution networks using an evolutionary approach and fuzzy sets, *International Journal of Electrical Power & Energy Systems* **22**: 103–110.

- Cormen, T. H., Leiserson, C. E., Rivest, R. L. and Stein, C. (2001). *Introduction to Algorithms*, 2 edn, The MIT Press.

- Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii, *Evolutionary Computation, IEEE Transactions on* **6**(2): 182–197.

- Delbem, A., de Carvalho, A. and Bretas, N. (2005). Main chain representation for evolutionary algorithms applied to distribution system reconfiguration, *Power Systems, IEEE Transactions on* **20**(1): 425–436.

- Diestel, R. (2005). *Graph Theory*, Vol. 173 of *Graduate Texts in Mathematics*, third edn, Springer-Verlag, Heidelberg.

- Mansour, M., Santos, A., London, J., Delbem, A. and Bretas, N. (2010). Node-depth encoding and evolutionary algorithms applied to service restoration in distribution systems, *Power and Energy Society General Meeting, 2010 IEEE*, pp. 1–8.

- Sanches, D., Mansour, M., London, J., Delbem, A. and Santos, A. (2011). Integrating relevant aspects of moeas to solve loss reduction problem in large-scale distribution systems, *PowerTech, 2011 IEEE Trondheim*, pp. 1–6.

- Santos, A., Delbem, A., London, J. and Bretas, N. (2010). Node-depth encoding and multiobjective evolutionary algorithm applied to large-scale distribution system reconfiguration, *Power Systems, IEEE Transactions on* **25**(3): 1254–1265.

- Srinivas, M. (2000). Distribution load flows: a brief review, *Power Engineering Society Winter Meeting, 2000. IEEE* **2**: 942–945 vol.2.

- Tsai, M.-S. and Hsu, F.-Y. (2010). Application of grey correlation analysis in evolutionary programming for distribution system feeder reconfiguration, *Power Systems, IEEE Transactions on* **25**(2): 1126–1133.

- Zitzler, E., Laumanns, M. and Thiele, L. (2001). Spea2: Improving the strength pareto evolutionary algorithm, *Technical report*.