

UMA ABORDAGEM DO PROBLEMA DE PLANEJAMENTO DE REDES ELÉTRICAS COM RESTRIÇÃO DE SEGURANÇA POR ALGORITMO EVOLUTIVO MULTI OBJETIVO

Aldir Silva Sousa, Filipe de Oliveira Saraiva, Eduardo Nobuhiro Asada

Universidade de São Paulo
Escola de Engenharia de São Carlos
Departamento de Engenharia Elétrica
São Carlos, SP 13566-590
{aldirss,filipe.saraiva,easada}@usp.br

Resumo – Este artigo propõe a modelagem do problema de planejamento da expansão de redes de energia elétrica com restrição de segurança através de um modelo multiobjetivo e a aplicação de algoritmos inteligentes para resolver problemas com estas características. O algoritmo aqui abordado foi o *SPEA-2: Strength Pareto Evolutionary Algorithm* (SPEA-2). Testes foram realizados em sistemas conhecidos na literatura especializada do problema no intuito de verificar a viabilidade da proposta.

Palavras-chave – Planejamento da expansão de redes elétricas, Algoritmos multiobjetivos, SPEA2.

Abstract – This paper proposes modeling the power grid expansion planning problem with security constraints through a multiobjective model and the application of intelligent algorithms to solve problems with these characteristics. We applied the algorithm SPEA-2: Strength Pareto Evolutionary Algorithm to solve the problem. The authors have accomplished tests on systems known in the literature of the problem in order to assess the viability of the propose.

Keywords – Transmission Expansion Planning, Multiobjective Algorithms, SPEA2.

1. INTRODUÇÃO

O problema de planejamento da expansão de sistemas de transmissão de energia elétrica (PEST) tem como objetivo determinar o custo de investimento mínimo para a expansão do sistema de transmissão de energia visando atender o aumento da demanda no horizonte futuro. O PEST é executado depois do estudo de previsão da geração e da demanda de energia elétrica. Após determinado em quanto e onde o sistema terá aumento de geração e demanda, surge o problema de determinar o menor custo de adição de equipamentos (linhas de transmissão e/ou transformadores) de forma a garantir um adequado nível de qualidade de energia elétrica aos consumidores.

Tradicionalmente, as metodologias sugeridas para solução do PEST podem ser divididas em dois grandes grupos: o grupo dos métodos exatos e os métodos aproximados. Dentre os métodos exatos, o algoritmo *branch and bound* (B&B) e os métodos de decomposição têm sido os mais empregados. Os artigos [1, 2] são exemplos de contribuições para resolução do PEST por meio de métodos exatos.

Dentre os métodos aproximados, os mais empregados são os métodos heurísticos construtivos e as metaheurísticas. Os métodos heurísticos construtivos, quando lidam com sistemas de grande porte, encontram soluções em pouco tempo computacional, porém de baixa qualidade. Quando se consideram os sistemas de grande porte, as metaheurísticas têm apresentado os melhores resultados quando se consideram tempo computacional e qualidade de solução. Os trabalhos [3, 4] são contribuições para solução do PEST utilizando métodos aproximados. Quando se aborda o PEST com suas características não determinísticas, sistemas *fuzzy* e programação multiobjetivo [5–7] têm sido bastante aplicados.

Com a reorganização da indústria de energia elétrica, novos desafios têm sido observados. Um desses desafios é garantir os critérios de segurança que, por sua vez, estão relacionados à habilidade do sistema de energia elétrica de reagir a distúrbios e antecipar-se à perda de equipamentos de geração e/ou transmissão [8]. Considerar os critérios de segurança quando do planejamento da expansão da rede de transmissão implica em modelos matemáticos mais complexos e planos de expansão mais caros do que os planos que não os consideram. Este aumento no custo de expansão é um dos maiores entraves para realização do PEST considerando critérios de segurança. Para contornar o elevado incremento decorrente da restrição de segurança, ao fornecer ao tomador de decisão o conjunto das melhores soluções considerando o impasse entre obter planos de expansão baratos e com o atendimento ao critério de segurança, este trabalho propõe a modelagem do PEST considerando estes dois objetivos conflitantes: minimização do investimento da expansão e maximização do nível de segurança do plano de expansão. Além disso, propomos a aplicação de métodos inteligentes para lidar com modelos com características multiobjetivo.

2. PLANEJAMENTO DE REDES ELÉTRICAS COM RESTRIÇÃO DE SEGURANÇA

O problema de planejamento da expansão de redes de transmissão com restrição de segurança é um problema de grande complexidade e importância prática, uma vez que todo sistema elétrico tende a crescer. A expansão planejada torna-se necessária para garantir o fornecimento de energia elétrica contínuo e com qualidade, o que é vital para o desenvolvimento de toda uma nação e para o bem-estar da sociedade em geral.

Tradicionalmente, há duas formas de realizar o PEST considerando critérios de segurança: (1) consideram-se métodos probabilísticos [9,10] baseados em índices de confiabilidade que determinam o grau de segurança de uma rede de energia; (2) considera-se o critério de segurança determinístico $n - 1$ [11]. O critério de segurança $n - 1$ impõe que a rede de energia continue operando mesmo que haja falta em um de seus equipamentos, geralmente considerando as linhas de transmissão. Em outras palavras, se houver falta em um linha de transmissão do sistema, esta falta não implicará em *blackout*.

Os modelos probabilísticos se baseiam principalmente em índices de confiabilidade como a *LOLE* (*Loss- of Load Expectation*), *EPNS* (*Expected Power not-Supplied*) e *LOLC* (*Loss of Load Cost*). Estes modelos apresentam as seguintes desvantagens: não há uma definição do quão confiável um sistema deve ser, baseando-se nesses índices de confiabilidade [12]; custo computacional muito elevado para avaliar os planos de expansão candidatos.

O modelo determinístico $n - 1$, que pode ser estendido para $n - m$, tem como desvantagem o elevado custo computacional e o aumento no investimento final. Neste trabalho abordamos o critério de segurança $n - 1$, porém, para contornar a desvantagem do incremento no investimento, propomos modelar o problema de planejamento da expansão das redes de transmissão segundo um modelo multiobjetivo, e aplicar métodos de inteligência computacional usados para resolver problemas com estas características, apresentando ao planejador as melhores soluções considerando os dois objetivos. A seguir, definiremos a programação multiobjetivo, o algoritmo multiobjetivo utilizado neste trabalho e a modelagem do PEST multiobjetivo considerando a minimização do investimento e a minimização do não atendimento ao critério de segurança.

3 OTIMIZAÇÃO MULTIOBJETIVO

Muitos problemas do mundo real envolvem a otimização simultânea de diversos objetivos. Geralmente, não há uma solução única, mas um conjunto de soluções alternativas. Problemas que têm mais de um objetivo a ser alcançado são classificados como problemas de otimização multiobjetivo (PMOs). Um PMO pode ser definido, portanto, como o problema de encontrar um vetor de variáveis de decisão que satisfaça um conjunto de restrições de igualdade e de desigualdade e que otimize um vetor cujos elementos são as funções objetivo do problema [13]. Um problema multiobjetivo composto de k funções objetivo, n variáveis de decisão, m restrições de desigualdade e p restrições de igualdade pode ser formulado matematicamente como segue.

$$\min[f_1(x), f_2(x), \dots, f_k(x)] \quad (1)$$

$$\text{sujeito a} \quad (2)$$

$$g_i(x) \leq 0 \quad i = 1, 2, \dots, m \quad (3)$$

$$h_i(x) = 0 \quad i = 1, 2, \dots, p \quad (4)$$

onde $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ é o vetor de variáveis de decisão.

3.1 DOMINÂNCIA

O conceito de dominância é de grande importância para a programação multiobjetivo. Este conceito é usado pelos algoritmos multiobjetivo no intuito de determinar se uma solução x^1 é melhor do que uma solução x^2 . Para tanto, comparam-se todas as funções objetivos considerando ambas as soluções. Se existe pelo menos uma função objetivo para a qual a solução x^1 é melhor do que a solução x^2 e para os demais objetivos x^1 não é pior do que x^2 , diz-se que x^1 domina, ou é melhor do que, x^2 . Ou ainda, diz-se que x^1 é não-dominada por x^2 .

O conjunto de todas soluções não-dominadas é chamado conjunto Pareto-ótimo. Portanto, dadas duas soluções pertencentes ao conjunto Pareto-ótimo x^a e x^b , considerando que existem dois objetivos f_1 e f_2 , se $f_1(x^a)$ for melhor do que $f_1(x^b)$, então necessariamente $f_2(x^a)$ é pior do que $f_2(x^b)$. Assim, nem x^a domina x^b , nem o inverso é verdadeiro. A importância de se encontrar o conjunto Pareto-ótimo é que desta forma garante-se ao tomador de decisão que nenhuma solução não pertencente a este conjunto é melhor do que qualquer soluções do conjunto. Como a relação de dominância permite determinar se uma solução é melhor do que uma determinada outra, a maioria dos métodos multiobjetivo usa este conceito como guia de busca por soluções não dominadas.

3.2 SPEA-2

Uma aproximação da fronteira Pareto-ótima envolve dois objetivos: minimização da distância da fronteira Pareto-ótima, e a maximização da diversidade das soluções geradas. Por isso, o algoritmo *SPEA-2: Strength Pareto Evolutionary Algorithm* (SPEA-2) [14] dá ênfase a duas fases importantes dos algoritmos evolutivos multiobjetivos: seleção para reprodução e seleção para criar a nova população. A primeira questão está relacionada com o objetivo de minimizar a distância da fronteira Pareto-ótima e a segunda, com o objetivo de gerar soluções uniformemente distribuídas ao longo da fronteira Pareto-ótima. As duas fases mais

críticas do algoritmo SPEA-2 é a atribuição do valor de adaptação e a seleção dos indivíduos que formarão a próxima geração. Portanto, nas próximas seções serão detalhadas estas duas etapas do algoritmo SPEA-2.

3.2.1 ATRIBUIÇÃO DO VALOR DE ADAPTAÇÃO

No algoritmo SPEA-2, além da população atual (\mathbb{P}_t) é mantido um arquivo externo ($\bar{\mathbb{P}}_t$) formado pelas soluções não-dominadas encontradas durante a execução do algoritmo. A cada indivíduo i pertencente a $\bar{\mathbb{P}}_t$ e a \mathbb{P}_t , é atribuído um valor de força $S(i)$, que representa o número de soluções que este indivíduo domina, conforme a Eq. (5).

$$S(i) = |\{j : j \in \mathbb{P}_t \cup \bar{\mathbb{P}}_t \wedge i \succ j\}| \quad (5)$$

onde $i \succ j$ significa que i domina j .

Uma vez determinado o número de soluções que cada um dos indivíduos dominam, usa-se a Eq. (6) para definir a força de cada um dos dominadores.

$$R(i) = \sum_{j \in \mathbb{P}_t \cup \bar{\mathbb{P}}_t, j \succ i} S(j) \quad (6)$$

Em outras palavras, para cada indivíduo i , $R(i)$ representa o quanto esta solução é dominada. Assim, para soluções não-dominadas, $R(i) = 0$. Porém, embora $R(i)$ seja um mecanismo de nicho baseado no conceito de dominância, ele falha quando muitos indivíduos não são dominados entre si. Em situações como esta, o índice $R(i)$ aplicado sozinho irá falhar em relação ao objetivo de encontrar soluções bem distribuídas ao longo da fronteira Pareto-ótima. Por isso, o algoritmo SPEA-2 incorpora uma informação a mais sobre a densidade da população. O estimador de densidade de um determinado ponto usado pelo SPEA-2 é o inverso da distância do k -ésimo vizinho mais próximo do ponto. Detalhando: para cada indivíduo i , gera-se uma lista de distâncias em relação a todos os outros indivíduos ($\mathbb{P}_t \cup \bar{\mathbb{P}}_t$). Gerada a lista de distâncias, esta deve ser ordenada em ordem crescente, e o k -ésimo elemento da lista, representado como σ_i^k , dá a distância de i . Conforme sugerido por [15], k é definido como sendo igual à raiz quadrada do tamanho da amostra, portanto, $k = \lceil \sqrt{|\mathbb{P}_t \cup \bar{\mathbb{P}}_t|} \rceil$. Uma vez definida a distância do indivíduo i , sua estimação de densidade é armazenada na lista de densidades D , conforme a Eq. (7).

$$D(i) = \frac{1}{\sigma_i^k + 2} \quad (7)$$

Soma-se o σ_i^k com dois para garantir que $D(i)$ seja maior do que zero e menor do que um. Finalmente, o valor de adaptação do indivíduo i pode ser atribuído conforme a Eq. (8).

$$F(i) = R(i) + D(i) \quad (8)$$

3.2.2 SELEÇÃO

Para seleção dos indivíduos que farão parte da próxima geração, dois cuidados são levados em conta pelo SPEA-2: i) o número de indivíduos no arquivo externo é mantido constante durante toda a execução do algoritmo e ii) o método de truncamento deve evitar que as soluções limitantes sejam removidas.

Pela Eq. (8), podemos afirmar que os indivíduos não dominados terão valor de adaptação menor do que um. Isto porque a parte $R(i)$ será zero e foi tomado cuidado para que a parte $D(i)$ da equação seja menor do que um. Desta forma, o primeiro passo a ser realizado quando da seleção dos indivíduos a fazerem parte da nova geração é copiar para o arquivo externo aqueles que tiverem valor de adaptação menor do que um. Este processo pode ser definido formalmente pela Eq. (9).

$$\bar{\mathbb{P}}_{t+1} = \{i : i \in \mathbb{P}_t \cup \bar{\mathbb{P}}_t \wedge F(i) < 1\} \quad (9)$$

Da Eq. (9), três situações podem ocorrer, conforme listado abaixo.

1. $\bar{\mathbb{P}}_{t+1} = \bar{N}$: o número de soluções não-dominadas é exatamente igual ao tamanho máximo do arquivo externo. Neste caso, nada tem que ser feito e a próxima geração inicia.
2. $\bar{\mathbb{P}}_{t+1} < \bar{N}$: o número de soluções não-dominadas não é suficiente para preencher o arquivo externo. Neste caso, faz-se $\mathbb{R}_t = \mathbb{P}_t \cup \bar{\mathbb{P}}_t$ e ordena-se a população \mathbb{R}_t em ordem crescente do valor de adaptação. Após estes passos, os primeiros \bar{N} indivíduos de \mathbb{R}_t são selecionados para a próxima geração.
3. $\bar{\mathbb{P}}_{t+1} > \bar{N}$: o número de soluções não-dominadas é maior do que o tamanho máximo do arquivo externo. Nesta situação, um método de truncamento é acionado no intuito de remover indivíduos de $\bar{\mathbb{P}}_{t+1}$ até que $\bar{\mathbb{P}}_{t+1} = \bar{N}$. O método de truncamento ocorre como segue. Primeiro, tenta-se remover o indivíduo com o menor valor de σ_i^k , ou seja, procura-se remover o indivíduo que está mais próximo de um vizinho. Havendo mais de um indivíduo com o menor valor de σ_i^k (indivíduos empatados com o menor valor), seleciona-se entre estes indivíduos empatados o que tiver o menor valor para σ_i^l , onde $l = k - 1$. A variável l é iterativamente decrementado em um até que o indivíduo com menor valor para σ_i^l seja único.

O Algoritmo 1 esboça os principais passos do algoritmo SPEA-2.

Algoritmo 1: Esboço do algoritmo SPEA-2

- 1 **População inicial:** gerar uma população inicial \mathbb{P}_0 e um arquivo externo vazio $\overline{\mathbb{P}}_0 = \emptyset$. Atribuir $t = 0$.
 - 2 **Atribuição do valor de adaptação:** calcular o valor de adaptação para cada membro de \mathbb{P}_t e $\overline{\mathbb{P}}_t$ de acordo com a Seção 3.2.1.
 - 3 **Seleção:** copiar todos os elementos de \mathbb{P}_t e $\overline{\mathbb{P}}_t$ para $\overline{\mathbb{P}}_{t+1}$. Se o tamanho de $\overline{\mathbb{P}}_{t+1}$ exceder \overline{N} chame o método de truncamento. Se o tamanho de $\overline{\mathbb{P}}_{t+1}$ for menor do que \overline{N} , então preencha $\overline{\mathbb{P}}_{t+1}$ com os indivíduos dominados de \mathbb{P}_t e $\overline{\mathbb{P}}_t$, conforme a seção 3.2.2.
 - 4 **Condição de parada:** Se t for igual ao número máximo de gerações, então pare.
 - 5 **Seleção para o grupo de reprodução:** realizar torneio binário com reposição com indivíduos em $\overline{\mathbb{P}}_{t+1}$ para criar o grupo de reprodução.
 - 6 **Descendência:** aplicar os operadores de cruzamento e mutação aos indivíduos do grupo de reprodução e gerar a geração \mathbb{P}_{t+1} . Incrementar $t = t + 1$ e voltar ao passo 2.
-

3.3 MODELAGEM MATEMÁTICA

Tradicionalmente o PEST tem sido modelado matematicamente através do modelo de fluxo de carga cc, mais conhecido como modelo cc, de acordo com [4]. O modelo cc pode ser representado pelas Eqs (10-17). Onde v é o custo do investimento; c_{ij} é o custo de adição de uma linha no ramo $i - j$; S é a matriz de incidência nó-ramo transposta; θ_j é o ângulo de tensão na barra j ; γ_{ij} é a susceptância da linha adicionada em $i - j$; f_{ij} é o fluxo do ramo $i - j$; \overline{f}_{ij} é o limite superior de f_{ij} ; g é o vetor de gerações; \overline{g} é o vetor com o limite superior das gerações; d é o vetor com o valor das cargas (demandas) do sistema; n_{ij} é o número de linhas que podem ser adicionadas no ramo $i - j$; \overline{n}_{ij} é o número máximo de linhas que pode ser adicionadas no ramo $i - j$; n_{ij}^0 é número de linhas presentes na topologia base no ramo $i - j$; r representa geradores artificiais; Ω é o conjunto de todos os ramos e Ψ é o conjunto de barras do sistema.

$$\text{minimizar } v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \sum_{j \in \Psi} r_j \quad (10)$$

sujeito a

$$Sf + g + r = d \quad (11)$$

$$f_{ij} - \gamma_{ij} (n_{ij}^0 + n_{ij}) (\theta_i - \theta_j) = 0 \quad (12)$$

$$|f_{ij}| \leq (n_{ij}^0 + n_{ij}) \overline{f}_{ij} \quad (13)$$

$$0 \leq g \leq \overline{g} \quad (14)$$

$$0 \leq r \leq d \quad (15)$$

$$0 \leq n_{ij} \leq \overline{n}_{ij} \quad (16)$$

$$n_{ij} \text{ inteiro; } f_{ij} \text{ e } \theta_j \text{ irrestritos} \quad (17)$$

Uma configuração factível apresenta todos geradores artificiais com valor zero, ou seja, $\sum_{j \in \Psi} r_j = 0$, o que indica que não há corte de carga. Dada uma configuração Υ factível, e seja Γ o conjunto de todos os ramos em que existe pelo menos uma linha em Υ . Diz-se que Υ atende ao critério $n - 1$ se ao se remover uma linha pertencente a qualquer um ramo de Γ , a configuração Υ continuar sem corte de carga.

Seja $\omega^k = \sum_{j \in \Psi} r_j^k$ o corte de carga decorrente da remoção da linha $k \in \Gamma$. Portanto, o índice $\rho = \sum_{k \in \Gamma} \omega^k$ indica o quão uma configuração não satisfaz o critério de segurança $n - 1$. Assim, quanto maior o valor de ρ , menos uma configuração atende ao critério $n - 1$. Já uma configuração que apresenta $\rho = 0$ atende totalmente ao critério de segurança $n - 1$. Convencionando-se que OC representa as Eqs. (11-17), propomos o seguinte modelo para representar o PEST multiobjetivo com critério de segurança $n - 1$.

$$\text{minimizar } \begin{cases} v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \sum_{j \in \Psi} r_j \\ \rho = \sum_{k \in \Gamma} \omega^k \end{cases} \quad (18)$$

sujeito a

$$\Upsilon \in OC \quad (19)$$

4. SPEA-2 APLICADO PARA O PLANEJAMENTO DE REDES ELÉTRICAS

A adequação do algoritmo SPEA-2 para solução do PEST multiobjetivo consiste nas seguintes modificações realizadas:

Codificação do problema: A codificação do problema é um dos aspectos mais importantes para implementação do um algoritmo genético. Em nossa abordagem, utilizamos uma codificação decimal para uma proposta de solução. Portanto, a codificação é

feita através de um vetor de tamanho igual ao número de ramos candidatos (nl), em que cada elemento representa um ramo candidato do sistema. O valor de cada elemento do vetor deve variar entre 0 e \bar{n}_{ij} , ou seja, o número máximo de linhas que podem ser adicionadas. A Figura 1 ilustra a codificação que utilizamos neste trabalho.

$1-2$	$1-3$	$1-4$	$1-5$...	$1-nl$	$2-3$	$2-4$...	$2-nl$...	$(nl-1)-nl$
1	3	0	0	0	-1	0	1	0	0	2	1
											nl

Figura 1: Proposta de codificação

População inicial: para geração da solução inicial, aplicamos uma heurística construtiva. A heurística aplicada foi a heurística construtiva proposta em [4], que usa o modelo cc, representado pelas Eqs. (11-17) Na heurística de [4] as restrições de integralidade são relaxadas. O índice de sensibilidade (SI) sugerido por [4] é definido pela Eq. (20).

$$IS = \operatorname{argmax}_{ij} \left\{ \frac{1}{2} (\theta_i^* - \theta_j^*)^2 \gamma_{ij} \right\} \quad (20)$$

onde θ_i^* é o valor da variável θ_i na solução ótima do problema de programação linear (PL). Esta heurística construtiva foi alterada neste trabalho. Aqui, selecionamos $\alpha = 4$ ramos com $IS > 0$ aleatoriamente. O que tiver o maior valor de IS será o ramo vencedor e neste será adicionada uma linha.

Portanto, para gerar uma população inicial, atribuímos a configuração inicial a cada posição da população inicial e depois a submetemos ao Algoritmo 2.

Algoritmo 2: gerarPopFactível(\mathbb{P}, N).

```

/* P: população formada por indivíduos inactíveis. */
/* N: tamanho da população P. */
1 Atribuir  $i = 0$ 
2 while  $i \leq N$  do
3   |  $i = i + 1$ 
4   | Aplicar a heurística de [4] com competição para eliminar o corte de carga do indivíduos  $P_i$ .
5 end
    
```

Através do Algoritmo 2, forçamos que todos os indivíduos sejam factíveis pelo menos para o caso em que não haja falta de linhas. Em outras palavras, primeiro tornamos o indivíduo P_i factível desconsiderando a restrição de segurança. Após, é simulada a remoção de cada uma das linhas de P_i no intuito de definir o valor para o objetivo ρ .

Cruzamento e Mutação: O operador de cruzamento utilizado neste trabalho foi o de um ponto, que é selecionado aleatoriamente. Para mutação, selecionamos dois ramos aleatoriamente, um em que há linhas adicionadas (b_{add}), e outro em que não há linhas adicionadas (b_{-add}). Uma linha é removida do ramo b_{add} selecionado. Uma linha é adicionada no ramo b_{-add} selecionado. O processo é repetido $numMut$ vezes.

Como não há nenhuma garantia de que os indivíduos gerados pelo cruzamento e mutação sejam factíveis, após estes procedimentos, todos os descendentes são submetidos ao Algoritmo 2.

Nova geração: Para geração de uma nova população, utilizamos o cruzamento e a mutação. Sendo $taxCruz$ a percentagem da nova população formada por elementos gerados por cruzamento e $taxMut$ a percentagem da nova população formada por indivíduos gerados a partir da mutação.

5. RESULTADOS COMPUTACIONAIS

Para mostrar os resultados do enfoque multiobjetivo do PEST com restrições de segurança, três sistemas utilizados na literatura foram considerados: o sistema clássico de teste proposto por [3] (Garv2), o sistema teste IEEE 24 barras (IEEE24Bar) e o sistema sul brasileiro (SulBr) com redespacho da geração.

Os códigos computacionais foram desenvolvidos na linguagem Fortran 90/95 e compilados pelo compilador *GNU Fortran compiler* versão *gcc 4.4.4 20100630*. Todos os testes foram rodados em um computador *Intel(R) Core(TM)2 Duo CPU T9550 @ 2.66GHz* com sistema operacional *Linux kernel 2.6.32.23*, distribuição *Fedora 14*.

Para os sistemas e algoritmos testados, utilizamos os parâmetros mostrados na Tabela 1.

5.1 SISTEMA DE GARVER

O sistema de Garver tem 6 barras e 15 ramos. A demanda de pico é de 760,00 MW e a capacidade de geração instalada é de 760,00 MW. A solução ótima considerando somente o objetivo v apresenta a seguinte topologia e investimento de \$ 200.000,00.

Tabela 1: Parâmetros utilizados.

Parametro	Valor
N	70
\bar{N}	30
$numMut$	3% de nl
$taxCruz$	97%
$taxMut$	3%

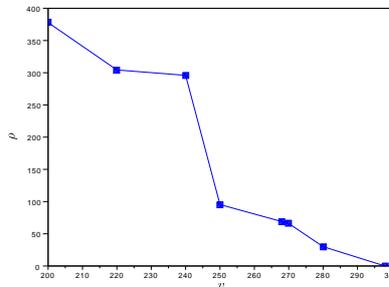


Figura 2: SPEA2: Fronteira Pareto-ótima do sistema Garv2.

$$n_{2-6} = 4, n_{3-5} = 1, n_{4-6} = 2.$$

A solução ótima considerando somente o objetivo ρ apresenta a seguinte topologia e investimento de \$ 298.000.

$$n_{2-6} = 4, n_{3-5} = 2, n_{3-6} = 1, n_{4-6} = 3.$$

O algoritmo foi executado por 500 iterações. A fronteira mostrada na Figura 2 foi encontrada após o algoritmo executar por volta de 100 iterações e não foi mais alterada.

5.2 SISTEMA IEEE 24 BARRAS

O sistema IEEE testado tem 24 barras e 41 ramos. A demanda de pico é de 8.550,00 MW e a capacidade de geração instalada é de 10.215,00 MW. Considerando somente o objetivo de minimizar o investimento do plano de expansão, a solução ótima já é conhecida na literatura [16] e tem valor de investimento de \$ $152,00 \times 10^6$ e a seguinte configuração.

$$n_{6-10} = 1, n_{7-8} = 2, n_{10-12} = 1, n_{14-16} = 1.$$

Para o objetivo em que se considera somente o critério de segurança $n - 1$, a solução ótima já é conhecida na literatura [11] e tem valor de investimento de \$ $441,00 \times 10^6$ e a seguinte configuração.

$$n_{1-5} = 1, n_{3-24} = 1, n_{4-9} = 1, n_{6-10} = 2, n_{7-8} = 2, n_{10-11} = 1, n_{11-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Ambas as soluções limitantes foram encontradas pelo algoritmo SPEA-2. A Figura 3 mostra a fronteira Pareto-ótima encontrada a partir da iteração número 100 à número 500. Pela Figura 3 podemos inferir que o algoritmo se estabilizou entre a iteração 100 e a iteração 200.

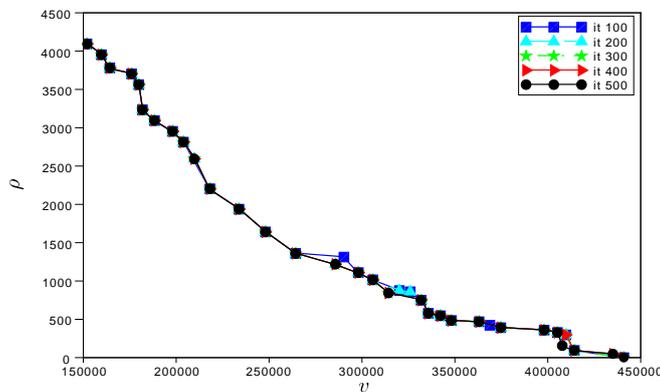


Figura 3: SPEA2: Fronteira Pareto-ótima do sistema IEEE24Bar.

5.3 SISTEMA SUL BRASILEIRO

O sistema Sul Brasileiro tem 46 barras e 79 ramos. A demanda de pico é de 6.880,00 MW e a capacidade DE geração instalada é de 10.545,00 MW. Considerando somente o objetivo de minimizar o investimento do plano de expansão, a solução ótima já é conhecida na literatura [17] e tem valor de investimento de U\$ $70.289,00 \times 10^3$ e a seguinte configuração.

$$n_{13-20} = 1, n_{20-23} = 1, n_{20-21} = 2, n_{42-43} = 1, n_{46-6} = 1, n_{5-6} = 2.$$

Para o objetivo em que se considera somente o critério de segurança $n - 1$, a solução ótima já é conhecida na literatura [11] e tem valor de investimento de U\$ $213,160 \times 10^6$ e a seguinte configuração.

$$n_{2-5} = 1, n_{5-6} = 3, n_{12-14} = 1, n_{19-20} = 1, n_{20-21} = 3, n_{20-23} = 2, n_{31-32} = 1, n_{32-43} = 1, n_{42-43} = 2, n_{42-44} = 1, n_{44-45} = 1, n_{46-6} = 2.$$

Ambas as soluções limitantes foram encontradas pelo algoritmo SPEA-2. A Figura 3 mostra a fronteira Pareto-ótima encontrada a partir da iteração número 100 à número 500. Pela Figura 3 podemos inferir que o algoritmo se estabilizou entre a iteração 200 e a iteração 300.

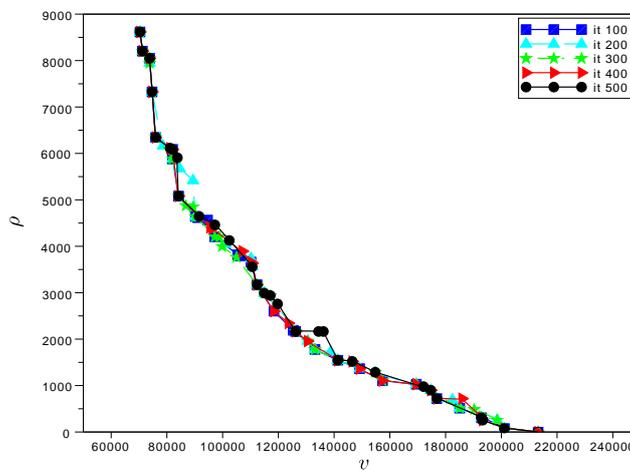


Figura 4: SPEA2: Fronteira Pareto-ótima do sistema SulBr.

Portanto, ao aplicar o modelo multiobjetivo propicia-se ao tomador de decisão em vez de uma solução (ou com o menor custo, ou que atenda completamente a restrição de segurança $n - 1$), um conjunto de soluções não-dominadas. Possibilitando desta forma que decisões realizadas em estágios posteriores levem em conta as melhores soluções possíveis quando se considera o impasse entre os dois objetivos. Cabe destacar que para todos os sistemas testados, o algoritmo evolutivo aplicado neste trabalho encontrou as soluções limitantes inferior e superior.

A Tabela 2 apresenta os dados referente ao desempenho do algoritmo quando aplicado aos sistemas testados. A coluna intervalo de convergência (FC) é referente ao intervalo de número de gerações em que o algoritmo alcançou estabilidade. A coluna NPL é o número de problemas de programação linear (PPLs) resolvidos até a última geração do intervalo de convergência. Por exemplo, na Tabela 2, 54.089 é o número de PPLs resolvidos até a geração de número 100. Da mesma forma, a coluna Tempo (s) refere-se ao tempo em segundos até a última geração do intervalo de convergência.

Tabela 2: Dados a respeito do desempenho do algoritmo SPEA2

Sistema	FC	NPL	Tempo (s)
Garv2	001 – 100	54.089	8,523
IEEE24Bar	100 – 200	274.263	795,211
SulBr	200 – 300	685.658	2.967,756

6 Conclusões

Um modelo matemático multiobjetivo e o algoritmo *SPEA-2: Strength Pareto Evolutionary Algorithm* foram aplicados para lidar com o problema de planejamento da expansão de redes de transmissão de energia elétrica com restrições de segurança. Este problema é de grande complexidade e importância para os sistemas de energia elétrica e por conseguinte, para propiciar o desenvolvimento de um país e/ou região.

Testes foram realizados com instâncias conhecidas na literatura do problema. Pelos resultados obtidos, podemos concluir que a metodologia proposta para lidar com as restrições de segurança como objetivo pode ser promissor. Para trabalhos futuros, o autores sugerem uma análise comparativa de desempenho e qualidade de solução resultantes da paralelização do algoritmo aqui testado.

7. AGRADECIMENTOS

Esta pesquisa tem sido desenvolvida com o apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

REFERÊNCIAS

- [1] R. Romero and A. Monticelli. “A Hierarchical Decomposition Approach for Transmission Network Expansion Planning”. *IEEE Transactions on Power Systems*, vol. 9, no. 3, pp. 1385–1391, Aug 1994.
- [2] V. A. Levi and M. S. Calovic. “A new decomposition based method for optimal expansion planning of large transmission networks”. *IEEE Transactions on Power Systems*, vol. 6, no. 3, pp. 937–943, 1991.
- [3] L. L. Garver. “Transmission Network Estimation Using Linear Programming”. *IEEE Transactions on Power Apparatus and Systems*, , no. 7, pp. 1688–1697, Sept. 1970.
- [4] A. Monticelli, A. Santos, M. Pereira, S. H. Cunha, B. J. Parker and J. C. G. Praca. “Interactive Transmission Network Planning Using a Least-Effort Criterion”. *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, pp. 3919–3925, 1982.
- [5] M. O. Buygi, G. Balzer, H. M. Shanechi and M. Shahidehpour. “Market-based transmission expansion planning”. *IEEE Transactions on Power Systems*, vol. 19, no. 4, pp. 2060–2067, 2004.
- [6] J. Choi, A. A. El-Keib and T. Tran. “A fuzzy branch and bound-based transmission system expansion planning for the highest satisfaction level of the decision maker”. *IEEE Transactions on Power Systems*, vol. 20, no. 1, pp. 476–484, 2005.
- [7] A. S. Sousa and E. N. Asada. “Combined heuristic with fuzzy system to transmission system expansion planning”. *Electric Power Systems Research*, vol. 81, no. 1, pp. 123 – 128, 2011.
- [8] A. Chowdhury and D. Koval. “Probabilistic assessment of transmission system reliability performance”. In *Power Engineering Society General Meeting, 2006. IEEE*. IEEE.
- [9] L. A. F. Manso and A. M. L. da Silva. “Probabilistic criteria for power system expansion planning”. *Electric Power Systems Research*, vol. 69, no. 1, pp. 51 – 58, 2004.
- [10] J. Choi, T. Tran, A. El-Keib, R. Thomas, H. Oh and R. Billinton. “A Method for Transmission System Expansion Planning Considering Probabilistic Reliability Criteria”. *Power Systems, IEEE Transactions on*, vol. 20, no. 3, pp. 1606 – 1615, 2005.
- [11] M. Rider, R. Romero, A. Garcia and C. Murari. “Transmission network expansion planning with security constraints”. In *Generation, Transmission and Distribution, IEE Proceedings-*, volume 152, pp. 828–836. IET, 2005.
- [12] L. S. Rezende, A. M. L. da Silva and L. A. F. Manso. “Planejamento da Expansão da Transmissão: Uma Discussão Sobre Confiabilidade e o Critério de Segurança “N-1””. 2010. XVIII Congresso Brasileiro de Automática, Bonito - MS.
- [13] C. A. C. Coello, G. B. Lamont and D. A. Van Veldhuizen. *Evolutionary algorithms for solving multi-objective problems*. Springer-Verlag New York Inc, 2007.
- [14] E. Zitzler, M. Laumanns and L. Thiele. “SPEA2: improving the strength Pareto evolutionary algorithm.” Technical report, Swiss Federal Institute of Technology, TIK-Report, 2001.
- [15] W. Silverman Bernard. “Density Estimation for Statistics and Data Analysis”, 1986.
- [16] R. Fang and D. J. Hill. “A new strategy for transmission expansion in competitive electricity markets”. *IEEE Power Engineering Review*, vol. 22, no. 11, pp. 60–60, 2002.
- [17] R. Romero, A. Monticelli, A. Garcia and S. Haffner. “Test systems and mathematical models for transmission network expansion planning”. *IEEE Proceedings-Generation, Transmission and Distribution*, vol. 149, no. 1, pp. 27–36, Jan. 2002.