

BUSCAS EM ESPAÇOS DE ESTADOS PARA ALOCAÇÃO ÓTIMA DE RECURSOS DE MANUTENÇÃO EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Eduardo Tadeu Bacalhau

Faculdade de Engenharia Elétrica e de Computação - UNICAMP
Cidade Universitária Zeferino Vaz, Av. Albert Einstein, 400. CEP.:13083-852, Campinas - SP
E-mail: dudubaca@densis.fee.unicamp.br

Christiano Lyra Filho

Faculdade de Engenharia Elétrica e de Computação - UNICAMP
Cidade Universitária Zeferino Vaz, Av. Albert Einstein, 400. CEP.:13083-852, Campinas - SP
E-mail: christi@densis.fee.unicamp.br

Celso Cavellucci

Faculdade de Engenharia Elétrica e de Computação - UNICAMP
Cidade Universitária Zeferino Vaz, Av. Albert Einstein, 400. CEP.:13083-852, Campinas - SP
E-mail: celsocv@densis.fee.unicamp.br

Resumo

Este artigo discute o problema de alocação ótima de recursos para manutenção de redes de distribuição de energia elétrica. O modelo matemático do problema representa os principais componentes das redes, suas inter-relações operacionais, suas confiabilidades e mudanças de condições devido a ações de manutenções. O objetivo do processo de otimização é reduzir os custos de manutenção sob restrições de operação com determinados níveis de confiabilidade, ao longo de um horizonte de planejamento. As melhores estratégias de manutenção podem ser obtidas através da solução de um problema de otimização combinatória misto, com variáveis discretas e contínuas. É desenvolvida uma meta-heurística híbrida, que utiliza buscas em espaços de estados, com articulações de *Busca em Profundidade* e *Simulated Annealing*. Um estudo de caso realizado apresenta uma comparação entre a abordagem proposta e um algoritmo genético híbrido.

PALAVRAS-CHAVE: otimização de manutenções, redes de distribuição de energia elétrica, otimização em espaços de estados.

Abstract

This paper is concerned with the optimal allocation of resources for the maintenance of electric power distribution networks. The mathematical model represents the main components of the networks, their operational interrelationships, their reliabilities and the changes in condition due to maintenance procedures. The objective of the optimization process is the reduction of maintenance costs under operations constraints with certain levels of reliability, during a given planning period. The best maintenance strategies can be obtained from the solution of a mixed combinatorial optimization problem, with continuous and discrete variables. One hybrid heuristic is developed, based on the *depth first* and *simulated annealing* state space searches. A Case study compare the proposed with an hybrid genetic algorithm.

KEY-WORDS: maintenance optimization, electric power distribution networks, state space optimization.

1 Introdução

O artigo aborda o problema de alocação ótima de recursos para manutenção de sistemas de distribuição de energia elétrica. O problema é representado através de modelo matemático considerando os componentes das redes, suas inter-relações para operação das redes, da confiabilidade e suas mudanças por ações de manutenções. O objetivo do processo de otimização é reduzir os custos de manutenção sob restrições de níveis mínimos de confiabilidade, ao longo de um horizonte de planejamento.

Vários métodos presentes na literatura foram desenvolvidos para o problema de alocação de recursos de manutenção. Encontra-se na literatura, aplicações mono-objetivo, as quais são destacadas a seguir. Endrenyi, Anders & Leite da Silva (1998) descrevem o impacto na confiabilidade do sistema de distribuição do processo de deteriorização dos elementos. O artigo apresenta a formulação para o cálculo do custo de várias alternativas de políticas de manutenção e identifica as melhores usando o método Markoviano para avaliar o impacto das variáveis de decisão na confiabilidade do sistema. Kuntz, Christie & Venkata (2002) utilizam redes neurais para previsão das taxas de falhas devido a interrupções ocasionadas pela vegetação existente ao longo dos alimentadores. As técnicas *simulated annealing*, algoritmo genético, busca tabu e combinações dessas técnicas foram utilizadas para resolver o problema de definição do cronograma de poda de árvore para redução do custo total da confiabilidade do sistema ((Russell & Norvig 2003), (Pearl 1984)). Janjic & Popovic (2007) propuseram uma abordagem com o objetivo de determinar o plano ótimo de ações de manutenção. O modelo de transição de estados se baseou em uma árvore de decisões que representam os possíveis cenários anuais de manutenções preventivas. Sittithumwat, Soudi & Tomsovic (2004) propuseram uma metodologia usando multiplicadores de taxa de falha para três níveis de manutenção: intensiva, mínima e nenhuma manutenção. As melhores políticas de manutenção são encontradas através da solução de um problema de programação linear mista. No trabalho de Reis (2007) é discutido o problema de redução dos custos de manutenção. Nesse trabalho, o autor utiliza duas abordagens de meta-heurísticas para minimizar os custos de manutenção, restritos por um nível mínimo de confiabilidade do sistema: o método GRASP (*greedy randomized adaptive search procedure*) (Feo & Resende 1995) e uma extensão do Algoritmo Genético (Holland 1975), denominado Algoritmo Genético Híbrido (AGH) que será objeto de comparação nesse artigo.

2 Modelo Matemático para o Problema de Manutenção

Os sistemas de distribuição de energia elétrica (SDDE) são definidos pelos circuitos elétricos que partem das subestações até seus clientes (consumidores de energia elétrica). Esses sistemas são constituídos de equipamentos de manobras, de proteção, de correção e de transformação, além dos alimentadores, condutores e infra-estruturas associadas com os postes, cruzetas e amarrações. Os equipamentos de proteção, como disjuntores, chaves-fusíveis, religadores, protegem a rede da propagação de falhas ocorridas ao longo dos circuitos. Esses equipamentos podem ser utilizados também para caracterizar as fronteiras das seções, como sugerem Sittithumwat et al. (2004) e Reis (2007). Em redes de distribuição radiais, se qualquer equipamento de uma seção falhar, o equipamento de proteção é acionado, causando a interrupção na transmissão da energia. Isto implica que as seções mais próximas dos alimentadores possuem importância maior em relação a confiabilidade do sistema, pois se ocorrerem falhas, um número maior de consumidores será atingido.

O sistema utilizado para estudo de caso é uma rede radial desenvolvida por Sittithumwat et al. (2004) e adaptada por Reis (2007). Sua estrutura é dispostas por seções, como ilustra a Fig. 1.

O modelo de otimização proposto por Reis (2007) caracteriza-se por uma função objetivo para minimizar os custos de manutenções corretivas e preventivas, e a restrição dada por meio do índice




Figura 1: Rede de Referência

de confiabilidade mínima do sistema, definida como a *frequência equivalente de interrupções por unidade consumidora* (FEC). As ações de manutenção são as variáveis de decisão do modelo, ou seja, os níveis de manutenção aplicado a cada equipamento, definidos como *com manutenção preventiva* ou *sem manutenção preventiva*. Estabelecido os níveis de manutenção calcula-se o custo total de manutenção e as taxas de falhas dos equipamentos para um determinado período.

2.1 Formulação Matemática

No modelo proposto a confiabilidade do sistema é medida pelo índice FEC, indicando a média de interrupções do sistema em um determinado período de planejamento. O FEC é calculado a partir das taxas de falhas e do número de clientes das seções pela equação:

$$FEC^t = \frac{\sum_{s \in S} \lambda_s^t N_s}{N_T}, \quad (1)$$

sendo S o conjunto de todas as seções, λ_s^t a taxa de falha da seção s no período t , N_s o número de clientes na seção s e N_T o número total de clientes da rede.

A taxa de falha da seção s no período t , λ_s^t , na Equação 1, pode ser calculada pelas equações:

$$\sum_{n \in N_{k_e}} x_{en}^t = 1, \quad (2)$$

$$\lambda_e^t = \lambda_e^{(t-1)} \sum_{n \in N_{k_e}} \delta_{k_e n} x_{en}^t \quad (3)$$

$$\lambda_s^t = \lambda_s + \sum_{e \in E_s} \lambda_e^t, \quad (4)$$

sendo λ_e^t a taxa de falha do equipamento e no período t , $\lambda_e^{(t-1)}$ a taxa de falha do equipamento e no ano anterior ou a taxa de falha inicial do equipamento e ($t = 1$), N_{k_e} o conjunto de todas as ações preventivas (incluindo a ação *sem manutenção*) que podem ser escolhidas, $\delta_{k_e n}$ o multiplicador de taxa de falha do equipamento de tipo k_e para a ação de nível n e x_{en}^t a variável booleana de decisão que indica se o equipamento e sofreu ($x_{en}^t = 1$) ou não ($x_{en}^t = 0$) uma manutenção de nível n no período t . Na Equação 4, λ_s é a taxa de falha base da seção s que representa uma parcela da taxa de falha associada a fatores não incorporados no modelo (é constante) e E_s é conjunto que contém todos os equipamentos e presentes na Seção s . Têm-se vários níveis de manutenção para cada equipamento, isso implica que existirá um $\delta_{k_e n}$ diferente para cada ação, determinando a taxa de falha em cada ano do período de um planejamento.

Usando-se a representação de rede descrita, pode-se caracterizar o problema matemático de otimização:

$$\min_{x_{en}^t} \sum_{t=1}^{HP} \left\{ \sum_{e \in E} \left[\sum_{n \in N_{k_e}} (p_{k_e n} x_{en}^t) + \lambda_e' c_{k_e} \right] \times \alpha_t \right\} \quad (5)$$

$$s.a.: \quad FEC^t \leq FEC_{perm} \quad \forall t = 1, \dots, HP, \quad (6)$$

sendo E o conjunto que contém todos equipamentos sujeitos à manutenção, FEC_{perm} o valor máximo permitido para o FEC, $p_{k_e n}$ o custo da ação preventiva de nível n no equipamento de tipo k_e , c_{k_e} o custo da manutenção corretiva do equipamento de tipo k_e e α_t um parâmetro associado a cada intervalo de tempo.

O parâmetro α_t visa equilibrar a distribuição das ações de manutenção ao longo dos intervalos do horizonte de planejamento (HP). Nessa formulação, α_t é definido como o ‘valor presente dos investimentos’:

$$\alpha_t = \left(\frac{1}{1+j} \right)^t, \quad (7)$$

sendo t o período e j a taxa de juros aplicada ao investimento.

3 Estratégias de Buscas em Espaços de Estados

Busca em espaços de estados é uma das técnicas utilizadas para resolução de problemas em Inteligência Artificial (Russell & Norvig 2003). A estratégia da busca em espaços de estados supõe a existência de um estado inicial, um conjunto de ações que podem ser executadas para realizar transições de estados e estados metas. A solução para esse problema consiste em achar uma sequência de ações que, partindo de um estado inicial, encontre um estado meta.

O problema de alocação ótima de recursos de manutenção para redes de distribuição de energia elétrica pode ser abordada por uma busca em espaço de estados. Seja $S_{m \times n}$ uma matriz, na qual m representa o número de anos definidos para o horizonte de planejamento em um dado problema de alocação ótima de recurso de manutenção e n o número de equipamentos de uma rede. Essa matriz pode representar um estado do problema, que caracteriza um determinado conjunto de ações de manutenção. Sendo assim, S_0 é uma matriz que representa um estado inicial para esse problema, ou seja, a primeira solução. Para um exemplo no qual a rede possui 30 equipamentos e o horizonte de planejamento definido é de três anos, S_0 pode ser construído da seguinte forma:

$$S_0 = \begin{bmatrix} 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 1 \end{bmatrix},$$

sendo 1 a representação da ação *com manutenção preventiva* e 0 a representação da ação *sem manutenção preventiva*.

Essas soluções estão definidas em um espaço de solução de tamanho $2^{(n \cdot HP)}$, no qual o estado meta é um planejamento de manutenção para o problema que fornece o menor valor de custo.

A sequência que define as ações programadas para a busca por soluções para o problema é determinada pela escolha dos processos de transição definidos nas operações, que podem ser definidas como:

$$tipodeaçãoescolhido(S, S')$$

sendo S o estado atual e S' o estado sucessor fornecido pela ação escolhida ($S \rightarrow S'$).

Como estratégia de busca aplicada ao problema de manutenção foram desenvolvidas heurísticas que exploram vários métodos. Chegou-se a construção de três metaheurísticas (Bacalhau 2009),

baseadas em diversas combinações da busca em profundidade (Pearl 1984), busca em largura (Pearl 1984) e o método *Simulated Annealing* (Michalewicz & Fogel 2000). Dentre essas meta-heurísticas, a combinação da busca em profundidade com o método *Simulated Annealing* obteve os melhores resultados, por isso será a meta-heurística utilizada para o estudo de comparação.

3.1 Busca em Profundidade

Na busca em profundidade a prioridade é buscar o nó de nível mais profundo da árvore de busca (Pearl 1984). A estratégia da busca em profundidade é expandir o nó analisado, explorando primeiro os nós gerados (filhos) por esse nó antes que os outros nós encontrados (irmãos) sejam analisados.

A busca em profundidade proposta, possui uma função de avaliação para a escolha dos filhos, ou seja, ela inclui características de uma busca informada.

3.2 Simulated Annealing

O *Simulated Annealing* foi proposto por Kirkpatrick, Gelatt & Vecchi (1983) como uma estratégia de determinação de estados de equilíbrio de uma coleção de átomos a uma dada temperatura.

A execução do movimento é baseada em uma probabilidade que vai diminuindo exponencialmente, à medida em que um movimento ruim é executado. Se o movimento realizado melhorar a função de avaliação, ele sempre será aceito. Caso contrário, o algoritmo aceitará o movimento com uma probabilidade $p < 1$.

A probabilidade p depende da qualidade relativa entre os valores da função de avaliação quando aplicada aos pontos, e da variável de 'temperatura', T :

$$p = 1 / (1 + (\exp((val(s) - val(s'))/T))) , \quad (8)$$

sendo s o ponto inicial, s' o ponto do movimento seguinte, $val(s)$ o valor da função avaliada no ponto s , $val(s')$ o valor da função avaliada no ponto s' e T a variável 'temperatura'.

4 Otimização em Espaços de Estados para o Problema de Manutenção

A busca em profundidade informada desenvolvida, combinada com o método de *Simulated Annealing*, produz uma meta-heurística híbrida. Nessa meta-heurística diversos tipos de ações de transição de estados são explorados. A estrutura da meta-heurística é apresentada da seguinte forma:

- Procedimento de Busca em Profundidade com *Simulated Annealing* (BPS)
 - Heurística Construtiva (HC)
 - Busca Inicial - Busca em Profundidade (BI)
 - *Simulated Annealing* (SA)

A Heurística Construtiva tem como função diminuir o número de iterações do algoritmo, elaborando uma primeira solução melhorada para o processo. A Busca Inicial tem a função de ser o primeiro processo, direcionando a primeira solução para uma solução melhorada. O *Simulated Annealing* é o principal processo, realizando a busca por melhores soluções com informação do problema.

4.1 Heurística Construtiva

Para a construção da solução inicial, a HC é auxiliada pelo uso de funções custo/benefício (CB) que determinam uma medida de investimento para cada equipamento. Dois tipos de funções CB são elaboradas:

$$CB1(t, e) = \frac{(M_{SM_e} - M_{CM_e})N_e}{C_{MP_e}\alpha_t \exp(t)} \quad e \quad (9)$$

$$CB2(t, e) = \frac{(FEC_{perm} - FEC_{min})(M_{SM_e} - M_{CM_e})N_e}{C_{MP_e}\alpha_t}, \quad (10)$$

sendo M_{SM_e} o multiplicador da taxa de falha para o equipamento e definido sem manutenção preventiva, M_{CM_e} o multiplicador da taxa de falha para o equipamento e definido com manutenção preventiva, N_e o número de clientes presentes na seção onde o equipamento e pertence, C_{MP_e} o custo de manutenção preventiva prevista para o equipamento e , α_t o parâmetro definido na subseção 2.1 para o período t , FEC_{perm} o máximo valor de FEC permitido e FEC_{min} o valor de FEC calculado para a formulação quando a qualidade de serviço é máxima.

Essas funções são escolhidas de acordo com o valor de FEC_{perm} definido. Escolhida a função CB, ela é calculada para todos elementos de S , armazenando os valores calculados na matriz MI de medida de investimentos. Em seguida, é obtido o maior valor de medida de investimento, MI_{max} . Esse valor é comparado com cada uma das medidas de investimento calculada. Se a medida de um elemento possuir um valor maior ou igual ao valor da maior medida selecionada, o elemento recebe manutenção, caso contrário, não recebe manutenção, construindo uma solução inicial.

Testa-se a factibilidade dessa solução inicial. Se ela for factível, a HC termina e o algoritmo retorna a solução construída, senão essa estratégia é reiniciada, selecionando a segunda maior medida de investimento em CB. Esse procedimento segue até que a solução inicial elaborada seja factível, dada a restrição de confiabilidade (FEC).

A estratégia da HC encontra a primeira solução factível, portanto terá um valor de restrição próximo do valor do FEC_{perm} . Isso implica uma redução dos passos de buscas do algoritmo, podendo acarretar uma convergência prematura. Para diminuir esse risco, realiza-se uma busca inicial utilizando o método de *busca em profundidade*, a fim de explorar as melhores alternativas de soluções.

4.2 Busca Inicial

Na BI o processo de transição de estados é dado por movimentos aplicados a cada combinação possível de pares de elementos. Esses movimentos alteram apenas um par de elementos da solução por iteração do movimento. Os pares são selecionados a partir de uma solução modelo definida através da função CB construída em HC. Para cada par de elementos, uma solução é produzida, determinando a regra transição. A busca em profundidade é executada quando nenhuma melhoria é encontrada, pelo movimento, na solução atual. O término da BI é dado por dois critérios de parada. O número de iterações ou o parâmetro que mede o grau de eficiência do método de busca.

O processo de transição da BI é resumido no Pseudo-código 1 ilustrado na Fig.2.

4.3 Simulated Annealing

O método do *Simulated Annealing* procura melhorar a solução fornecida, evitando regiões de atração de ótimos locais. A estratégia realiza movimentos com certo grau de aleatoriedade, visando ampliar a área de exploração do espaço de estados e encontrar soluções mais diversificadas. Alguns movimentos tratam o conhecimento prévio sobre o problema, outros realizam uma exploração ampla do espaço de estados e os demais procuram manter a generalidade da solução inicial.

Pseudo-código 1 Busca Inicial - Profundidade (S)

```
1:  $S_{aux} \leftarrow S$ 
2:  $PILHA \leftarrow S$ 
3: Repita
4:    $S_{s'} \leftarrow Movimento\ 1$ 
5:   Selecciona  $S' \in S_{s'}$  com menor valor de custo
6:   Se  $Custo(S') < Custo(S_{aux})$  então
7:      $S \leftarrow S'$ 
8:      $S_{aux} \leftarrow S'$ 
9:     insira  $S'$  na  $PILHA$ 
10:  Se  $Custo(S') < CustoFinal$  então
11:     $S_{final} \leftarrow S'$ 
12:     $CustoFinal \leftarrow Custo(S')$ 
13:  Fim Se
14:  Senão
15:     $S_{aux} \leftarrow$  primeiro da  $PILHA$ 
16:    retira o primeiro da  $PILHA$ 
17:    Se  $PILHA \neq$  vazio então
18:       $S \leftarrow$  primeiro da  $PILHA$ 
19:    Senão
20:      Encerra a Busca
21:    Fim Se
22:  Fim Se
23: Até que (Limite de Iteração)
```

Retorna: S_{final}

Figura 2: Pseudo-código 1

O processo possui uma estrutura semelhante à apresentada na BI, porém nesta estratégia dois tipos de movimentos são sorteados e executados a cada iteração. Esses dois tipos de movimentos são escolhidos através da elaboração de dois subconjuntos de contém tipos de movimentos diferentes. O primeiro subconjunto possui um tipo de movimento que se assemelha àqueles executados nas BIs e o segundo subconjuntos possui tipos de movimentos mais diversificados.

É sorteado um tipo de movimento para cada subconjunto, produzindo uma nova solução. O melhor movimento, dado pelo valor de custo da função objetivo, é selecionado para a continuação do procedimento. Se o valor do custo dessa solução for menor que o valor do custo dado pela solução atual, a solução atual é substituída. Senão, é executado o procedimento com a probabilidade p . Calcula-se a probabilidade p usando a Equação 8 com valor inicial de temperatura $T = 1$ e avalia-se o valor de p . Se o valor de p for menor ou igual a um valor específico determinado no algoritmo, a solução atual é substituída pela solução encontrada e o valor da temperatura é atualizado seguindo um procedimento de redução geométrico, como ilustra a seguinte Equação:

$$T = r.T, \quad (11)$$

sendo $r = 0,95$ o valor da taxa de resfriamento da temperatura.

Contudo, se o valor da probabilidade p for maior que o valor especificado, um contador mede o grau de funcionalidade do método SA, analisando o número de ocorrências da solução sucessora dada pelos movimentos, determinando, ou não, o fim da busca. Esse critério de parada pode ser associado ao resfriamento da temperatura, pois conforme a temperatura diminui menor é a chance de uma solução ruim ser escolhida.

Além desse critério de parada, outros dois critérios podem determinar a interrupção do processo: parâmetro que mede a eficácia dos movimentos executados; e o número máximo de iterações. O Pseudo-código 2 ilustrado na Fig.3, resume esse processo de busca realizado pelo método *Simulated Annealing*.

Pseudo-código 2 Simulated Annealing (S_{final})

- 1: $CustoFinal \leftarrow Custo(S_{final})$
- 2: inicia T
- 3: **Repita**
- 4: efetua *movimento* 1 sorteado
- 5: efetua *movimento* 2 sorteado
- 6: Guarda as soluções
- 7: Seleciona a melhor delas e armazena em S'_{final}
- 8: **Se** $Custo(S'_{final}) < Custo(S_{final})$ **então**
- 9: $S_{final} \leftarrow S'_{final}$
- 10: **Se** $Custo(S'_{final}) < CustoFinal$ **então**
- 11: $CustoFinal \leftarrow Custo(S'_{final})$
- 12: **Fim Se**
- 13: **Senão**
- 14: Calcule p
- 15: **Se** $p \leq \text{valor específico}$ **então**
- 16: $S_{final} \leftarrow S'_{final}$
- 17: atualiza $T = r.T$
- 18: **Senão**
- 19: testa *grau de funcionalidade*
- 20: **Fim Se**
- 21: **Fim Se**
- 22: **Até que** (*Limite de Iteração* ou *falha do grau de funcionalidade* ou *parâmetro de eficácia do método satisfeito*)

Retorna: S_{final}

Figura 3: Pseudo-código 2

Para resumir a combinação desses processos é apresentado um fluxograma, ilustrado na Fig. 4.




Figura 4: Fluxograma do Algoritmo BPS

5 Estudo de Caso

Dois sistemas de rede de distribuição são testados no caso da Rede de Referência. O primeiro caso é a rede de referência que contém 30 equipamentos distribuídos em sete seções. O segundo caso é uma ampliação da rede contendo 76 equipamentos distribuídos nas mesmas sete seções. Nos dois casos existem dez tipos diferentes de equipamentos. A Tabela 1 ilustra os equipamentos presentes nas redes e seus respectivos valores de Custo de Manutenção Corretiva (*CMC*), Custo de Manutenção Preventiva (*CMP*), Multiplicador das Taxas de Falhas para a ação de Manutenção

Preventiva (*Mtx MP*), Custo Sem Manutenção (*CSM*), Multiplicador das Taxas de Falhas para a ação Sem Manutenção (*Mtx SM*) e Taxas de Falhas Iniciais (*TF Inicial*).

Tipo	CMC (R\$ x 1000)	CMP (R\$ x 1000)	Mtx MP	CSM (R\$ x 1000)	Mtx SM	TF Inicial (falha/ano)
Cabo	0.06	0.03	0.92	0	1.08	0.02
Infraestrutura 1	0.94	0.47	0.79	0	1.26	0.05
Infraestrutura 2	0.94	0.47	0.79	0	1.26	0.05
Poste 1	14.5	7.25	0.69	0	1.2	0.001
Poste 2	14.5	7.25	0.69	0	1.2	0.001
Regulador	16	8	0.89	0	1.12	0.029
Religador	1.2	0.6	0.91	0	1.28	0.015
Poda de Rede 1	2.05	1.025	0.95	0	1.51	0.05
Poda de Rede 2	1.05	0.525	0.95	0	1.51	0.05
Transformador	1.692	0.846	0.95	0	1.51	0.01

Tabela 1: Tipos de Equipamentos

Nesse experimento, a meta-heurística desenvolvida BPS é comparada à abordagem por algoritmo genético, o Algoritmo Genético Híbrido (AGH) desenvolvido por Reis (2007). O AGH e o algoritmo BPS são executado 5 vezes para cada cenário estudado, selecionando o menor valor de custo dado pela função objetivo, a média dos valores de custo e os tempos médios das 5 execuções. Os valores são apresentados na Tabela 2.

Caso I	AGH			BPS		
	Melhor Solução (R\$ x 1000)	Solução Média (R\$ x 1000)	Tempo Médio (segundos[s])	Melhor Solução (R\$ x 1000)	Solução Média (R\$ x 1000)	Tempo Médio (segundos[s])
HP=3, FEC=0,40 e Tx 10%	21,0907	21,0918	6,9800	21,1583	21,1704	13,8032
HP=3, FEC=0,40 e Tx 15%	20,0911	20,4236	7,7253	20,2307	20,2790	14,1000
HP=3, FEC=0,55 e Tx 10%	14,4249	14,6224	6,6425	14,2601	14,4014	4,9782
HP=3, FEC=0,55 e Tx 15%	13,6644	13,8327	3,9525	13,4375	13,4749	5,5678
HP=3, FEC=0,95 e Tx 10%	7,2746	7,2746	2,8442	7,2746	7,2746	5,2345
HP=3, FEC=0,95 e Tx 15%	6,9220	6,9220	3,2551	6,9220	6,9220	4,7514
HP=5, FEC=0,40 e Tx 10%	36,9316	37,0354	13,2037	37,5483	38,0230	214,6250
HP=5, FEC=0,40 e Tx 15%	33,4602	33,8188	14,6742	33,8446	34,2302	202,1406
HP=5, FEC=0,55 e Tx 10%	30,0111	30,2218	19,4561	29,6738	29,7502	132,3570
HP=5, FEC=0,55 e Tx 15%	27,4911	27,7534	17,0217	26,7379	26,9758	133,7816
HP=5, FEC=1,82 e Tx 10%	15,5581	15,5581	2,6873	15,5581	15,5581	34,1177
HP=5, FEC=1,82 e Tx 15%	13,9953	13,9953	3,4601	13,9953	13,9953	35,6900
Caso II						
HP=3, FEC=0,72 e Tx 10%	119,9894	119,9894	18,7190	119,6642	120,4471	3817,9187
HP=3, FEC=0,72 e Tx 15%	118,1152	118,1152	26,5943	119,5900	119,9294	4130,7843
HP=3, FEC=1,00 e Tx 10%	32,3090	32,3566	12,5471	32,1219	32,3283	1175,9625
HP=3, FEC=1,00 e Tx 15%	30,8709	30,9080	27,3592	30,4572	30,5125	829,8625
HP=3, FEC=1,82 e Tx 10%	15,1706	15,1706	4,8443	15,1706	15,1706	16,6970
HP=3, FEC=1,82 e Tx 15%	14,4568	14,4568	5,9850	14,4568	14,4568	15,5931

Tabela 2: Comparação dos resultados

Para o planejamento serão estudados os dois Casos de Rede desenvolvidos. No Caso I os algoritmos são executados variando o Horizonte de Planejamento ($HP = 3$ e $HP = 5$), o FEC (0,40, 0,55 e 0,95 para $HP = 3$ e 0,40, 0,55 e 1,82 para $HP = 5$) e a taxa de juros anual (10% e 15%). No Caso II apenas o FEC (0,72, 1,00 e 1,82) e a taxa de juros anual (10% e 15%) variam, mantendo o Horizonte de Planejamento fixo ($HP = 3$).


Quando a qualidade de serviço tem uma restrição mais apertada (FEC=0,40 e FEC=0,72) o AGH obtém boas soluções finais, sendo um pouco superiores às obtidas pelo algoritmo BPS, porém em alguns casos com a média dos valores de custo inferior. Quando o número de equipamentos da rede cresce, a diferença entre os resultados obtidos por esses algoritmos diminui, nos quais, em

alguns cenários, o algoritmo BPS obtém melhores resultados quanto aos melhores valores obtidos.


À medida que essa restrição de serviço vai ficando mais folgada ($FEC=0,55$ e $FEC=1,00$), o algoritmo BPS obtém bons resultados comparados ao AGH, superando em todos os cenários desenvolvidos. Os valores de tempo médio obtidos são muito distintos, sendo muito maiores para o algoritmo BPS. Isso é devido ao fato de que o algoritmo BPS foi implementado em uma linguagem de programação considerada inferior (MatLab) à linguagem de programação utilizada para a implementação do AGH (Java).

Quando a restrição do problema deixa de existir ($FEC=0,95$ e $FEC=1,82$), os dois algoritmos obtém os mesmos resultados, mostrando que a estratégia de busca presente é eficiente quanto à liberdade de manutenção, porém a diferença entre os valores de tempo médio continua grande.

Os melhores resultados obtidos pelo algoritmo BPS são detalhados nos *boxplots*¹ apresentados nas figuras 5(a), 5(b) e 5(c). Os *boxplots* tem o objetivo de conduzir uma análise sobre comportamento dos algoritmos, quanto aos valores de custo das soluções finais encontradas pelas 5 execuções programadas no experimento.



(a) Boxplot 5 - Caso I - $FEC = 0.55$, $HP=3$ e Juros 15% (b) Boxplot 6 - Caso I - $FEC = 0.55$, $HP=5$ e Juros 10%



(c) Boxplot 7 - Caso II - $FEC = 1.00$, $HP=3$ e Juros 15%

Figura 5: Comparação dos resultados do algoritmo BPS e AGH

Os *boxplots* ilustram o bom desempenho do algoritmo BPS independente do tamanho da rede executada. O AGH mostra um bom comportamento apenas no Caso de Rede II, porém a diferença entre os resultados obtidos pelos dois algoritmos aumenta.

¹Gráficos que possibilitam representar a distribuição de um conjunto de dados com base em alguns de seus parâmetros descritivos.

6 Conclusão

A principal contribuição do artigo foi descrever uma metodologia baseada em buscas em espaços de estados para o problema de alocação ótima de recursos para manutenção em redes de distribuição de energia elétrica. Sua principal referência foi o trabalho realizado por Reis (2007), que desenvolveu um modelo matemático para representar o problema e propôs uma abordagem para a solução, um algoritmo genético híbrido.

A heurística desenvolvida, denominada BPS, utiliza um procedimento construtivo guiado por uma função de avaliação do custo/benefício, seguido de uma *busca em profundidade* informada. Ao final da *busca em profundidade* é realizado um procedimento de melhoria baseado no método *Simulated Annealing*. Criou-se um conjunto de ações de transição de estados específicos para o problema estudado, que incorporam conhecimento sobre o problema e procedimentos de diversificação, com o objetivo de alcançar regiões promissoras do espaço de soluções, mas ao mesmo tempo procurando evitar no espaço de buscas regiões nas quais soluções ótimas locais exercem atração excessiva.

As avaliações que comparam o método desenvolvido com o algoritmo genético híbrido proposto por Reis (2007) permitem as seguintes observações: nas redes de menor porte, o algoritmo de busca em espaço de estados forneceu as melhores soluções em situação na qual a restrição de confiabilidade foi mais folgada; em casos nos quais as restrições de confiabilidade são mais apertadas, o algoritmo genético híbrido apresentou os melhores resultados; nas instâncias de maior porte, o algoritmo BPS obteve melhores resultados do que o algoritmo genético híbrido na maioria dos casos, tanto em situações com confiabilidade muito restrita, quanto em situações menos exigentes em termos de confiabilidade.

Acredita-se que o processo de busca em espaços de estados conseguiu um melhor comportamento para esse tipo de problema por beneficiar certos aspectos qualitativos desejáveis em políticas de manutenção. Alguns desses aspectos foram incorporados aos operadores de transição.

Agradecimentos

Os autores agradecem o apoio da CAPES e CNPQ.

Referências

- Bacalhau, E. T. (2009). *Metaheurísticas para alocação ótima de recursos de manutenção em redes de distribuição de energia elétrica*, Mestrado, Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, Campinas - SP - Brazil.
- Endrenyi, J., Anders, G. & Leite da Silva, A. (1998). Probabilistic evaluation of the effect of maintenance on reliability. an application, *IEEE Transactions on Power Systems* **13**(2): 576–583.
- Feo, T. & Resende, M. (1995). Greedy randomized adaptive search procedures, *Journal of Global Optimization* **6**: 109–133.
- Holland, J. (1975). *Adaptation in Natural and Artificial Systems*, The University of Michigan Press.
- Janjic, A. & Popovic, D. (2007). Selective maintenance schedule of distribution networks based on risk management approach, *IEEE Transactions on Power Systems* **22**(2): 597–604.
- Kirkpatrick, S., Gerlatt, C. D. J. & Vecchi, M. P. (1983). Optimization by simulated annealing, *Science* **220**: 671–680.

- Kuntz, P., Christie, R. & Venkata, S. (2002). Optimal vegetation maintenance scheduling of overhead electric power distribution systems, *IEEE Transactions on Power Delivery* **17**(4): 1164–1169.
- Michalewicz, Z. & Fogel, D. B. (2000). *How to Solve it*, Spring-Verlag, New York.
- Pearl, J. (1984). *Intelligent Search Strategies for Computer Problem Solving*, Addison-Wesley Publishing Company., Los Angeles, California, U.S.A.
- Reis, P. A. (2007). *Otimização baseada em confiabilidade de planos de manutenção de sistemas de distribuição de energia elétrica*, Mestrado, Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, Campinas - SP - Brazil.
- Russell, S. & Norvig, P. (2003). *Artificial Intelligence: A Modern Approach*, 2nd edn, Prentice-Hall, Englewood Cliffs, NJ.
- Sittithumwat, A., Soudi, F. & Tomsovic, K. (2004). Optimal allocation of distribution maintenance resources with limited information, *Electric Power Systems Research* **68**: 208 – 220.