

# OTIMIZAÇÃO DA LOGÍSTICA DE MANUTENÇÃO CORRETIVA EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA POR ALGORITMOS GENÉTICOS

<sup>1,2</sup>EDSON BOBEL, <sup>2</sup>HEITOR S. LOPES

<sup>1</sup> COPEL-Companhia Paranaense de Energia  
Rua José Izidoro Biazetto 158 bl B  
81200-240 - Curitiba, PR

<sup>2</sup> Centro Federal de Educação Tecnológica do Paraná  
Prog. de Pós-Grad. em Eng. e Inf. Industrial  
Av. 7 de setembro, 3165 - 80230-901 - Curitiba, P

*E-mails:* hslopes@cefetpr.br, ebobel@onda.com.br

**Resumo** — Um dos problemas enfrentados pelas concessionárias de Energia Elétrica está relacionado à manutenção. Este trabalho tem como foco alocar as equipes de manutenção de redes de energia elétrica a fim de que os custos relacionados a interrupções no sistema e das respectivas equipes sejam minimizados. A alocação de equipes de manutenção tem dois aspectos: se forem estabelecidas muitas equipes estrategicamente distribuídas ter-se-á uma redução no tempo de atendimento a defeitos no sistema, entretanto o custo fixo relativo às equipes são altos. Por outro lado, se poucas equipes forem alocadas, o tempo para o atendimento se torna muito elevado e outros problemas relativos à qualidade do fornecimento de energia vêm à tona, implicando, além da energia não faturada, possíveis indenizações a serem pagas a consumidores, multas aplicadas pela Agência Nacional de Energia Elétrica (ANEEL) devido a contratos de fornecimentos específicos.

**Abstract** — This work is aimed to apply Genetic Algorithms to minimize maintenance costs in the specific area of electric power distribution. A power distribution network has several equipments (switchers, circuit breakers, transformers, etc) which are subject to periodical maintenance procedures (either corrective or preventive). A team of technicians based in a viable place is responsible for a given number of equipments. In this work we used real-world historical data about previous malfunctions in the network in order to establish the points where maintenance teams have to be located so as to minimize costs and allow an efficient service. Results obtained so far encourages further development of the system.

**Keywords:** Genetic Algorithms, Logistics, Planning, Electric Energy, Optimization

## 1 Introdução

Para o estudo de caso deste trabalho, foram utilizados dados reais da área de Distribuição da COPEL, região de Maringá. Os possíveis locais para as equipes de manutenção, por definição, são os municípios sob sua responsabilidade. Para este estudo são considerados 10 municípios daquela região. Quanto aos locais a serem submetidos a manutenção, foram consideradas todas as chaves existentes na rede da região de responsabilidade de Maringá, perfazendo 1072 chaves.

Devido à complexidade e dimensionalidade do problema utilizou-se uma técnica envolvendo Algoritmos Genéticos (Lopes, 1999), pois considerar todas as combinações possíveis torna o problema intratável pelos sistemas computacionais atuais. Outro aspecto relevante a considerar é que, na prática, as regiões têm mais locais para alocação de equipes e o número de locais a serem submetidos à manutenção é bem maior do que o considerado neste trabalho, caso o estudo considerasse toda a região de abrangência da concessionária.

## 2 Metodologia

### 2.1 Informações necessárias

Como o objetivo do trabalho é a minimização dos custos de manutenção, considerando a ocorrência das interrupções na região em estudo conforme o histórico do ano de 1999, as informações necessárias para o modelamento do problema e implementação da abordagem por Algoritmos Genéticos foram fornecidas pela COPEL, setor de Distribuição, e são as seguintes:

- Histórico das interrupções ocorridas em cada chave no ano em estudo, no caso 1999. Estes registros contém informações relativas à potência média na chave, tempo de interrupção, quantidade de consumidores interrompidos bem como as coordenadas geográficas da chave.
- Relação dos possíveis locais para alocar as equipes de manutenção com sua respectiva coordenada geográfica.

## 2.2 Variáveis do problema e Codificação

Para a região em estudo, existem 10 municípios em potencial para a alocação das equipes e 1072 chaves distribuídas nesta região. Para a implementação do algoritmo, utilizou-se a codificação binária tradicional, com 4 bits para representar cada um dos 10 possíveis municípios onde uma equipe pode ser alocada. Cada uma das 1072 chaves são as variáveis do problema que devem ser alocadas a uma determinada equipe. Desta forma, definiu-se que cada indivíduo (possível solução do problema) do AG terá 1072 genes, cada um com 4 bits. Esta codificação leva a um espaço de busca de  $2^{(4 \times 1072)}$  ou, aproximadamente,  $10^{1072}$ , o que é intratável por métodos enumerativos tradicionais.

## 2.3 Restrições

Numa primeira abordagem, não foi colocada nenhuma restrição importante ao problema, para que seja possível verificar as características de convergência. A única exceção é que nenhuma chave pode ser atendida por dois locais distintos. Porém isto não pode ocorrer em função da codificação adotada. Há que ser lembrado que neste problema há a possibilidade de que um ou mais municípios não atendam nenhuma chave ou até mesmo um único município atender todas as chaves.

## 2.4 Função objetivo e de fitness

Como a natureza do problema é de minimização e, por definição, um Algoritmo Genético procura por um valor máximo, há a necessidade de se obter o custo (estimado) para a pior situação, de modo a converter um problema de minimização em maximização. Desta forma, inicialmente considerou-se como função objetivo a equação (1):

$$g = \left( \sum_{chave=1}^{1072} PM_{chave} * TD * TAR \right) + NEQP * CEQP \quad (1)$$

onde:

$PM$  = Potência média na chave em kW;

$TD$  = Tempo de deslocamento da equipe que atende a chave até a mesma;

$TAR$  = Valor do kWh;

$NEQP$  = Número de equipes da solução encontrada;

$CEQP$  = Custo anual de cada equipe.

O custo anual de cada equipe de manutenção foi estimado pela Concessionária em 85.000. O valor obtido foi de aproximadamente 11.000.000. Para o pior caso possível (hipotético), obteve-se um valor estimado de 12.000.000 para a função objetivo, sendo este o valor utilizado como constante para a

transformação do problema de minimização em maximização, conforme (Goldberg, 1989).

Para a simplificação do modelamento, o cálculo do tempo de deslocamento considera que a distância do local onde se encontra a equipe até o da chave a ser reparada vai ser percorrida em linha reta, sem obstáculos, a uma velocidade média de 40km/h.

Para que se possa observar melhor a evolução da solução ao longo das gerações é usual normalizar-se a função de *fitness* para que a mesma tenha um intervalo de variação de 0 a 1. Assim, a função de *fitness* final é definida pela equação 2, com base na função objetivo anteriormente definida (equação 1):

$$f = 12000000 - \frac{g}{12000000} \quad (2)$$

## 2.5 Parâmetros do Algoritmo Genético

O número de indivíduos da população de soluções foi estabelecido em 250 e o critério de parada do algoritmo foi o alcance de um número superior de gerações (definido posteriormente). O método de seleção utilizado foi o da amostragem universal estocástica, pelo fato de não ser muito agressivo. Os operadores genéticos utilizados foram os tradicionais *crossover* de um ponto e mutação de um bit, aplicados com probabilidade respectivamente de 0,7 e 0,005.

## 3 Simulações e Resultados

Para a implementação da solução computacional do problema foi utilizado como base um *software* de domínio público, o GALOPPS, versão 3.2 (Goodman, 1986), escrito em linguagem C.

O *software* foi rodado várias vezes em um PC Pentium III (500 MHz, 64 Mb RAM) e os melhores resultados obtidos estão sumarizados na tabela 1, onde se mostra o número máximo de gerações de cada experimento, o custo minimizado obtido e o tempo aproximado de processamento.

A solução obtida para a alocação das 10 equipes na região é mostrada nas figuras 2 a 11, com os nomes dos respectivos municípios e os 1072 pontos de manutenção alocados às equipes. Infelizmente, a resolução não permite uma observação mais acurada, porém, por inspeção, percebe-se que há uma distribuição bastante concisa e factível.

Tabela 1: Resultados dos experimentos computacionais.

Número máximo de gerações	Menor custo total obtido	Tempo total de processamento
1000	2.299.992,05	6min
10000	1.863.442,01	1h
35000	1.693.106,62	3h
50000	1.680.391,89	5h
100000	1.676.559,51	8,5h

A figura 12 mostra a curva de evolução da melhor solução ao longo de 100000 gerações, mostrando que, com cerca de 6000 gerações, o algoritmo genético já encontrou uma solução melhor do que a atualmente existente.

#### 4 Análise dos Resultados

Utilizando-se a equação de custo (1) com os dados referentes à situação atual, não otimizada (figura 1), para a equipe lotada em Maringá e que atende toda a região, obtêm-se um custo de 1.504.741,02. Entretanto, este valor refere-se a uma equipe e existem 7 equipes de manutenção que atendem as áreas, desta forma a este custo deve ser acrescido os custos provenientes das outras 6 equipes (510.000,00) o que totaliza 2.014.741,02.

Com o melhor valor obtido na geração 99078 (da rodada de 100000 gerações da tabela 1) tem-se uma economia de **338.181,51** unidades monetárias em relação à situação atual com base nas considerações contempladas no presente trabalho.

Salienta-se ainda que, na realidade, existem várias pequenas equipes de manutenção compostas de apenas uma pessoa que presta o atendimento inicial, chamado de emergência e realiza pequenas manutenções cujos elementos não foram considerados no presente estudo. Somente na cidade de Maringá existem 22 pessoas que prestam este tipo de atendimento.

#### 5 Conclusões e Trabalhos Futuros

Como exposto anteriormente, o trabalho considerou várias simplificações as quais podem ser refinadas a fim de se chegar a condições bem mais próximas da realidade entre as quais pode-se salientar:

- Tempo de deslocamento até o local onde há um equipamento para ser feita a manutenção. No presente estudo, considerou-se uma velocidade uniforme de 40km/h e uma distância reta entre o local da equipe e do defeito para o cálculo do tempo de deslocamento. Entretanto, em termos

práticos, existem fatores que fazem com que isto não ocorra, ou seja, a distância pode ser pequena, mas haver dificuldades de se chegar ao local como condições da estrada, ou acesso dificultado. Isto pode causar um tempo maior de deslocamento para uma distância pequena em relação a um local mais afastado com condições mais favoráveis. Desta forma, pode ser considerado o tempo real de deslocamento de cada equipe ao local a ser submetido à manutenção e consequentemente obter-se resultados bem mais próximos da realidade. Porém isto demanda um levantamento de dados em campo atualizado e detalhado, o que não está disponível no momento.

- Consideração de custos relativos a indenizações. Nesta etapa não foram considerados os custos relativos a indenizações pagas devido aos danos ocorridos e cujos valores podem ser obtidos através do histórico. Tais valores poderiam ser considerados para equacionar melhor o problema e também ter o modelo mais próximo da realidade. Alguns exemplos típicos são aparelhos elétricos e eletrônicos danificados e eventuais prejuízos a perecíveis devido ao tempo de interrupção.
- Consideração de multas. As multas mais comuns estão relacionadas a locais específicos os quais têm características especiais para o sistema como um todo ou para um ou vários consumidores específicos. Por exemplo, uma indústria cuja interrupção no fornecimento ocasiona muitos prejuízos e tem contrato formal e específico com a concessionária. Outro caso envolvendo a ANEEL cujas chaves pertençam a rede básica, estas não devem ser desligadas. Mesmo quando programado o desligamento paga-se uma multa e no caso de desligamento acidental (não programado) a multa torna-se bem maior. Considerando esta condição podem haver alterações significativas nos resultados para determinadas regiões.
- Limite de chaves por equipe. No presente trabalho tal consideração não foi considerada, e, entretanto, na prática, a situação deve ser considerada devido à possibilidade de ocorrências simultâneas. Podem ocorrer ao mesmo tempo mais de uma chave que deva ser submetida à manutenção pela mesma equipe em locais dispersos, ocasionando um tempo maior no atendimento e, consequentemente, aumentando os custos envolvidos.

- Custos relativos à infra-estrutura. Conforme o local em que as equipes de manutenção estejam alocadas existe um custo de infra-estrutura relacionados a aluguel de imóveis, comunicação, informática e outros específicos a cada empresa. Tais custos também poderão ser considerados futuramente.
- Redução de custos devido ao aproveitamento de infra-estrutura. Se houver a necessidade de mais de uma equipe ser alocada no mesmo local o custo de infra-estrutura é reduzido, tal consideração também pode ser contemplada.

Concluindo, o potencial do trabalho exposto é muito grande no sentido de se obter uma melhor disposição / quantidade de equipes para atendimento das áreas a serem submetidas à manutenção com o menor custo possível para determinada condição. Quanto maiores as considerações envolvidas no processo, como as já expostas, mais próximo de uma melhor condição real estará o resultado obtido, entretanto o problema torna-se cada vez mais complexo e o esforço computacional envolvido também aumenta.

Na próxima etapa do trabalho serão considerados os custos relativos a logística e número máximo de chaves por equipe.

### **Referências Bibliográficas**

- GOLDBERG, D.E., (1989) *Genetic Algorithms in Search, Optimization and Machine Learning*. Reading: Addison-Wesley.
- GOODMAN E.D. (1996) *Genetic Algorithm Optimized for Portability and Parallelism System*. East Lansing, Michigan State University.
- LOPES, H.S. (1999) Algoritmos genéticos em projetos de engenharia: aplicações e perspectivas futuras. In: *Anais do SBAI'99 - IV. Simpósio Brasileiro de Automação Inteligente*. São Paulo, 08-10/setembro/1999, p. 64-74.




Figura 1. Situação Atual – Todas as chaves (pontos menores) são atendidas pelo município de Maringá




Figura 2. Doutor Camargo




Figura 4. Itambé




Figura 3. Floresta




Figura5. Ivatuba




Figura 6. Mandaguaiçu




Figura 9. Maringá




Figura 7. Mandaguari




Figura 10. Presidente Castelo Branco




Figura 8. Marialva




Figura 11. São Jorge do Ivaí

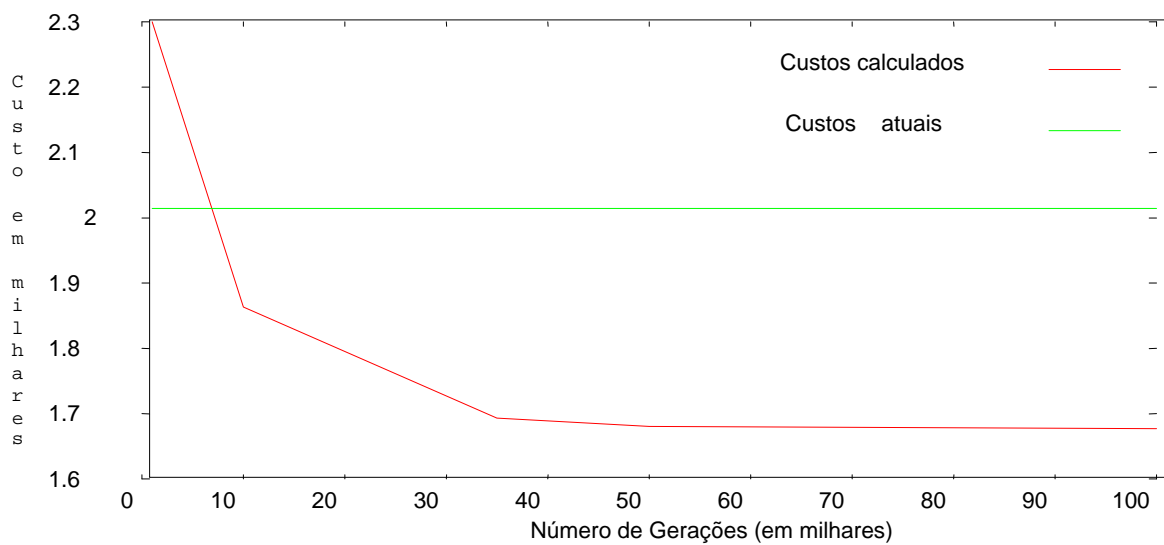


Figura 12. Evolução dos resultados pelo número de gerações