

MODELO MATEMÁTICO MULTI OBJETIVO BINÁRIO PARA A MANUTENÇÃO DA VEGETAÇÃO EM UM SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Eduardo de Souza

professoreduardosouza@gmail.com

André do Amaral Penteadó Biscaro

aapbiscaro@hotmail.com

José Roberto Sanches Mantovani

mant@dee.feis.unesp.br

Laboratório de Planejamento de Sistemas de Energia Elétrica – LaPSEE
Departamento de Engenharia Elétrica – UNESP – Ilha Solteira
Avenida Brasil, 56 – Centro
15.385-000 ILHA SOLTEIRA, SP, BRASIL

RESUMO

Neste trabalho propõe-se um modelo matemático de programação binária dinâmica multiobjetivo para o problema de manutenção preventiva da vegetação em sistemas de distribuição de energia elétrica. O modelo de otimização contempla a minimização de três objetivos: custos com energia não suprida devido às falhas relacionadas com a vegetação, custos com manutenções - poda ou remoções de árvores, e um indicativo de confiabilidade do sistema devido à continuidade do serviço baseado no índice FEC (Frequência Equivalente por Consumidor). A confiabilidade dos alimentadores é determinada através de modelos probabilísticos como um processo renovável, considerada no modelo matemático como um índice de inconfiabilidade. A metodologia de solução proposta é o algoritmo multiobjetivo NSGA-II, implementado em linguagem de programação C++, obtendo-se um conjunto de soluções não dominadas, que tende a convergir para frente ótima de Pareto. Esta metodologia foi testada em um sistema de distribuição real de uma cidade de médio porte.

PALAVRAS CHAVE. Manutenção da Vegetação, Confiabilidade, NSGA-II.

Área principal (Energia, Programação Matemática)

ABSTRACT

This paper proposes a mathematical model of dynamic multiobjective binary programming to preventive maintenance problem of vegetation for electric power distribution systems. The optimization model includes the minimization of three objectives: cost of energy not supplied due to failures related to the vegetation, costs of maintenance - trimming or trees removal and, an indication of system reliability due to continuity of service based on FEC (Equivalent Frequency for Consumer). The feeders reliability is determined using probabilistic models as a renewable process, considered in the mathematical model as an index of unreliability. The proposed solution methodology is a multiobjective algorithm NSGA-II implemented in the programming language C++, obtaining a set of non-dominated solutions among themselves, which tends to converge to Pareto optimal front. This methodology was tested on a real distribution system of a medium sized city.

KEYWORDS. Maintenance of Vegetation, Reliability, NSGA-II.

Main area (Energy, Mathematical Programming)

1. Introdução

Os sistemas de distribuição de energia elétrica (SDEE) são predominantemente aéreos, devido ao fato de exigirem baixos investimentos em equipamentos e infraestrutura. Apresentam um menor índice de confiabilidade devido às diversas interferências, principalmente do meio ambiente com os dispositivos presentes no sistema. Em particular, a vegetação exerce influência na confiabilidade do sistema de distribuição, pois pode causar danos à rede devido ao contato de suas extremidades com os elementos energizados do sistema (Elétróbrás. Comitê de Distribuição, 1982a). Segundo Appelt e Beard (2006), a fim de se evitarem danos causados pela vegetação, as empresas de distribuição de energia elétrica devem fazer manutenções regulares, tais como podas simples ou remoção da vegetação. Porém, em alguns casos, o corte no serviço de fornecimento de energia é necessário. Planos de manutenção a longo prazo devem ser elaborados pelas empresas a fim de reduzir os problemas com interrupções, favorecendo o aumento da confiabilidade do sistema a baixos custos.

Alguns modelos matemáticos baseados em Manutenção Centrada em Confiabilidade para otimizar o processo de manutenção da vegetação no sistema são encontrados na literatura. No modelo desenvolvido por Kuntz et al. (2002), os autores propõem a criação de três funções objetivo as quais visam: 1) Minimizar o custo total da confiabilidade; 2) Minimizar os custos de manutenção para obter um índice preestabelecido que avalia a confiabilidade; 3) Maximizar a confiabilidade do sistema para um valor preestabelecido de custo de manutenção. Como restrições são colocadas a disponibilidade de mão de obra oferecida pela empresa de manutenção (em km), um valor preestabelecido para o índice de avaliação da confiabilidade e um montante máximo para o custo total da manutenção. Os autores usam uma rede neural artificial proposta por Radmer et al. (2002), obtendo uma previsão para as taxas de falhas. Para encontrar uma solução satisfatória, os autores penalizam as funções objetivos com restrições violadas e geram um problema monoobjetivo. O algoritmo de melhoria local *hill climbing* (Hill) foi combinado ao algoritmo *simulated annealing* (SA), algoritmo genético (AG) e *tabu search* (TS) gerando os algoritmos híbridos SA-HILL, AG-HILL e TS-HILL. São comparados os resultados obtidos com os algoritmos SA, AG, TS, SA-Hill, AG-HILL e TS-HILL, obtendo destaque para o AG-HILL (Kuntz et al., 2002).

Em Apolinário e Mantovani (2011), propõe-se um modelo dinâmico monoobjetivo para o planejamento de podas, visando minimizar os custos com a energia não suprida somado ao custo de manutenção da vegetação, tendo em conta as seguintes restrições: 1) Recursos financeiros máximos disponíveis preestabelecidos para efetuar a manutenção no período; 2) Mão de obra máxima disponibilizada pela empresa de manutenção (em metros) e 3) Um valor máximo para o índice de continuidade, adotando-se uma predição para FEC, citada por Reis et al. (2008), responsável pela avaliação da confiabilidade do sistema. Para prever as taxas de falha, os autores realizaram um ajuste dos dados históricos às curvas baseadas em modelos não lineares dadas pela distribuição normal. A técnica de solução do modelo é o algoritmo genético de *Chu-Beasley-AGCB* (Chu e Beasley, 1997).

Neste artigo, apresenta-se um modelo matemático de programação binária dinâmica multiobjetivo dirigido à tomada de decisão referente a quando e em quais alimentadores se realizará a manutenção da vegetação, seja ela parcial ou total. Minimizam-se simultaneamente tres objetivos: 1) Custo com energia não suprida; 2) Custo com a manutenção da vegetação e 3) Um indicativo de confiabilidade, responsável por avaliar a confiabilidade do sistema. Empresas responsáveis pelos serviços de manutenção da vegetação tais como podas ou remoções ficam limitadas a certas quantidades devido a disponibilidade de suas equipes. Esses limites são apresentados em metros disponíveis para realização de manutenção na vegetação e são inseridas no modelo matemático como uma restrição.

A ideia de propor um modelo multiobjetivo parte do princípio de que o administrador do sistema deve possuir um conjunto de possibilidades para a tomada de decisão, ajustando, assim, a manutenção da vegetação com as manutenções pertinentes ao restante do sistema como, por exemplo, poder controlar um índice de inconfiabilidade, escolhendo a melhor relação para a

empresa entre custos com manutenção da vegetação e a confiabilidade da rede. Para testar a metodologia proposta foram usados os dados do SDEE (somente urbano) de uma empresa situada no interior do estado de São Paulo. No modelo são usadas as incertezas ou inconfiabilidades referentes a cada alimentador, aplicando-se a teoria de confiabilidade aos dados disponíveis, e não a determinação e uso das taxas de falha como nas propostas por Apolinário e Mantovani (2011), Radmer et al. (2002) ou Guikema et al. (2006). O método de solução utilizado na busca de soluções para o modelo matemático proposto é o algoritmo genético *Non Sorting Genetic Algorithm II* (NSGA2), proposto por Deb et al. (2002).

Adicionalmente a esta seção introdutória, este artigo está organizado da seguinte forma: Na Seção 2 são apresentados os índices de continuidade no fornecimento de energia elétrica e a teoria para determinação da confiabilidade do sistema devido a interferência da vegetação; Na Seção 3 apresenta-se o modelo matemático proposto para atribuição de tarefas relacionadas a manutenção da vegetação sob um SDEE; Na Seção 4, a técnica de solução para o problema proposto, o NSGA-II é detalhado; Na Seção 5 é mostrada a codificação das propostas de solução para o problema; Na Seção 6 são apresentados os testes e os resultados obtidos com o algoritmo NSGA-II implementado. Para a realização dos testes e obtenção dos resultados, os dados de um sistema de distribuição real de uma cidade de médio porte do interior do estado de São Paulo foram usados; Na Seção 7 estão as considerações finais baseadas na análise do modelo matemático e da proposta de solução apresentada. Propostas para trabalhos futuros também são descritas nessa seção.

2. Índices e Confiabilidade do SDEE

Confiabilidade, citada em Eletrobrás. Comitê de Distribuição (1982b), é definida como a “capacidade de um item desempenhar a função exigida, sob condições estabelecidas, por um período de tempo determinado, podendo ser expresso como uma probabilidade”.

A qualidade na distribuição de energia elétrica faz com que índices que quantificam a confiabilidade dos sistemas elétricos sejam criados. A Agência Nacional de Energia Elétrica (ANEEL) estabelece índices para monitorar a qualidade do fornecimento de energia nos sistemas de distribuição. Os índices baseados na continuidade do serviço mais usados são os de ordem coletivos como: DEC (Duração Equivalente de Interrupção por Consumidor), correspondente ao índice internacional SAIDI (*System Average Interruption Duration Index*), mostrado em (1); FEC (Frequência Equivalente de interrupção por Consumidor), correspondente ao índice internacional SAIFI (*System Average Interruption Frequency Index*), mostrado em (2).

Observa-se que os valores obtidos para os índices DEC e FEC crescem/decrecem com o aumento/decrescimento das falhas que ocorrem no sistema. Portanto, os índices de continuidade avaliam a confiabilidade do sistema. Sittithumwat et al. (2004), citado por Reis et al. (2008), propõem através de (3) uma previsão para o índice FEC, através da predição da variável taxa de falhas (λ).

$$DEC = \frac{\sum_{i=1}^n C_a(i) * t(i)}{C_S} \quad (1) \quad FEC = \frac{\sum_{i=1}^n C_a(i)}{C_S} \quad (2) \quad P_{FEC} = \frac{\sum_{i=1}^{NA} \lambda_i C_A(i)}{C_{ST}} \quad (3)$$

Onde:

- n : Número de setores/conjuntos;
- NA : Número de alimentadores do sistema;
- $C_a(i)$: Consumidores atingidos na interrupção i ;
- C_S : Número total de consumidores do conjunto;
- $t(i)$: Tempo decorrido na interrupção i ;
- λ_i : Taxa de falha prevista para o alimentador/setor i ;
- $C_A(i)$: Número total de consumidores do conjunto i ;
- C_{ST} : Total de consumidores do sistema compreendido pelos NA alimentadores.

A previsão das taxas de falha relacionadas à vegetação pode ser elaborada segundo Radmer et al. (2002), de duas formas: direta e indiretamente. Nos modelos indiretos as taxas de crescimento referente aos tipos de vegetação são levadas em consideração, o que não ocorre nos modelos diretos. Modelagens baseadas em modelos indiretos podem não ser possíveis pois, quando se trata de um sistema real, os alimentadores estão sujeitos às intervenções de diferentes tipos de vegetação em diferentes lugares, o que dificulta a utilização das diferentes taxas de crescimento.

Modelos diretos são encontrados na literatura, como Radmer et al. (2002), que realizaram a comparação entre quatro modelos de predição das taxas de falha: Modelo Exponencial (ME), Modelo Linear Simples (MLS), Modelo Linear Multivariável (MLM) e uma Rede Neural Artificial (RNA). Os modelos ME e MLS utilizam a taxa de falha anual relacionada à vegetação bem como o tempo decorrido em anos desde a última manutenção. Os modelos MLM e RNA, além dos dados empregados nos dois primeiros modelos, adotam também a perspectiva da interferência das temperaturas (mínima e máxima) e precipitações médias anuais. Para estimar as taxas de falhas, a RNA foi a que obteve a melhor predição.

Com relação à determinação das taxas de falha, encontram-se na literatura algumas propostas como em Guikema et al. (2006), que propõem uma nova visão na tentativa de analisar os efeitos da vegetação no SDEE através de taxas de falhas não constantes. Neste modelo, leva-se em consideração o número de incidentes com a vegetação, os tempos da primeira e da mais recente poda, o comprimento das linhas (aéreas e subterrâneas), o número de consumidores conectados e a densidade populacional, dados esses para cada ramo/circuito do sistema em estudo. Foram apresentados três modelos: Modelo Linear Generalizado de Poisson (MLGP), Modelo Linear Generalizado Binomial Negativo (MLGBN) e um Modelo Linear Generalizado Misto de Poisson (MLGMP).

Os dados históricos disponíveis para elaboração deste trabalho não foram suficientes para a determinação das taxas de falhas através dos modelos de Guikema et al. (2006), e Radmer et al. (2002). Assim, optou-se pelos estudos baseados na teoria da probabilidade, visando determinar a confiabilidade dos alimentadores em função das falhas relacionadas à vegetação sob os mesmos, e usar este resultado no modelo matemático proposto.

2.1. Modelos probabilísticos.

Pode-se denotar a confiabilidade de um elemento $C(t)$ através de uma probabilidade P , onde o grau de certeza de que o tempo de vida T de um elemento exceda um valor estipulado t , mostrada em (4):

$$C(t) = P[T > t] \quad (4)$$

Em Zapata (2010), observa-se que as variáveis tempo entre falhas (tbf) e tempo de reparo (ttr) formam a base dos termos característicos da confiabilidade. Também, podem ser tomadas como variáveis aleatórias explicadas por uma ou mais distribuições de probabilidade.

Utilizando Zapata (2010) e Zapata (2011), considera-se que as interrupções causadas pela vegetação representam um processo reparável, ou seja, apresentada uma indisponibilidade, existe um tempo de restauração do serviço; uma reparação única e a confiança do dispositivo não é afetada. Assim, busca-se para este problema um modelo discreto quanto ao estado/motivo (falhas) e contínuo no tempo t , isto é, um processo estocástico pontual reparável. Tendo em vista os dados observados, nota-se que a magnitude encontrada para os ttr's é mínima quando comparada à magnitude dos tbf's, permitindo que as variáveis sejam estudadas separadamente e, neste caso, tomou-se como amostra para a construção do modelo probabilístico somente os dados históricos da variável tbf. Uma amostra desses dados históricos aleatórios passa por uma série de testes para obter o melhor modelo probabilístico, sendo eles:

- Prova de tendência: Durante o intervalo de tempo t , a distribuição dos dados pode se comportar de forma crescente (positiva), decrescente (negativa) ou nula. Testes de tendência podem ser realizados gráfica e analiticamente (Teste de Laplace para tendência).

- Prova de independência: Necessária para mostrar que não existe dependência entre os dados, sendo analisado graficamente pelo diagrama de dispersão dos dados i por $i+1$;

- Prova de ajuste a uma distribuição de probabilidade: Usa-se o teste de *Kolmogorov - Smirnov* (K-S Test) em todas as possíveis distribuições. Testes de hipótese são aplicados para verificar o ajuste dos dados às distribuições Normal, Lognormal, Weibull, etc. (Processo de Poisson Homogêneo (HPP) ou um Processo de Renovação (RP)). Caso se rejeite as duas hipóteses, o Método de TTT Plot verifica se existe ajuste a uma distribuição *Power Law* (Processo de Poisson Não Homogêneo (NHPP)).

A função de distribuição de probabilidade (para variável aleatória), caso seja um HPP ou RP é dada por (5), enquanto para um NHPP é dada por (6). Os parâmetros das distribuições podem ser estimados utilizando os Métodos de Verossimilhança ou Momentos, como em Zapata (2010) ou Montgomery e Runger (2012).

$$P[N(t) = k] = \frac{1}{k!} [\hat{\lambda} t^\beta]^k * e^{-\hat{\lambda} t^\beta}, \text{ com } k = 0, 1, 2, \dots \quad (5)$$

$$P[N(t) = k] = \frac{1}{k!} [\lambda t]^k * e^{-\lambda t}, \text{ com } k = 0, 1, 2, \dots \quad (6)$$

Onde $P[N(t) = k]$ é a probabilidade de que o número de falhas em um intervalo de tempo t ($N(t)$) seja igual a k falhas, $\hat{\lambda}$ e β são os parâmetros estimados das distribuições de probabilidade (constantes) e λ a taxa de falha (constante em HPP e RP).

Baseado na teoria apresentada, a confiabilidade do sistema referente à vegetação é a probabilidade de que em certo período de tempo t não ocorra nenhuma falha, ou seja, tem-se nas equações (5) e (6) que $k = 0$.

3. Modelo Matemático.

O sistema de distribuição está sujeito à invasão da vegetação ao longo de seu trajeto. O contato da vegetação com os elementos do sistema são comuns quando não são realizadas manutenções preventivas na vegetação, gerando interrupções na distribuição de energia elétrica que reduzem a confiabilidade do sistema. A necessidade de se saber “quando e onde”, “ou realizar ou não realizar” uma manutenção é o objetivo deste trabalho. Um modelo matemático de programação binária dinâmica multiobjetivo foi desenvolvido, o qual deve fornecer ao administrador do sistema um conjunto de soluções não dominadas, indicando onde e quando serão realizadas as tarefas de manutenções da vegetação.

Em um SDEE, uma falha no início do alimentador implica em maior quantidade de energia não suprida que uma falha em seu final, devido a sua configuração ser radial. Neste modelo, as probabilidades de falhas não estão ligadas a dados geográficos devido à escassez de dados históricos disponibilizados e, portanto, considera-se que ao ocorrer uma falha, todo o alimentador é afetado. Da mesma forma, caso se opte por realizar uma manutenção, toda a extensão do alimentador recebe poda ou remoção da vegetação.

No modelo matemático, minimizam-se simultaneamente três objetivos distintos e conflitantes, descritos em (7), (8) e (9), sendo estes: 1) Custo com energia não suprida (CENS); 2) Custo com manutenções relacionadas à vegetação (CMV) e 3) Indicativo de confiabilidade (IIC). Este conjunto de objetivos está sujeito às restrições apresentadas em (10), (11) e (12).

$$\text{Min CENS} = \sum_{t=1}^T \sum_{al=1}^{NA} \{ [\sum_{tr=1}^{NT} D(tr, al)] * (1 - P[N(t, al) = 0]) * \varphi(x(t, al)) * (NC_{res}^{al} * C_{res} + NC_{ind}^{al} * C_{ind} + NC_{com}^{al} * C_{com}) * \bar{ttr}(al) \} \quad (7)$$

$$\text{Min CMV} = \sum_{t=1}^T [\sum_{al=1}^{NA} l(al) * C_{man}^{al} * x(t, al)] \quad (8)$$

$$\text{Min } Ilc = \sum_{t=1}^T \left[\sum_{al=1}^{NA} \frac{(1-P[N(t)=0]) * NC(al) * \varphi(x(t,al))}{(\sum_{al=1}^{NA} NC(al))} \right] \quad (9)$$

s.a

$$L_{max}^t - \sum_{al=1}^{NA} l(al) * x(t, al) \geq 0 \quad (10)$$

$$\varphi(x(t, al)) = \left(1 - \frac{x(t,al)}{2}\right) * (1 - \min\{1; -x(t, al) + \sum_{m=1}^t x(m, al)\}) \quad (11)$$

$$x(t, al) = 0/1 \quad (12)$$

Sendo:

- NA : Número de alimentadores sob análise;
- NT : Número total de transformadores do alimentador *al*;
- D(tr,al) : Demanda média em kW no transformador *tr* do alimentador *al*;
- 1 - P[N(t,al) = 0] : Probabilidade de ocorrer falhas no alimentador *al* no tempo *t*;
- $NC_{res}^{al}, NC_{ind}^{al}, NC_{com}^{al}$: Respectivamente, número de consumidores residenciais, industriais e comerciais do alimentador *al*;
- NC(al) : Número total de consumidores conectados no alimentador *al*;
- $C_{res}, C_{ind}, C_{com}$: Respectivamente os valores do kWh para consumidores residenciais, industriais e comerciais;
- $\overline{ttr}(al)$: Tempo médio de restauração no alimentador *al* devido à vegetação;
- T : Horizonte de planejamento;
- l(al) : Comprimento do alimentador *al*;
- C_{man}^{al} : Custo para se realizar a manutenção no alimentador *al*;
- L_{max}^t : Comprimento máximo permitido para se realizar manutenções no período de planejamento *t*;
- $x(t, al)$: Variável de decisão binária, onde 1 e 0 implicam respectivamente realizar ou não uma manutenção no alimentador *al* no período *t*;
- $\varphi(x(t, al))$: Variável em função de $x(t, al)$, sendo igual a 1 caso não ocorra nenhuma manutenção da vegetação nos períodos anteriores a *t*; 0,5 no período *t* que esteja prevista a manutenção, e 0 nos períodos posteriores à realização de manutenção da vegetação.

Na equação (7), o uso das probabilidades de falhas por alimentador foi adotado para evitar a extrapolação do CENS quando se aplica a predição das taxas de falha por modelos probabilísticos. Além disso, utiliza-se a confiabilidade, ou seja, são levadas em consideração as chances de que ocorra ao menos uma falha, fazendo com que a possibilidade de existir interrupções no alimentador não fique ligada à quantidade de ocorrências. A demanda média por alimentador é considerada para avaliação da energia não suprida. Considera-se que quando surge uma falha, o serviço de fornecimento de energia elétrica em todo alimentador é interrompido.

Após realizar a manutenção da vegetação em um alimentador, sua probabilidade de falha para os próximos períodos do horizonte de planejamento é zero, porém, para o período em que a manutenção está sendo proposta, é considerada uma redução de sua probabilidade de falha. Essas variações do CENS são dinamicamente observadas pela função $\varphi(x(t, al))$. Os consumidores residenciais, industriais e comerciais e seus respectivos custos de energia não fornecida são utilizados. Para cada alimentador, tomou-se através dos dados históricos o tempo médio de reparação do sistema.

Na equação (8) mostra-se o custo e o comprimento das manutenções realizadas ao longo de todo horizonte de planejamento do sistema em análise. As empresas responsáveis pelas manutenções na vegetação definem um comprimento máximo para que suas equipes possam realizá-las em definidos intervalos de tempo t , incluído no modelo como uma restrição em (10).

Para fins de análise, a confiabilidade do sistema é avaliada em (9), uma adaptação de (3), porém, não pode ser atribuído ao valor previsto de FEC, ou seja, trata-se de um indicativo de inconfiabilidade, onde a probabilidade da inconfiabilidade ponderada pelos consumidores de cada alimentador e de todo o sistema gera um valor entre 0 e 4, sendo a melhor e a pior confiabilidade do sistema quando I_{lc} tende a seus limites inferior e superior, respectivamente.

4. Técnica de Solução.

Para resolver o problema (7)-(12), optou-se pelo algoritmo *Non Sorting Genetic Algorithm II* (NSGA2) proposto por DEB *et al.* (2002), um algoritmo genético elitista, de fácil implementação e de baixo “custo” computacional quando comparado aos outros métodos de otimização multiobjetivo *a posteriori*. Esse método de otimização é estruturado para criar conjuntos contendo soluções não dominadas entre si, onde cada conjunto determina n frentes de dominância (F_n) em que a primeira frente domina a segunda frente e assim sucessivamente.

A convergência do algoritmo busca levar a melhor frente de dominância para Frente de Pareto Ótima (PF). Um fator importante nesse tipo de otimização é manter a diversidade da população, ou seja, percorrer o maior número de possíveis soluções durante o processo iterativo. Sendo assim, para garantir a diversidade da população, os autores propõem o operador $I[i]_{distance}^n$, denominado distância de agrupamento ou distância multidão (*crowding distance*, do inglês) da solução i em F_n , operador este que estima o perímetro do cubóide com vértices nas soluções $i-1$ e $i+1$, centrado em i , como mostrado na Figura 1.




Figura 1 - Cálculo da distância de multidão (Adaptado de Deb *et al.*, 2002).

Para cada frente de dominância n , sejam f_{max}^j e f_{min}^j os valores máximos e mínimos da função objetivo j . O valor estimado do operador *crowding distance* da solução i pertencente à frente n é dado em (13).

$$I[i]_{distance}^n = \sum_{j=1}^m \left| \frac{f^{j(i+1)} - f^{j(i-1)}}{f_{max}^j - f_{min}^j} \right| \quad (13)$$

O processo iterativo é composto das seguintes etapas:

- i. P_t é gerada aleatoriamente, contendo N indivíduos;
- ii. Classifique a população conforme a dominância de Pareto (criam-se as frentes F_n) e calcule $I[i]_{distance}^n$ para cada indivíduo;
- iii. Através dos operadores genéticos (seleção por torneio, recombinação e mutação), a população Q_t é gerada contendo N indivíduos. O diferencial deste algoritmo está no método de torneio, denominado torneio *crowding*, onde o vencedor se encontra em uma melhor F_n , e caso a frente para ambos os indivíduos seja igual, aquele com maior $I[i]_{distance}^n$ vence;
- iv. A população P_t é unida com a população Q_t , gerando um novo conjunto com $2N$ indivíduos;

- v. Repete-se a etapa *ii*;
- vi. A população P_{t+1} com N indivíduos é gerada tomando-se sequencialmente os indivíduos melhores classificados em níveis de dominância em $P_t \cup Q_t$;
- vii. Se o critério de parada (número de iterações) for atingido pare, senão, volte para a etapa *i*.

5. Codificação das soluções do problema.

O problema de minimização apresentado na seção 3 deve indicar quando e onde serão realizadas as manutenções da vegetação. A Figura 2 mostra a representação (cromossomo) usada na codificação das propostas de soluções do problema. Cada cromossomo é dividido em 4 subconjuntos (trimestres do ano) e, em cada subconjunto, existem NA alimentadores, cada um representado por um bit. A cada bit pode-se atribuir realizar ou não uma manutenção, indicados, respectivamente, por 0 e 1. Na Figura 2, por exemplo, no primeiro trimestre o alimentador 1 passará por manutenção, o que não ocorrerá com o alimentador 2.

1° Trimestre					2° Trimestre					3° Trimestre					4° Trimestre				
1	0	...	1	0	1	0	...	0	1	0	1	...	0	0	1	1	...	1	1
1	2	...	NA-1	NA	1	2	...	NA-1	NA	1	3	...	NA-1	NA	1	2	...	NA-1	NA

Figura 2 - Codificação proposta para um cromossomo (Adaptado de Apolinário e Mantovani, 2011).

6. Testes e Resultados.

O modelo de minimização proposto foi testado em um sistema real de uma cidade localizada no interior do estado de São Paulo. Dados históricos de 25 alimentadores foram analisados no período de 2002 a 2011. Apenas os dados relacionados às interrupções causadas por vegetação foram considerados.

Testes de ajustes foram feitos para as funções que melhor se adaptavam aos dados históricos analisados. Quando os dados podem ser explicados através dos modelos RP e HPP, as possíveis distribuições são comparadas, e a distribuição considerada mais “apta” é aquela com a menor estatística D do *K-S Test*. Quando os dados devem ser explicados por um NHPP, testa-se o ajuste a um processo de *Power-Law*. Para a análise de ajuste e determinação dos parâmetros dos modelos, utilizou-se o toolbox *Statistics* do *software Matlab*®. O Quadro 1 mostra os modelos usados para cada um dos 25 alimentadores analisados. O termo *p1a1*, indica que o alimentador 1 está conectado a subestação 1 e, assim, sucessivamente.

Quadro 1 - Modelos ajustados aos dados dos alimentadores do sistema

Alimentador	Modelo	Alimentador	Modelo	Alimentador	Modelo
p1a1	gamma	p3a6	power law	p4a9	power law
p1a2	power law	p3a7	power law	p4a10	power law
p1a4	power law	p4a2	power law	p5a1	power law
p1a6	exponencial	p4a3	exponencial	p5a2	normal
p1a8	power law	p4a4	power law	p5a3	gamma
p3a1	power law	p4a5	power law	p5a4	power law
p3a3	lognormal	p4a6	power law	p5a6	power law
p3a4	normal	p4a7	power law		
p3a5	power law	p4a8	power law		

O tempo para reparação do sistema, caso aconteça uma interrupção no fornecimento devido à vegetação, é dado pelo tempo médio (*ttr*), obtido através dos dados históricos para cada alimentador. Por hipótese, considera-se que a empresa responsável pela manutenção da vegetação deva realizar no máximo podas em 120 km do SDEE por trimestre. O custo para realizar manutenções na vegetação é, em média, R\$17,40 por árvore (Apolinário e Mantovani, 2011).

Neste trabalho, estima-se que existam em média, 6 árvores a cada 100 metros, obtendo-se um custo de manutenção por metro no valor de R\$1,04. O custo referente ao não fornecimento de energia elétrica para os consumidores residenciais, industriais e comerciais por kWh são, respectivamente, R\$2,31, R\$9,16 e R\$2,00 (Meneses e Mantovani, 2012). Na busca do conjunto de soluções não dominadas pertencentes à melhor frente dominante, o método de otimização NSGA-II foi implementado em linguagem C++.

Diversos testes foram realizados para calibrar os parâmetros do algoritmo genético, obtendo-se os valores: 0,9 e 0,04 para as taxas de recombinação e mutação, respectivamente. A população inicial possui 2000 indivíduos. O critério de parada é satisfeito quando são realizadas 2000 iterações. Este conjunto de parâmetro foi considerado o melhor por obter uma frente ótima com a maior diversidade de soluções.

A restrição do problema, caso violada, recebe uma penalidade. O algoritmo também leva em consideração um parâmetro que produz um aumento nas funções objetivos penalizadas. Este parâmetro faz com que em cada iteração, soluções extremamente infactíveis possam ser analisadas, porém, tornam-se cada vez menos atraentes para compor a próxima população. As funções objetivo (7) e (8) são penalizadas em cada período t , segundo (14). A função objetivo (9) é penalizada ponderando-se (14) pelo número de consumidores do alimentador, descrita em (15). Nota-se que a penalidade descrita em (15) é um valor entre 0 e 1, fazendo com que (9) não fique bruscamente penalizada, não prejudicando a excursão pelo espaço de busca dos objetivos.

$$MAX(0; L_{max}^t - \sum_{al=1}^{NA} l(al) * \varphi(x(t, al))) \quad (14)$$

$$MAX(0; \frac{L_{max}^t - \sum_{al=1}^{NA} l(al) * \varphi(x(t, al))}{(\sum_{al=1}^{NA} NC(al))}) \quad (15)$$

A Figura 3 mostra a frente F_1 obtida pelo algoritmo NSGA-II implementado. Esta frente tende a convergir para a frente ótima de Pareto, que, para o problema real, é desconhecida.

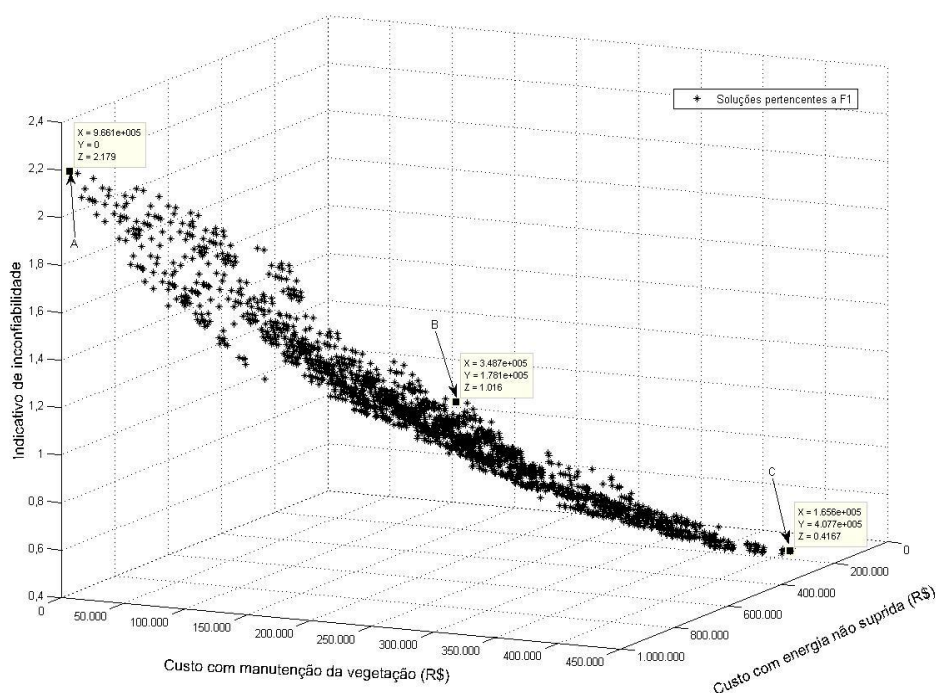


Figura 3 - Frente F_1 contendo as soluções não dominadas encontradas pelo NSGA-II

7. Considerações finais.

A proposta de se criarem modelos de manutenções preventivas pode ajudar as empresas de distribuição de energia elétrica a manter seus níveis de confiabilidade altos, gastando, após um período de adaptação, um menor valor. Modelos multiobjetivos *a posteriori* geram um conjunto de soluções não dominadas, possibilitando ao administrador do sistema tomar a melhor decisão para o horizonte de planejamento. O modelo matemático proposto neste trabalho considera a minimização do CENS, CMV e IIC, itens indispensáveis para o gerenciamento de uma rede de distribuição.

Realizar a manutenção em todo o alimentador é um método não muito eficaz, pois nem toda a vegetação em sua extensão é passível de poda ou remoção, além de existir a possibilidade de certa área/região não apresentar grandes riscos para ocorrência de falhas ou danos ao sistema. A falta de dados referentes à vegetação (neste caso georreferenciados), ou a impossibilidade de se conhecer a vegetação sob o sistema (em regiões delimitadas do sistema) não permite reduzir a opção de realizar ou não manutenções em regiões do alimentador ou do sistema neste modelo.

Modelos probabilísticos tradicionais usam taxas de falhas constantes, não levando em consideração que fatores externos possam interferir no crescimento e, conseqüentemente, há tendência à taxa de falhas não constantes. O uso da inconfiabilidade ao invés das taxas de falhas procura minimizar esse efeito. Caso a vegetação seja conhecida, modelos de crescimento vegetativo podem ser usados, obtendo taxas de falhas mais precisas, auxiliando para obtenção de melhores resultados para o modelo de minimização proposto.

O algoritmo NSGA-II apresentou uma rápida convergência e a diversidade nas gerações é preservada pelo operador *crowding distance*. O custo computacional é baixo, o que resulta em um tempo de processamento adequado para este tipo de problema de planejamento. É um método de otimização multiobjetivo promissor para o modelo proposto em função de seu bom desempenho e conservação da diversidade, como mostrado nos resultados.

Pode-se levar em consideração, para modelos multiobjetivo futuros, o pagamento de multas referentes às violações dos índices de continuidade. Para os índices de frequência, o uso de probabilidades impede que o mesmo seja previsto, porém, pode ser adicionado, caso adote taxas de falhas. Para os índices relacionados à duração, notou-se pelos dados históricos que interrupções neste SDEE geravam ttr's que não ultrapassam seus limitantes.

Agradecimentos.

Os autores agradecem a CAPES e o CNPq (processo 305371/2012-6) pelo apoio financeiro.

Referências.

- Apolinário, L. A. e Mantovani, J. R. S.** (2011), Modelo de programação matemática para controle do crescimento da vegetação sob redes de distribuição de energia elétrica, *Revista Controle & Automação*, n. 22, v. 3, 284-295.
- Appelt, P. J. e Beard, A.** (2006), Components of an effective vegetation management program, *Electric Power Conference*, n. 1, v. B3, 1-8.
- Billinton, R. R.** (1986), An analytical approach to evaluate probability distributions associated with the reliability indices of electric distribution systems, *IEEE Transactions on Power Delivery*, n. 3, v. 1, 245-251.
- Chu, P. e Beasley, J. E.** (1997), A genetic algorithm for the generalized assignment problem, *Computers & Operations Research*, n. 24, v. 1, 17-23.
- Deb, K., Pratap, A., Agarwal, S. e Meyarivan, T.** (2002), A fast an elitist multi-objective genetic algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation*, n. 6, v. 2, 182-197.

- Eletrobrás. Comitê de Distribuição.**, *Planejamento de Sistemas de Distribuição*, v. 1, Editora Campus/Eletrobrás, Rio de Janeiro, 1982a.
- Eletrobrás. Comitê de Distribuição.**, *Planejamento de Sistemas de Distribuição*, v. 3, Editora Campus/Eletrobrás, Rio de Janeiro, 1982b.
- Guikema, S. D., Davidson, R. A. e Haibin, L.** (2006), Statistical models of the effects of tree trimming on power system outages, *IEEE Transactions on Power Delivery*, n. 17, v. 3, 1549-1557.
- Kuntz, P. A., Christie, R. D. e Venkata, S. S.** (2002), Optimal vegetation maintenance scheduling of overhead electric power distribution systems, *IEEE Transactions on Power Delivery*, n. 17, v. 4, 1164-1169.
- Meneses, C. A. P. e Mantovani, J. R. S.** (2012), Improving the grid operation and reliability cost of distribution systems with dispersed generation, *IEEE Transactions on Power Systems*, n. 99, v. PP, 1-12.
- Montgomery, D. C. e Runger, G. C.**, *Estatística aplicada e probabilidade para engenheiros*. Editora LTC, Rio de Janeiro, 2012.
- Radmer, D. T., Kuntz, P. A., Christie, R. D., Venkata, S. S. e Fletcher, R. H.** (2002), Predicting vegetation related failure rates for overhead distribution feeders, *IEEE Transactions on Power Delivery*, n. 17, v. 4, 1770-1775.
- Reis, P. A., Filho, L. C., Cavellucci, C., Zuben, F. J., Usberti, F. L. e Gonzáles, J. F.** (2008), Problema de alocação ótima de recursos de manutenção: formulações e estudos de caso, *Atas do XL SBPO*, 447-459.
- Sittithumwat, A., Soudi, F. e Tomsovic, K.** (2004), Optimal allocation of distribution maintenance resources with limited information, *Electric Power Systems Research*, n. 68, v. 1, 208-220.
- Zapata, C. J.**, *Análisis Probabilístico e Simulación*, Universidade de Pereira, Colômbia, 2010, (http://academia.edu/1995572/Analisis_probabilistico_y_simulacion, jul. 2013).
- Zapata, C. J.**, *Confabilidad en Ingeniería*. Universidade de Pereira, Colombia, 2011.