

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HÉCTOR MANUEL ORELLANA CRUZ

**ALOCÇÃO OTIMIZADA DE SENSOES INDICADORES DE FALTA EM  
REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Ilha Solteira  
2016



HÉCTOR MANUEL ORELLANA CRUZ

**ALOCAÇÃO OTIMIZADA DE SENSORES INDICADORES DE FALTA EM  
REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Especialidade: Automação.

Prof. Dr. FÁBIO BERTEQUINI LEÃO  
Orientador

Ilha Solteira  
2016



FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Orellana Cruz, Héctor Manuel.  
O668a Alocação otimizada de sensores indicadores de falta em redes de distribuição de energia elétrica / Héctor Manuel Orellana Cruz. -- Ilha Solteira: [s.n.], 2016  
69 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2016

Orientador: Fabio Bertequini  
Inclui bibliografia

1. Alocação otimizada. 2. Indicadores de falta. 3. Algoritmo genético adaptativo. 4. Sistemas de distribuição.

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA DISSERTAÇÃO:** Alocação Otimizada de Sensores Indicadores de Falta em Redes de Distribuição de Energia Elétrica.

**AUTOR:** HECTOR MANUEL ORELLANA CRUZ

**ORIENTADOR:** FABIO BERTEQUINI LEÃO

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:

*Fábio Bertequini Leão*

Prof. Dr. FABIO BERTEQUINI LEÃO  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

*Rubem Augusto Romero-Lazaro*

Prof. Dr. RUBEN AUGUSTO ROMERO-LAZARO  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

*Mário Oleskovicz*

Prof. Dr. MARIO OLESKOVICZ  
Departamento de Engenharia Elétrica / Escola de Engenharia de São Carlos-USP

Ilha Solteira, 16 de dezembro de 2016

## **AGRADECIMENTOS**

Meus agradecimentos a meus pais Héctor Manuel Orellana San Martín e Nidia Teresa Cruz Casaña e meus irmãos Jorge Luis Orellana e Carlos Andrés Orellana por seu carinho, incentivo e apoio.

Ao professor Fabio Berrequini pela sua orientação, pelo apoio e pela confiança em meu trabalho e encinamento; aos professores e funcionários da FEIS-UNESP que contribuíram para a realização deste trabalho.

A meus amigos Luis de Oro, Ozy Melgar, Juan Pérez, Carlos Sabillón, Julia Rivera, Esaú Figueroa e aos meus amigos e colegas do LAPSEE pela companhia e ajuda durante estes anos;

A Geovanna Moya por seu carinho e incondicional apoio;

A CAPES – Coordenação de aperfeiçoamento de pessoal de nível superior, pelo suporte financeiro oferecido para o desenvolvimento deste projeto.

“La ignorancia aparenta ser inofensiva, hasta que comienzas a combatirla”

**Anónimo.**

## RESUMO

Este trabalho propõe abordar o problema de alocação de dispositivos indicadores de faltas (IFs) em redes de distribuição de energia elétrica por meio da técnica do Algoritmo Genético Adaptativo (AGA). O algoritmo busca obter uma configuração eficiente de instalação de IFs no sistema e reduzir o custo anual da energia não suprida (CENS) e por outro lado, o custo anual de investimento dos sensores (CINV). Estes custos conflitantes devem ser minimizados como um problema combinatório utilizando o AGA que possui taxas de recombinação e mutação dinamicamente calibradas baseadas na diversidade de cada população no processo. Os resultados mostram que o AGA é um método efetivo para encontrar soluções para o problema de alocação de IFs. Quando comparado com o AG clássico em vários testes, é observado que o AGA tem uma convergência mais rápida mostrando ser mais eficiente. Além disso, o AGA é utilizado para obter uma variedade de soluções numa Fronteira de Pareto aproximada variando os pesos do CENS e o CINV na função objetivo. Portanto, esta metodologia permite obter um conjunto de soluções em lugar de uma única solução e a partir da Fronteira de Pareto é possível escolher a solução que melhor satisfaz os interesses técnicos e econômicos da concessionária de distribuição de energia elétrica.

Palavras-Chaves: Algoritmo genético adaptativo. Indicadores de faltas. Qualidade do serviço. Distribuição de energia elétrica.

## ABSTRACT

This work proposes the Adaptive Genetic Algorithm (AGA) to solve the problem of Fault Indicator (FI) placement in electric distribution systems. The algorithm attempts to obtain an efficient configuration for the installation of FIs in the system and reduce the annual customer interruption cost (CIC) and on the other hand, the annual investment cost (CINV) of the fault indicators placement. These two conflicting costs must be minimized as a problem of combinational nature with the AGA which uses dynamically calibrated crossover and mutation rates based on the diversity of each population of the process. Results show that the AGA is an effective method to find solutions to the problem of fault indicator placement. When compared with the classic GA in various tests, it is observed that the AGA converges faster showing to be more efficient. Besides, in the last test the AGA is used to obtain a variety of solutions in an approximate Pareto Front by varying the weighting factors of the CIC and CINV in the objective function. Therefore, this methodology permits to obtain a set of solutions instead of one only solution and from the Pareto Front it is possible to choose the solution that best satisfies the technical and economic interests of the concessionary.

**Keywords:** Adaptive genetic algorithm. Fault indicators. Service quality. Electric energy distribution.



## LISTA DE FIGURAS

Figura 1 – Alimentador de 2002 barras.....	15
Figura 2 – Representação da lógica Fuzzy.....	19
Figura 3 – Processo para encontrar a solução pelo Algoritmo Imune.....	21
Figura 4 – Sistema de distribuição com 4 sensores IFs alocados.....	32
Figura 5 – Codificação para o AGA par ao sistema da figura 4.....	34
Figura 6 – Diagrama de blocos para o AGA multiobjetivo.....	35
Figura 7 – Codificação exemplo da população inicial para o sistema de 19 barras.....	37
Figura 8 – Sistema de distribuição de 19 barras.....	39
Figura 9 – Sistema de distribuição de 34 barras.....	40
Figura 10 – Sistema de distribuição e 134 barras.....	41
Figura 11 – Evolução do AGA e o AG para o sistema de 19 barras.....	45
Figura 12 – Evolução do AGA e o AG para o sistema de 34 barras.....	45
Figura 13 – Evolução do AGA e o AG para o sistema de 134 barras.....	46
Figura 14 – Evolução da diversidade, recombinação e mutação para o sistema de 19 barras.....	46
Figura 15 – Evolução da diversidade, recombinação e mutação para o sistema de 34 barras.....	47
Figura 16 – Evolução da diversidade, recombinação e mutação para o sistema de 134 barras.....	47
Figura 17 – Fronteira de Pareto para o sistema de 19 barras.....	51
Figura 18 – Ampliação da Figura 17 para o sistema de 19 barras.....	52
Figura 19 – Fronteira de Pareto para o sistema de 34 barras.....	52
Figura 20 – Ampliação da Figura 19 para o sistema de 34 barras.....	53
Figura 21 – Fronteira de Pareto para o sistema de 134 barras.....	53
Figura 22 – Ampliação da Figura 21 para o sistema de 134 barras.....	54

## LISTA DE TABELAS

<b>Tabela 1 – Melhores parâmetros de simulação para o AGA.....</b>	<b>42</b>
<b>Tabela 2 – Melhores respostas das simulações do AGA. ....</b>	<b>42</b>
<b>Tabela 3 – Melhores parâmetros de simulação para o AG. ....</b>	<b>43</b>
<b>Tabela 4 – Melhores respostas das simulações do AG .....</b>	<b>43</b>
<b>Tabela 5 – Tempos computacionais de convergência para o AGA e o AG.....</b>	<b>44</b>
<b>Tabela 6 – Resultados para a Fronteira de Pareto do sistema de 19 barras.....</b>	<b>48</b>
<b>Tabela 7 – Dados de entrada do sistema teste de 19 barras. ....</b>	<b>59</b>
<b>Tabela 8 – Dados de entrada do sistema teste de 34 barras .....</b>	<b>60</b>
<b>Tabela 9 – Dados de entrada do sistema teste de 134 barras .....</b>	<b>61</b>
<b>Tabela 10 – Resultados para a Fronteira de Pareto do sistema de 34 barras.....</b>	<b>65</b>
<b>Tabela 11 – Resultados para a Fronteira de Pareto do sistema de 134 barras.....</b>	<b>67</b>

## LISTA DE ABREVIATURAS E SIGLAS

AEMO	-Algoritmo Evolutivo Multiobjetivo
AG	-Algoritmo Genético clássico
AGA	-Algoritmo Genético Adaptativo
AHC	-Algoritmo Heurístico Construtivo
CENS	- Custo da Energia Não Suprida
CIC	-Custo de Interrupção do Consumidor
CINV	-Custo de Investimento dos sensores
CNS	-Clientes Não-Supridos
DEC	-Duração Equivalente de interrupção por unidade Consumidora
ECOST	-Custo Esperado de interrupção do cliente
END	-Energia Não Distribuída
ENS	- <i>Energy Not Supplied</i>
IF	- Indicador de Falta
INVC	- <i>Investment Cost of FIs</i>
LF	-Lógica Fuzzy
MOSP	- <i>Multi-objective Switch Positioning</i>
NSGA-II	- <i>Non-dominated Sorting Genetic Algorithm II</i>
SAIDI	- <i>System Average Interruption Duration Index</i>
TCR	- <i>Total Cost of Reliability</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>11</b>
1.1	JUSTIFICATIVA PARA ALOCAÇÃO DE IFS .....	11
1.2	O PROBLEMA DE ALOCAÇÃO DOS IFS NOS SISTEMAS DE DISTRIBUIÇÃO .....	12
1.3	METODOLOGIA PROPOSTA PARA ALOCAÇÃO DE IFS .....	12
1.4	ORGANIZAÇÃO DA DISSERTAÇÃO .....	13
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>14</b>
2.1	O PROBLEMA DE ALOCAÇÃO DE IFS EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA .....	14
2.2	ALGORITMO GENÉTICO .....	22
2.3	OTIMIZAÇÃO EVOLUTIVA MULTI OBJETIVO .....	25
<b>3</b>	<b>METODOLOGIA PARA ALOCAÇÃO OTIMIZADA DE INDICADORES DE FALTA EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA...29</b>	
3.1	FORMULAÇÃO DO PROBLEMA .....	29
<b>3.1.1</b>	<b>EXEMPLO DE CÁLCULO DO CENS .....</b>	<b>31</b>
3.2	ALGORITMO GENÉTICO ADAPTATIVO APLICADO AO PROBLEMA.....	33
<b>4</b>	<b>TESTES E RESULTADOS .....</b>	<b>39</b>
4.1	SISTEMAS TESTES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA.....	39
4.2	SIMULAÇÕES CONSIDERANDO PESOS $\omega_1 = \omega_2 = 0,5$ .....	41
4.3	RESULTADOS PARA A ANÁLISE MULTI OBJETIVO DO PROBLEMA DE ALOCAÇÃO DE IFS EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA .....	47
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS.....</b>	<b>55</b>
5.1	CONCLUSÕES .....	55
5.2	TRABALHOS FUTUROS .....	56
	<b>REFERÊNCIAS.....</b>	<b>56</b>
7	<b>APÊNDICE A - Dados de entrada dos sistemas testes.....</b>	<b>59</b>
	<b>APÊNDICE B - Resultados para a Fronteira de Pareto aproximada.....</b>	<b>65</b>

## 1 INTRODUÇÃO

Neste capítulo, é exposta a necessidade da alocação de indicadores de faltas, o problema da localização de indicadores de faltas e a metodologia para resolver o modelo proposto

### 1.1 JUSTIFICATIVA PARA ALOCAÇÃO DE IFS

Quando ocorre uma falta na rede de distribuição de energia elétrica pode haver a interrupção do suprimento de energia elétrica a diversos consumidores. Um grande número de interrupções ao longo de um período de tempo representa uma pior qualidade da energia para os consumidores. As faltas podem ser classificadas em duas categorias; as faltas temporárias ou transitórias e as permanentes. A ocorrência de uma falta temporária interrompe o fornecimento da energia elétrica durante um tempo limitado; devido sua característica e o sistema de proteção estando adequadamente projetado, as faltas temporárias são eliminadas através da atuação da proteção e o restabelecimento do serviço é realizado de forma automática. Por outro lado faltas permanentes não podem ser eliminadas mesmo depois que uma chave seccionadora ou dispositivo automático como relés e religadores operam para restabelecer o fornecimento de energia. Portanto para faltas do tipo permanente as equipes de manutenção devem localizar a falta na rede de distribuição e reparar o defeito no menor tempo possível. O objetivo principal é reduzir o tempo de localização da falta e reparo do defeito e, portanto, reduzir o tempo da interrupção do sistema melhorando a qualidade do serviço prestado. O reparo do defeito demora certo tempo e boa parte deste tempo de reparação se deve à busca do local da falta. Neste sentido o processo de identificação do local da falta será mais rápido se houver mais informação sobre a falta. Conseqüentemente o restabelecimento no fornecimento da energia elétrica será mais rápido.

Nesse contexto os IFS destacam-se como dispositivos adequados para a detecção de pontos defeituosos porque eles fornecem informação útil sobre as faltas no sistema sinalizando a passagem de uma sobrecorrente ou corrente de curto-circuito. Estudos apontam que com a instalação de IFS em pontos estratégicos pode-se reduzir o tempo de interrupção em até 60% devido ao tempo gasto pelas equipes para localizar a falta a partir das informações dos IFS (USIDA et al., 2010).

## 1.2 O PROBLEMA DE ALOCAÇÃO DOS IFS NOS SISTEMAS DE DISTRIBUIÇÃO

Deve-se notar que não é viável e tão pouco necessário instalar IFS em todos os ramais da rede de distribuição de modo a melhorar a confiabilidade da rede. Desta forma tem-se o problema de alocação de IFS como um problema de otimização combinatória e os sensores devem ser alocados estrategicamente a partir de determinado critério que, no caso deste trabalho, é minimizar o Custo de Energia Não Suprida (CENS) e o Custo de Investimento dos Sensores (CINV) simultaneamente. Na literatura há alguns métodos propostos para a resolução deste problema que são baseados nas técnicas: Algoritmos Genéticos (ALMEIDA et al. 2011; RAISON et al. 2005; USIDA; COURRY, 2012; USIDA et al. 2012; USIDA et al. 2010), Lógica Fuzzy (DE SOUZA et al., 2009), Colônia de formigas (SAL; ALMEIDA, 2014) e Algoritmo Imune (HO; LEE; LIN, 2011).

## 1.3 METODOLOGIA PROPOSTA PARA ALOCAÇÃO DE IFS

Neste trabalho a função objetivo é baseada nos custos conflitantes (CENS e CINV) os quais devem ser minimizados de modo que a solução reflita o compromisso entre o custo da energia não suprida e o custo de investimento na alocação dos sensores. Neste trabalho, o problema de alocação de sensores, que trata da minimização simultânea do CENS e CINV, é tratado como um problema mono-objetivo sendo a função objetivo do problema formulada através da soma ponderada dos dois custos conflitantes.

A técnica de solução proposta é o Algoritmo Genético Adaptativo (AGA) baseado em (LEÃO; PEREIRA; MANTOVANI, 2014) onde destaca a sua efetividade na solução de problemas multimodais e de difícil resolução. O AGA também foi escolhido por apresentar como vantagem a necessidade de calibração de somente dois parâmetros: o tamanho da população e o número máximo de gerações (as taxas de recombinação e mutação são automaticamente calculadas em cada geração no AGA).

Nesta dissertação é proposta uma nova estratégia heurística para geração da população inicial do AGA. Também são realizadas adaptações no algoritmo para obtenção de uma Fronteira de Pareto aproximada com um conjunto das melhores soluções através da variação dos pesos da função objetivo. Dentre as características do AGA pode-se observar que ele possui taxas de recombinação e mutação automática e dinamicamente calibradas em cada

geração, baseadas na saturação da população corrente, possuindo uma imediata resposta à possível convergência prematura para ótimos locais.

Para testar a metodologia são considerados dois casos de estudo: 1) fixando os pesos de forma a dar igual importância aos dois objetivos conflitantes e desta maneira comparar o AGA com o AG e 2) realizando a variação dos pesos de forma a obter um conjunto de soluções ou uma Fronteira de Pareto aproximada. A partir dos resultados são realizadas comparações entre a melhor solução encontrada no caso 1) com as soluções obtidas no caso 2). Para os dois casos de estudo o método é capaz de encontrar soluções de boa qualidade.

#### 1.4 ORGANIZAÇÃO DA DISSERTAÇÃO

A dissertação está organizada da seguinte forma. No capítulo 2 é apresentada uma revisão bibliográfica das metodologias existentes para resolver o problema de alocação de sensores indicadores de faltas; as metodologias incluem critérios de avaliação e métodos para encontrar soluções para o problema. A seguir é apresentada a teoria sobre algoritmos genéticos.

No capítulo 3 é apresentada a formulação matemática incluindo a codificação das configurações candidatas e os critérios para avaliar a sua qualidade como soluções ao problema. Neste capítulo também é apresentado o algoritmo genético adaptativo, o qual é utilizado neste trabalho e são apresentados os sistemas testes que serão utilizados para demonstrar a metodologia de solução

No capítulo 4 são mostrados os testes e resultados do trabalho utilizando o AGA e o AG para resolver o problema de alocação de IFs considerando os sistemas testes. Finalmente o capítulo 5 apresenta as conclusões do trabalho e propõe ideias para trabalhos futuros que podem contribuir para expandir o conhecimento na solução deste problema.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo serão apresentadas as publicações de trabalhos que expõem o estado da arte do problema de alocação de sensores indicadores de faltas em sistemas de energia elétrica.

### 2.1 O PROBLEMA DE ALOCAÇÃO DE IFS EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Os trabalhos propostos na literatura para resolver o problema de alocação de IFs em redes de distribuição de energia elétrica têm considerado como variáveis principais os dados do alimentador como a carga, o número de unidades consumidoras, a distância entre equipamentos de proteção com função de indicação de falta e entre dispositivos indicadores de faltas. Em Usida et al. (2010) é utilizada a meta-heurística Algoritmo Genético (AG) como técnica de solução, e para a avaliação das soluções os autores propõem como função objetivo a expressão matemática descrita em (1):

$$f(x, y, z) = \sum_{i=1}^n (x_i + y_i) * z_i \quad (1)$$

Onde  $x_i$  é a variável que representa a carga da barra avaliada,  $y_i$  o número de unidades consumidoras referente a barra avaliada pertencente ao tronco principal,  $z_i$  a representação da distância de cada barra ao mais próximo elemento de indicação de falta e  $n$  representa o número de barras que compõem o tronco principal. As variáveis  $x_i$ ,  $y_i$  e  $z_i$  são consideradas como valores normalizados. Esta função objetivo que deve ser minimizada considera variáveis do alimentador como a carga, o número de unidades consumidoras e a distância entre equipamentos de proteção.

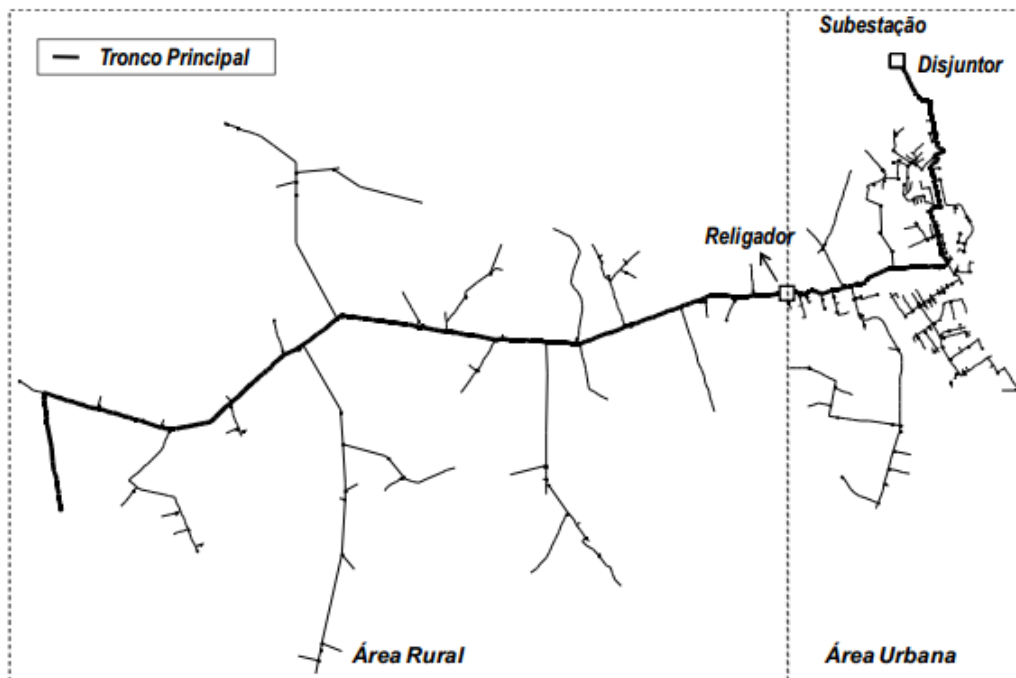
O trabalho considera a alocação dos IFs somente no tronco principal do alimentador, o qual deve ser determinado. O tronco principal é responsável em atender todas as cargas do alimentador. A proposta é justificada pois numa falta o restabelecimento do serviço poderá ser feito gradualmente conforme as equipes de manutenção percorram o tronco principal e verifiquem que o ponto defeituoso está à montante ou à jusante do último IF inspecionado.



No AG cada indivíduo da população deve representar uma possível solução do problema tratado e adotou-se a codificação inteira para os indivíduos ao invés da binária. Cada indivíduo é um vetor do tamanho igual a  $n$ , indicando o número de IFs que devem ser alocados no alimentador.

Resultados foram obtidos a partir de um alimentador real de 13,8kV, com 2002 barras e 2001 trechos primários, 5480 unidades consumidoras, e uma carga de 16,02 MVA conforme ilustrado na Figura 1.

Figura 1 – Alimentador de 2002 barras.



Fonte: (USIDA et al., 2010) .

O algoritmo encontrou configurações para diferentes valores de  $n$  e para cada configuração foram avaliados indicadores de qualidade da resposta (DEC: duração equivalente de interrupção por unidade consumidora, END: a energia não distribuída, Custo de interrupção da energia anual, Custo do IF anual). Com os indicadores pode-se notar a configuração que tem o menor custo de interrupção de energia sem ser superado pelo custo de IF.

Na pesquisa apresentada por Usida e Coury (2012), a alocação de sensores também foi limitada ao tronco principal o qual deve ser determinado para cada sistema. Este trabalho utiliza o sistema da Figura 1 de 2002 barras para a realização dos testes.

Conforme este artigo, para avaliar as configurações candidatas, é necessário levar em conta algumas variáveis do alimentador como a carga em cada barra, o número de consumidores em cada barra e as distâncias entre os dispositivos de proteção ou com detecção de faltas no sistema. A carga total e o número de consumidores dependendo de uma barra são fatores que fazem esta barra uma boa candidata para ter instalado um IF. Por outro lado, se outra barra próxima a barra candidata tem um IF instalado, a probabilidade da primeira barra de ter um IF instalado diminui.

No trabalho utilizam-se dois fatores de ponderação na função objetivo apresentada em (2).

$$f_{\text{objetivo}} = \sum_{i=1}^M (\alpha_1 l_i + \alpha_2 c_i) * d_i(\overline{FI}) \quad (2)$$

Onde  $l_i$  é a carga média normalizada na barra  $i$ ,  $c_i$  é o número de consumidores em  $i$ ,  $d_i(FI)$  é o vetor da distância da barra  $i$  até seu IF mais próximo,  $(FI)$  é o vetor que representa a localização atual dos IF no tronco principal e  $M$  é o número de barras no tronco principal. As constantes  $\alpha_1$  e  $\alpha_2$  são os fatores de ponderação para a carga e para o número de consumidores respectivamente.

A partir da variação dos parâmetros  $\alpha_1$  e  $\alpha_2$  pode-se ponderar um dos dois critérios para avaliar configurações possíveis (carga ou número de consumidores). No artigo os dois parâmetros foram considerados iguais a 1,0, mas conforme o usuário deseje pode priorizar um dos dois critérios de modo a aumentar o peso dos termos na solução do problema conforme a políticas de fornecimento de energia ou interesses monetários da distribuidora. O indicador de qualidade SAIDI (*System Average Interruption Duration Index*) e a ENS (*Energy Not Supplied*) são calculados a partir da melhor solução de alocação de IFs.

Testes foram realizados limitando a quantidade de IFs a alocar, desde 0 IFs até 10 IFs. Para cada caso uma configuração foi obtida, e para cada uma o SAIDI e a ENS foram avaliados. Para o custo estimado dos IFs é levado em conta o custo de compra, custo de instalação, custo de manutenção e vida útil do IF.

Os autores consideram que o ponto de decisão é o ponto onde o custo dos IFs resulta maior que o custo da energia não suprida. Se o custo dos IFs é maior, o investimento para essa alocação não é viável. Este ponto de decisão é o caso onde são alocados 7 IFs (o caso onde o custo de investimento ainda é menor que o custo da energia não suprida). Se são alocados 8 o investimento em IFs supera o custo da energia não suprida para esta configuração.

Em Raison et al. (2005) os autores abordam o problema de alocação de IFs também utilizando um AG como técnica de solução levando em conta a geração distribuída (GD) nos alimentadores. Com a GD, além da interrupção de energia dos consumidores, deve-se considerar a energia não fornecida pelos geradores. A função objetivo é determinada levando em conta a probabilidade de falta de cada zona e um dos seguintes critérios:

-Tempo de interrupção médio de cada cliente

$$ATO = \frac{\sum_{c=1}^{N_{customer}} \sum_{z=1}^{N_{zone}} OTime_{-c-z} \cdot \lambda_{Zone_{-z}}}{N_{customer}} (h/year) \quad (3)$$

-Energia não distribuída

$$NDE = \sum_{z=1}^{N_{zone}} NDEnergy_{-z} \cdot \lambda_{Zone_{-z}} (kWh/year) \quad (4)$$

-Custo de interrupção

$$OuC = \sum_{z=1}^{N_{zone}} OCost_{-z} \cdot \lambda_{Zone_{-z}} (\text{€}/year) \quad (5)$$

-Custo global

$$Global = \sum_{z=1}^{N_{zone}} OCost_{-z} \cdot \lambda_{Zone_{-z}} + N_{FI} \cdot FI_{-cost} (\text{€}/year) \quad (6)$$

Com os custos dos IF calculados em (7).

$$FI_{-cost} = \frac{FI_{-price} + FI_{-inst}}{FI_{-age}} + FI_{-maint} \quad (7)$$

Sendo  $FI_{-cost}$  o custo anual por IF,  $FI_{-price}$  o custo de compra do IF,  $FI_{-inst}$  o custo de instalação e  $FI_{-age}$  é a vida útil do IF e  $FI_{-maint}$  é o custo de manutenção. O sistema tem  $N_{zones}$  zonas,  $N_{customers}$  consumidores e  $N_{FI}$  IFs. O trabalho utiliza uma codificação binária para os indivíduos.

Várias simulações foram feitas variando o número de IFs a alocar de 1 até 10 e com a melhor configuração em cada caso foram avaliados indicadores de qualidade a través do cálculo das equações (3) a (6).

No trabalho de Almeida et al. (2011) é proposto um método baseado em impedâncias utilizando IFs para eliminar a incerteza do ponto da falta. Para resolver o problema de otimização é utilizado o AG Chu-Beasley. No trabalho também é pré-determinado um número fixo de IFs e o método tenta alocá-los reduzindo as incertezas para localização do ponto da falta (todos os possíveis pontos onde pode ser encontrada a falta). Com isto as configurações que apresentam menores números de localizações suspeitas são consideradas de melhor qualidade. São considerados diferentes critérios para três diferentes funções objetivo: o critério do número suspeito de pontos de falta, critério da distância entre locais suspeitos e o critério de prioridade.

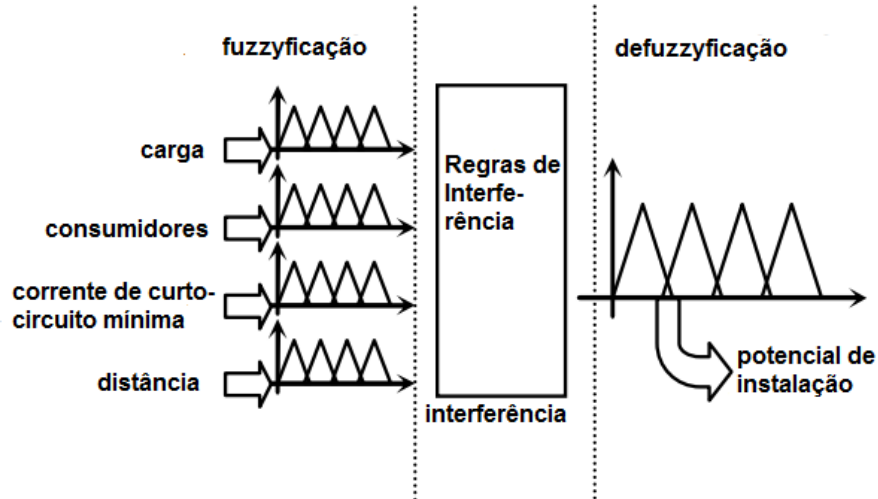
Os sistemas testes utilizados foram o IEEE de 34 barras e um sistema real de 475 barras. Os critérios utilizados encontraram soluções de melhor qualidade que os métodos ad hoc anteriores e demonstraram ser efetivos para alimentadores de grande porte.

Em De Souza e Da silva (2009) os autores buscam resolver o problema com Lógica Fuzzy (LF). Em lugar de encontrar uma solução do problema de alocação o trabalho avalia variáveis que afetam a quantificação de potenciais pontos para a instalação de IFs no alimentador. O trabalho também faz uso da identificação do tronco principal para alocação e assim reduzir a quantidade dos pontos candidatos para a alocação.

São considerados os sistemas testes denominados por PDS-1 e PDS-2. Para os sistemas são analisadas informações como carga e número de consumidores os quais são normalizados para o procedimento de solução. Outras informações analisadas são: o comportamento da corrente de curto circuito mínima ao longo do alimentador e a distância normalizada até o IF mais próximo ao longo do alimentador.

O sistema de inferência Fuzzy foi formulado (Figura 2) para calcular os potenciais pontos para a instalação de IFs. A vantagem da LF é que permite tomar decisões quando há muita incerteza na informação inicial. O processo leva em conta as variáveis anteriormente mencionadas e como estão normalizadas, as entradas são valores entre 0 e 1. O sistema de inferência Fuzzy, apresentado na Figura 2, é um sistema que utiliza 28 regras para finalmente calcular os potenciais pontos para instalação de IFs para os dois sistemas. O trabalho conclui que a lógica fuzzy é efetiva na busca de pontos para a alocação de IFs e é útil para avaliar a qualidade de redes existentes com IFs instalados.

Figura 2 – Representação da lógica Fuzzy.



Fonte: Adaptado (DE SOUZA; DA SILVA, 2009) .

Em Sau e Almeida (2014) os autores dividem o problema em duas partes. Na primeira parte é exposta uma ferramenta utilizando o algoritmo de Colônia de Formigas para calcular a distância percorrida pelas equipes de manutenção entre os pontos suspeitos da falta. A metodologia é associada à estimação da distância e tem por objetivo a minimização do deslocamento da equipe de manutenção. A segunda parte foi baseada em algoritmos genéticos e é utilizada para avaliar as propostas de alocação de IFs obtidas na primeira parte. A maior contribuição deste trabalho é o uso de distâncias reais na função objetivo.

É utilizado um método baseado em passos de impedância para a estimação da distância na localização da falta. O trabalho utiliza dois critérios para alocação dos IFs: o número de locais suspeitos e a distância entre os locais suspeitos.

A metodologia parte do princípio de que as formigas criam um caminho que liga todos os pontos suspeitos; isto é para cada passo de impedância. O caminho (chamado percurso) é a soma dos comprimentos dos trechos usados pela formiga para sair de um ponto suspeito e chegar aos demais com a mesma impedância. A função objetivo a ser minimizada é o percurso da formiga, porque a necessidade é a otimização das rotas. No problema as rotas ligam os pontos suspeitos e dependendo das ramificações da rede podem haver diversos pontos suspeitos com a mesma impedância. Portanto deve-se escolher um passo de

impedância que permite a inclusão de pelo menos um ponto suspeito por cada ramo do sistema.

As formigas têm informação a través do feromônio. Ao final de cada iteração o conjunto de formigas acrescenta o feromônio nos trechos, e para evitar a convergência prematura, é considerada uma evaporação.

A saída deste algoritmo tem os ramos suspeitos da falta para diferentes valores do passo de impedância e a distância percorrida entre eles. Estes dados são usados no cálculo da função objetivo (8).

$$F_d = \sum_i^p \sum_j^m d_{ij} \quad (8)$$

onde  $d_{ij}$  é a distância real passando pelos acessos entre os pontos suspeitos indicados na linha  $i$  e na coluna  $j$  da matriz de pontos suspeitos.

O sistema utilizado é o IEEE 34 barras e para o algoritmo foram considerados os passos de impedância de  $1 \Omega$  e  $0,1 \Omega$ . Para verificar a eficiência do método de distância percorrida foi calculado para cada quantidade de IFs a instalar o número de possíveis soluções. Também foi analisado o efeito do passo de impedância no resultado calculando o número necessário de IFs para eliminar todos os pontos suspeitos da falta.

O trabalho conclui que a metodologia associada para a estimação de distância se mostrou bastante eficiente. Além disso, o uso das distâncias reais leva a melhor distinção entre pontos suspeitos resultando em uma menor quantidade de propostas de alocação.

Em Ho, Lee, Lin (2014) os autores examinam a aplicação do Algoritmo Imune (AI) no problema de alocação de IFs minimizando o custo total da energia não suprida e o custo de investimento dos IFs conforme a equação (9). O trabalho utiliza como sistemas testes reais um sistema exemplo e um da companhia *Taiwan Power* para demonstrar a efetividade do AI. Este algoritmo apresenta vantagens sobre os AGs clássicos apresentando convergência em menor tempo computacional. Os autores afirmam que esta vantagem é devido ao fato de que a diversidade da população está incorporada no algoritmo a partir do cálculo de afinidade e a proposta de injeção de vacinas nos indivíduos em cada geração.

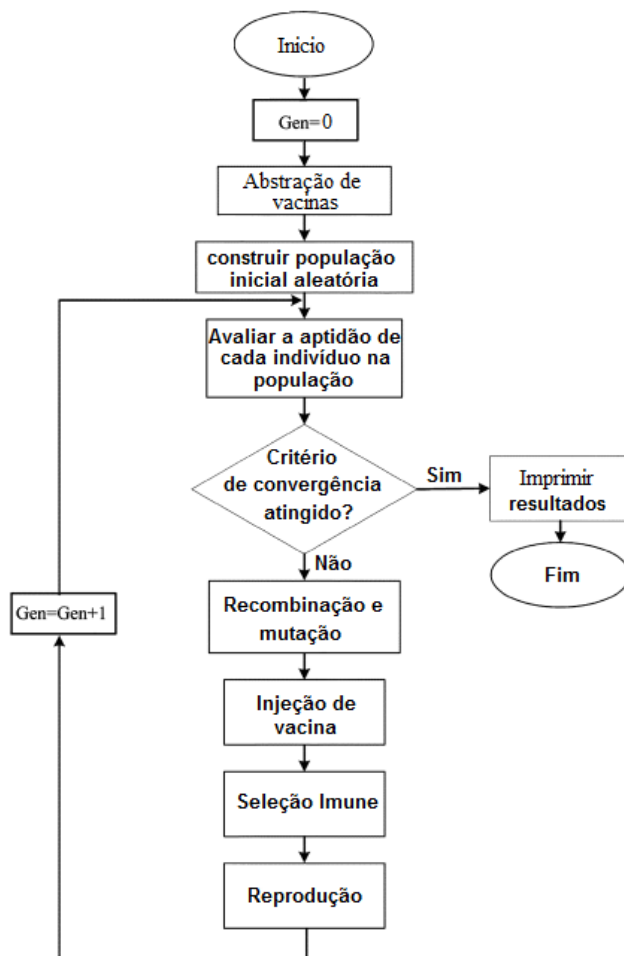
$$TCR = CIC + INVC \quad (9)$$

O TCR é definido como (*Total Cost of Reliability*), INVC (*Investment Cost of FIs*) é o custo de investimento dos IFs (o custo de compra é determinado pelo fabricante) e o CIC (*Customer Interruption Cost*) é o custo de interrupção do consumidor. O CIC é calculado em:

$$CIC = \sum_{i=1}^m \lambda_i l_i \left( \sum_{j=1}^m C_{ij} L_j \right) \quad (10)$$

Onde  $m$  é um número de segmento da linha,  $ICI$  o custo de interrupção por ano,  $\lambda_i$  a taxa de interrupção (faltas por ano por km),  $l_i$  o comprimento da linha,  $C_{ij}$  o custo de interrupção no segmento  $j$  devido a interrupção no segmento  $i$ ,  $L_j$  a carga total do segmento  $j$ . A função TCR então deve ser minimizada.

Figura 3 –Processo para encontrar a solução pelo Algoritmo Imune.



Fonte: Adaptado (HO; LEE; LIN, 2014) .

O algoritmo imune é amplamente utilizado para resolver problemas de otimização. A capacidade de reconhecimento e memorização de padrões do método é eficiente para resolver os problemas de otimização comparado com o AG. Os operadores no algoritmo são de recombinação, mutação e o operador das vacinas; o algoritmo é ilustrado na Figura 3.

O indicador custo total de confiabilidade (TCR); foi calculado para diferentes quantidades de IFs a alocar e os resultados apontaram que 6 IFs é a quantidade com a melhor resposta. Depois foram avaliados outros dois indicadores, o custo esperado de interrupção do cliente (ECOST) e o SAIDI. O método é comparado, usando o mesmo sistema teste, com o algoritmo imune sem vacinas e com o AG, concluindo que o algoritmo imune com vacinas converge em menor tempo computacional.

Em conclusão, o método utiliza conhecimento prévio do sistema para resolver o problema. Este conhecimento é utilizado nas vacinas como os níveis de prioridade dos clientes. O algoritmo imune demonstrou ser mais efetivo para encontrar soluções comparado com o AG e demonstrou a vantagem de utilizar vacinas para a sua rápida convergência.

## 2.2 ALGORITMO GENÉTICO

É uma meta-heurística desenvolvida por Holland na década de 70 sendo que apenas na década de 80 teve sua aplicação de forma intensa para resolver problemas complexos no campo da pesquisa operacional. Holland encontrou semelhanças entre a forma de resolver um problema de otimização matemática e o processo de seleção natural e de evolução das espécies. Na verdade, na natureza o processo de seleção natural e a evolução das espécies é a consequência de um processo de otimização estocástico (ROMERO; LAVORATO, 2012).

Na realidade o processo de seleção natural e a evolução das espécies é um problema muito complexo para que seja imitado de forma adequada por um processo de otimização no campo da pesquisa operacional. Então, pode-se afirmar que o AG imita apenas uma parcela dos componentes que fazem parte do processo de seleção natural.

O algoritmo tem elementos que não acompanham de forma adequada o processo de seleção natural, mas são elementos do AG:



- Um cromossomo na genética é considerado como equivalente a uma proposta de solução (configuração) no problema de otimização. Uma proposta de solução, deveria ser equivalente a um indivíduo; também na genética não existe um cromossomo, mas uma cadeia cromossômica.
- Um cromossomo na genética na verdade é um par cromossômico formado por duas cadeias de informação; um herdado do pai e outro herdado da mãe. Além disso, cada elemento do cromossomo (gene) tem dois componentes (alelo), um de cada cadeia.
- A informação em cada gene é chamada genótipo e têm relação com uma característica do indivíduo chamado fenótipo.
- Não existe uma relação biunívoca entre informação genética e o fenótipo.
- O fenômeno de dominância em que um alelo domina o outro não se encontra no AG.
- O fenômeno de recombinação é fundamental para a existência da diversidade genética que é a chave fundamental na seleção natural.
- No AG o fenômeno de recombinação over é imitado pelo operador de recombinação.
- A mutação ocorre quando um gene é alterado mudando a qualidade do indivíduo.

Um algoritmo genético básico assume a seguinte forma:

1. Passo preliminar.

- Definir os dados do problema.
- Escolher uma forma de codificação para a proposta de solução denominada de  $p$ .
- Escolher a forma de avaliar a qualidade da proposta de solução através de uma função objetivo -  $f(p)$ .

- Escolher os valores dos parâmetros: população  $np$ , a taxa de recombinação  $pr$ , a taxa de mutação  $pm$  e o tipo de seleção.
  - Escolher o critério de parada.
2. Gerar a população inicial. Esta se converte na primeira população corrente.
  3. Avaliar a qualidade de todos os elementos da população corrente, e se for possível atualizar a incumbente. A incumbente é a melhor configuração encontrada até o momento no processo e é armazenada na memória para ser comparada nas gerações posteriores. Se é encontrada uma configuração de melhor qualidade, essa configuração é a nova incumbente e é armazenada.
  4. Se o critério de parada for satisfeito pare; caso contrário ir ao passo 5.
  5. Implementar o operador de seleção.
  6. Implementar o operador de recombinação.
  7. Implementar o operador de mutação, atualizar a população corrente e voltar ao passo 3.

Alguns problemas precisam de uma codificação binária, mas os algoritmos genéticos modernos seguem a proposta de Michalewicz sugerindo que a codificação deve ser realizada seguindo a natureza e as características do problema. Esta codificação pode ser observada em (MICHALEWICZ, 1996).

A população inicial pode ser gerada de forma aleatória e para problemas complexos pode ser utilizado um algoritmo heurístico construtivo (AHC) generalizado para gerar esta primeira população. Também o operador de seleção determina o número de participantes que deve ter cada elemento da população corrente na nova geração. Na proposta inicial do algoritmo genético, o operador de seleção era implementado usando a seleção proporcional que determina o número de participações de cada proposta de solução.

Na década de 90 apareceram muitas propostas alternativas para a seleção proporcional e aplicações recentes dos AGs praticamente abandonaram a lógica de proporcionalidade. Destas soluções alternativas destaca-se a seleção por torneio que tem as seguintes características:

- Os descendentes são escolhidos realizando  $np$  jogos.
- Em cada jogo são escolhidos aleatoriamente  $k$  propostas de solução.
- Das  $k$  propostas de solução a ganhadora é aquela que tem o valor de melhor qualidade.
- O valor de  $k$  geralmente é pequeno. Tipicamente  $k \in \{2,3,4,5\}$ .
- Após os  $np$  jogos termina o processo de seleção.

O operador de recombinação escolhe duas propostas de solução com direito a gerar novos descendentes e recombina essas soluções gerando duas candidatas a novas soluções. Estas novas soluções têm parcelas das soluções geradoras anteriores.

A mutação significa uma pequena perturbação na composição de uma proposta de solução. Em uma codificação binária o gene troca de valor o 1 para 0 ou de 0 para 1.

### 2.3 OTIMIZAÇÃO EVOLUTIVA MULTI OBJETIVO

O trabalho de Zitzler et al. (2004), expõe a relação entre os algoritmos evolutivos e as soluções dos problemas com múltiplos objetivos conflitantes apresentando uma visão geral na teoria de otimização evolutiva multiobjetivo. Também apresenta princípios na otimização multiobjetivo e algoritmos evolutivos destacando características de atribuição de qualidade, preservação de diversidade e elitismo.

Tem-se um cenário com um problema multiobjetivo arbitrário com  $k$  objetivos, que por simplicidade devem ser todos maximizados. A solução deste problema pode ser descrita em termos de um vetor de decisão  $(x_1, x_2, \dots, x_n)$  no espaço de decisão  $\mathbf{X}$ . Uma função  $f$  avalia a qualidade de uma solução através da obtenção do vetor objetivo  $(y_1, y_2, \dots, y_n)$  no espaço objetivo  $\mathbf{Y}$ .

Supondo que o espaço objetivo é um subconjunto dos números reais e que o objetivo da otimização é maximizar um único objetivo, uma solução  $\mathbf{x}^1$  em  $\mathbf{X}$  é melhor que outra solução  $\mathbf{x}^2$  em  $\mathbf{X}$  se  $\mathbf{y}^1 = \mathbf{f}(\mathbf{x}^1)$  é maior que  $\mathbf{y}^2 = \mathbf{f}(\mathbf{x}^2)$ . Apesar de que muitas soluções podem existir num

espaço de decisão todas estão no mesmo vetor objetivo. Portanto, existe somente uma solução otimizada no espaço objetivo.

No caso de uma função de avaliação vetorial, a comparação entre duas soluções  $\mathbf{x}^1$  e  $\mathbf{x}^2$  é mais complexa. Logo, o conceito de dominância de Pareto é abordado a seguir: um vetor objetivo  $\mathbf{y}^1$  é dito dominar outro vetor objetivo  $\mathbf{y}^2$  se nenhum componente de  $\mathbf{y}^1$  é menor que o componente correspondente de  $\mathbf{y}^2$  e pelo menos um componente é maior (considerando um processo de maximização). Consequentemente, pode ser dito que a solução  $\mathbf{x}^1$  é melhor que a solução  $\mathbf{x}^2$ ,  $\mathbf{x}^1$  domina  $\mathbf{x}^2$ , se  $\mathbf{f}(\mathbf{x}^1)$  domina  $\mathbf{f}(\mathbf{x}^2)$ . Nesta classe de otimização as soluções otimizadas, i.e., não dominadas por outras soluções, são alocadas em vetores objetivo diferentes.

O conjunto de soluções ótimas no espaço de decisão  $\mathbf{X}$  é em geral chamado de conjunto de Pareto  $\mathbf{X}^*$  contido no espaço  $\mathbf{X}$ . A sua imagem no espaço objetivo denota a Fronteira de Pareto  $\mathbf{Y}^* = \mathbf{f}(\mathbf{X}^*)$  contido no espaço  $\mathbf{Y}$ . Em muitos problemas de otimização multiobjetivo o conhecimento sobre o conjunto ajuda na escolha da solução mais conveniente. Existem muitas formas diferentes de trabalhar com um problema de otimização multiobjetivo. Uma forma é a agregação dos objetivos em um objetivo global. Na literatura existem muitos trabalhos que concentram esforços na construção de uma Fronteira de Pareto aproximada através da agregação dos múltiplos objetivos em uma função mono-objetivo como é feito em Bezerra et al. 2015.

Zitzler et al. 1999 descreve dois métodos para aproximar a Fronteira de Pareto: o método dos pesos e o método das restrições. Cabe mencionar que estes métodos são independentes do processo de otimização escolhido para resolver o problema.

No método dos pesos o problema de otimização multiobjetivo é convertido em um problema de otimização mono-objetivo formando uma combinação linear dos objetivos. Na função objetivo são somados os objetivos multiplicados cada um por um fator de ponderação ou peso ( $y = f(\mathbf{x}) = \omega_1 * f_1(\mathbf{x}) + \omega_2 * f_2(\mathbf{x}) + \dots + \omega_k * f_k(\mathbf{x})$ ). Se os pesos são normalizados então a soma dos pesos é igual a 1 e o processo varia sistematicamente os pesos para obter soluções otimizadas que formam a Fronteira de Pareto aproximada. A maior desvantagem desta técnica é que não é possível gerar todas as soluções pertencentes a Fronteira de Pareto devido a discretização do passo para variação dos pesos.

O método das restrições não tende a ter problemas com porções convexas da Fronteira de Pareto e o método transforma  $k - 1$  dos  $k$  objetivos em restrições. O objetivo que não é transformado em restrição é deixado como objetivo único da função objetivo e pode ser escolhido arbitrariamente. Depois são definidos limites inferiores nos parâmetros das restrições e são progressivamente variados pelo processo de otimização para obter várias soluções na Fronteira de Pareto. Este método é capaz de obter soluções nas partes não convexas da curva. Para cada combinação nos parâmetros das restrições uma solução é obtida e várias soluções são utilizadas para a formação da Fronteira de Pareto.

Uma desvantagem é identificada no método das restrições: se os limites não são escolhidos apropriadamente a zona factível obtida poderia não ter soluções e ficar vazia. É importante utilizar qualquer informação disponível para escolher estes limites ou escolher previamente uma gama adequada de valores com antecipação.

Zitzler et al. (2004) também ressalta a preferência para utilizar Algoritmos Evolutivos Multi-Objetivo (AEMO) para a construção da Fronteira de Pareto. Gerar a Fronteira de Pareto pode gerar muito esforço computacional e utilizar métodos exatos não é aplicável. Outras estratégias estocásticas como os algoritmos evolutivos, *tabu search*, *simulated annealing* e colônia de formigas foram desenvolvidas porque são efetivas em encontrar uma resposta aproximada do ponto ótimo.

Devem ser discutidos três aspectos importantes presentes nos algoritmos evolutivos: atribuição de qualidade, preservação de diversidade e elitismo.

Na otimização mono-objetivo a função de qualidade e a função objetivo são frequentemente idênticas. Mas na otimização multiobjetivo, ambas devem permitir a participação de vários objetivos no problema de otimização. Em geral pode-se abordar o problema com estratégias baseadas em critérios, baseadas em agregação ou baseadas na Fronteira de Pareto.

Uma abordagem consiste em agregar os objetivos em uma função objetivo parametrizada. Os parâmetros desta função são variados sistematicamente no processo de otimização de forma a encontrar um conjunto de soluções não dominadas ou uma solução para cada combinação de parâmetros avaliada. Em alguns AEMOs é utilizada uma função objetivo com soma de critérios ponderados, onde estes pesos de ponderação são variados no processo.

Outro aspecto a discutir é a preservação de diversidade. Muitos AEMOs tentam manter a diversidade no conjunto de aproximação de Pareto incorporando a informação de densidade no processo de seleção: um indivíduo tem poucas probabilidades de ser selecionado se a densidade dos vizinhos é alta. Os AEMOs podem utilizar muitas técnicas para medir a “distância” entre os pontos e desta forma ter uma medida da diversidade nas populações.

O elitismo aborda o problema de eliminar boas soluções no processo de otimização devido a efeitos aleatórios. Uma forma de lidar com o problema é combinando a geração anterior com os descendentes ao invés de substituir toda a população com a geração nova. Outra estratégia é manter uma população extra como arquivo separado do processo de otimização. Esta é utilizada para armazenar indivíduos que podem ser úteis nas próximas gerações.

O critério da dominância é comumente utilizado. Se uma população no arquivo é utilizada pode ser que essa população seja um conjunto aproximado da Fronteira de Pareto se no processo as soluções não dominadas são priorizadas sobre as dominadas. O critério da dominância também pode não ser suficiente para a construção da Fronteira, por exemplo, num problema contínuo onde existem infinitas soluções. O critério de dominância deve ser complementado com informação para reduzir o número de soluções armazenadas; essas informações podem ser sobre a densidade ou o tempo transcorrido desde que o membro entrou no arquivo.

Bezerra et al. (2015) propõem um algoritmo multiobjetivo baseado na metaheurística enxame de partículas (MOSP) que utiliza o método dos pesos para o posicionamento de chaves considerando dois pesos sendo inerente ao custo das chaves e a confiabilidade do sistema. O algoritmo MOSP obtém como resultado a configuração de chaves que minimiza o número de Clientes Não Supridos (CNS). É determinado o número máximo de chaves a ser alocado e a codificação é um vetor binário de dimensão igual ao número de chaves a ser alocado. Na última etapa do problema, na classificação, a Fronteira de Pareto é determinada. Cada solução ao final de cada iteração é armazenada em *gbest* se na comparação com a incumbente resulta ser melhor. Ao final cada configuração armazenada no conjunto de *gbest* deve ser classificada como dominada ou não-dominada. Depois o subconjunto das soluções não-dominadas forma a base para a Fronteira de Pareto.

### 3 METODOLOGIA PARA ALOCAÇÃO OTIMIZADA DE INDICADORES DE FALTA EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

#### 3.1 FORMULAÇÃO DO PROBLEMA

Para resolver o problema de alocação de IFs em redes de distribuição é necessário estabelecer um critério de avaliação da qualidade das soluções obtidas. Neste trabalho é formulada uma função objetivo que considera os dois custos conflitantes, ou seja, o custo da energia não suprida (CENS) e o custo de investimento em sensores IFs (CINV). A função objetivo é formulada conforme a equação (11).

$$\text{Min } F_0 = \omega_1 * \text{CENS} + \omega_2 * \text{CINV} \quad (11)$$

Sujeito a:

$$N < N_{\text{max}} \quad (12)$$

$$\omega_1 + \omega_2 = 1 \quad (13)$$

$$\omega_1 \text{ e } \omega_2 \geq 0 \quad (14)$$

Sendo:

$\omega_1, \omega_2$ : os pesos para dar maior importância ao CENS ou ao CINV, respectivamente;

$N$ : Número de sensores a serem instalados no sistema;

$N_{\text{max}}$ : Número máximo de sensores a serem instalados no sistema.

O primeiro termo da função objetivo dada em (11) pode ser modelado a través de (15):

$$\text{CENS} = C_e * \sum_{z=1}^{nz} \sum_{j \in NL_z} L_i * \left( \sum_{j \in NS_z} \lambda_j * t_j^m \right) \quad (15)$$

Sendo:

$\text{CENS}$ : Custo da Energia Não Suprida anual (R\$/ano);

$C_e$ : Custo da energia (R\$/Kwh);

$nz$ : Número de zonas do sistema;

$NL_z$ : Conjunto de cargas dentro da zona  $z$ ;

$NS_z$ : Conjunto de seções/ramos dentro da zona  $z$ ;

$L_i$ : Potência da barra  $i$  (kW);

$\lambda_j$ : Taxa de falha da seção/ramo  $j$  (falhas/ano);

$t_j^m$ : Tempo total de restabelecimento do serviço na seção  $j$  com sensor ( $m=1$ ), ou sem sensor ( $m=0$ ) em horas. Leva em consideração o tempo total para localização e reparo da falta com e sem sensor alocado.

Deve-se comentar que a taxa de falha da seção/ramo é calculada multiplicando o comprimento de cada ramo com uma taxa de faltas global do sistema,  $\lambda$ , que é expressada em (faltas/anos-km). Tipicamente a obtenção da taxa de faltas global não é fácil; para calcular a taxa é necessário ter um registro do histórico das faltas ocorridas no sistema nos últimos anos. É provável que muitos sistemas não tenham um registro das faltas e esta taxa deve ser estimada para o processo de alocação de IFs.

Para calcular o CENS para cada configuração é necessário calcular o  $t_j^m$  para cada barra em cada configuração. O tempo de restabelecimento do serviço é a soma de três tempos diferentes e são relacionados na seguinte expressão:

$$t_j^m = t_j^{local} + t_j^{reparo} + t_j^{desloca} \quad (16)$$

Sendo:

$t_j^{local}$ : O tempo de localização da falta considerando o sensor IF alocado ( $m=1$ ) ou sem sensor IF alocado ( $m=0$ ). Este é o tempo com o valor que varia se o ramo respectivo tem IF alocado ou não.

$t_j^{reparo}$ : O tempo médio de reparo do defeito gasto pelas equipes de manutenção.

$t_j^{desloca}$ : O tempo que as equipes de manutenção demoram em deslocar-se até o local da falta.

Para o terceiro tempo ( $t_j^{desloca}$ ) deve-se calcular para cada barra o comprimento total de linha desde a subestação (supondo que o ponto de partida das equipes é a subestação) até a barra  $j$  e conhecer a velocidade média de deslocamento das equipes de manutenção. A expressão para o cálculo deste tempo é:

$$t_j^{desloca} = \frac{l_{SE-j}}{V_{equipes}} \quad (17)$$



Sendo:

$l_{SE-j}$ : a distância total desde a subestação até a barra  $j$ .

$V_{equipes}$ : a velocidade média das equipes de manutenção.

O segundo termo da equação (11) é definido em (Raison, Rognon, 2005) como:

$$CINV = N * \left[ \left\{ \frac{(CFI + CIFI)}{IDFI} \right\} + CMFI \right] \quad (18)$$

Sendo:

CINV: Custo do investimento total anual com a instalação dos sensores no sistema (R\$/ano);

CFI: Preço de compra de cada sensor (R\$);

CIFI: Custo de instalação do sensor (R\$);

IDFI: Tempo de vida útil média do sensor (anos); e


CMFI: Custo de manutenção do sensor (R\$/ano).

Em (11) tem-se o critério para avaliar as configurações candidatas considerando os dois custos conflitantes (CENS e CINV). Variando os valores de  $\omega_1$  e  $\omega_2$ , sendo a soma dos dois igual a 1, pode-se dar preferência a um dos objetivos sobre o outro. Quando se tem que  $\omega_1 > \omega_2$ , a tendência é priorizar configurações candidatas que tenham melhores valores de CENS; ou valores menores de CENS. E quando  $\omega_1 < \omega_2$ , a tendência é priorizar configurações com menores valores no CINV. É evidente, conforme exposto anteriormente, que com um maior valor de  $\omega_2$  a tendência é alocar uma menor quantidade de sensores no sistema, e com um menor valor a tendência é alocar maior quantidade de IFs. Portanto, a escolha dos valores de  $\omega_1$  e  $\omega_2$  reflete a prioridade ou o interesse da concessionária na solução do problema.

### 3.1.1 Exemplo de Cálculo do CENS

Para ilustrar o cálculo do CENS, tem-se na Figura 4 um sistema modelo de 6 barras com 4 IFs alocados numa configuração exemplo.

Figura 4 – Sistema de distribuição com 4 sensores IFs alocados.



Fonte: Próprio autor.

Com a alocação de sensores IF nesta configuração em particular pode-se identificar 4 zonas: a zona Z1 delimitada entre os sensores IF1 e IF2; a zona Z2 entre IF2 e IF3; a zona Z3 entre IF3 e IF4, e a zona Z4 após o IF4. Observa-se que as zonas são criadas a partir da alocação dos sensores e são delimitadas entre sensores adjacentes. Assim, se ocorre uma falta em uma destas zonas o sensor a montante desta zona deve enviar um sinal de atuação devido à falta ao centro de operação de distribuição.

Deve-se observar que na zona 3 há dois ramos (das barras 4 e 5) e somente um sensor alocado. Isto dificulta indicar com precisão em qual ramo 3-4 ou 4-5 está a falta. Logo, se a falta é no ramo 3-4 a equipe deve levar um tempo  $t_3^1$  que leva em conta a presença do sensor. Caso a falta seja no ramo 4-5, e por este não possuir sensor, deve levar um tempo  $t_4^0$ . Deve-se notar que  $t_3^1 < t_4^0$ .

Para continuar com o exemplo, os ramos em cada zona são definidos com os seguintes dados:  $n_z=4$ ,  $NL_1=\{1\}$ ,  $NL_2=\{2\}$ ,  $NL_3=\{3,4\}$ ,  $NL_4=\{5\}$ ,  $NS_1=\{1\}$ ,  $NS_2=\{2\}$ ,  $NS_3=\{3,4\}$  e  $NS_4=\{5\}$ . A partir das definições dos conjuntos, formula-se a equação para o cálculo do CENS do sistema modelo a partir de (15), como:

$$CENS = C_e * \sum_{z=1}^{n_z} \sum_{i \in NL_z} L_i * (\sum_{j \in NS_z} \lambda_j * t_j^m)$$

$$CENS = C_e * [\sum_{i \in NL_1} L_i * (\sum_{j \in NS_1} \lambda_j * t_j^m) + \sum_{i \in NL_2} L_i * (\sum_{j \in NS_2} \lambda_j * t_j^m) + \sum_{i \in NL_3} L_i * (\sum_{j \in NS_3} \lambda_j * t_j^m) + \sum_{i \in NL_4} L_i * (\sum_{j \in NS_4} \lambda_j * t_j^m)]$$

$$\text{CENS} = C_e * [L_1 \lambda_1 t_1^1 + L_2 \lambda_2 t_2^1 + (L_3 + L_4) * (\lambda_3 t_3^1 + \lambda_4 t_4^0) + L_5 \lambda_5 t_5^1] \quad (19)$$

É importante mencionar que (19) é a expressão do cálculo do CENS para a configuração particular da Figura 4. Para outras configurações a ser avaliadas o zoneamento do sistema é diferente e, portanto, o cálculo do CENS é diferente.

### 3.2 ALGORITMO GENÉTICO ADAPTATIVO APLICADO AO PROBLEMA

A técnica de solução a ser empregada neste trabalho é o Algoritmo Genético Adaptativo (AGA) baseado em (LEÃO; PEREIRA; MANTOVANI, 2014). O algoritmo tem taxas de recombinação e mutação que são dinamicamente calibradas em cada geração baseadas na diversidade da população dessa geração. Para este processo o cálculo das taxas (Diversidade, recombinação e mutação) foram baseadas no trabalho de (LEÃO; PEREIRA; MANTOVANI, 2014). A taxa de diversidade na geração  $q$  é calculada conforme (20):

$$\text{Div}_{(q)} = \left[ 1 - \frac{C_{eq}}{np} \right] * 100 \quad (20)$$

Sendo:

$\text{Div}_{(q)}$ : Taxa de diversificação calculada (percentual);

$q$ : Contador do número de gerações do AGA;

$C_{eq}$ : Número máximo calculado de configurações iguais;

$np$ : Número total de indivíduos na população.

Depois de calcular a taxa de diversidade devem-se calcular as taxas de recombinação e de mutação conforme as equações (21) e (22) respectivamente.

$$tr_{(q)} = \frac{\text{Div}_{(q)}}{100} * e^{\left(\frac{\text{Div}_{(q)}}{100} - 1\right)} \quad (21)$$

$$tm_{(q)} = \left(\frac{\text{Div}_{(q)}}{100} - 1\right) * e^{-\left(\frac{\text{Div}_{(q)}}{100}\right)} \quad (22)$$


Sendo:

$tr_{(q)}$ : Taxa de recombinação variável;

$tm_{(q)}$ : Taxa de mutação variável.

Na resolução do problema com o AGA é necessário escolher uma codificação. O cromossomo do algoritmo representa um indivíduo na população que é uma solução possível do problema. Então a codificação das configurações é representada por um vetor de tamanho igual ao número de barras no sistema, e cada gene corresponde a um bit que indica a ausência, ou alocação, de um IF na barra (0 ou 1, respectivamente). A codificação empregada neste trabalho é representada na Figura 5 e é ilustrado a solução de alocação mostrada na Figura 4.

Figura 5 – Codificação para o AGA par ao sistema da figura 4.

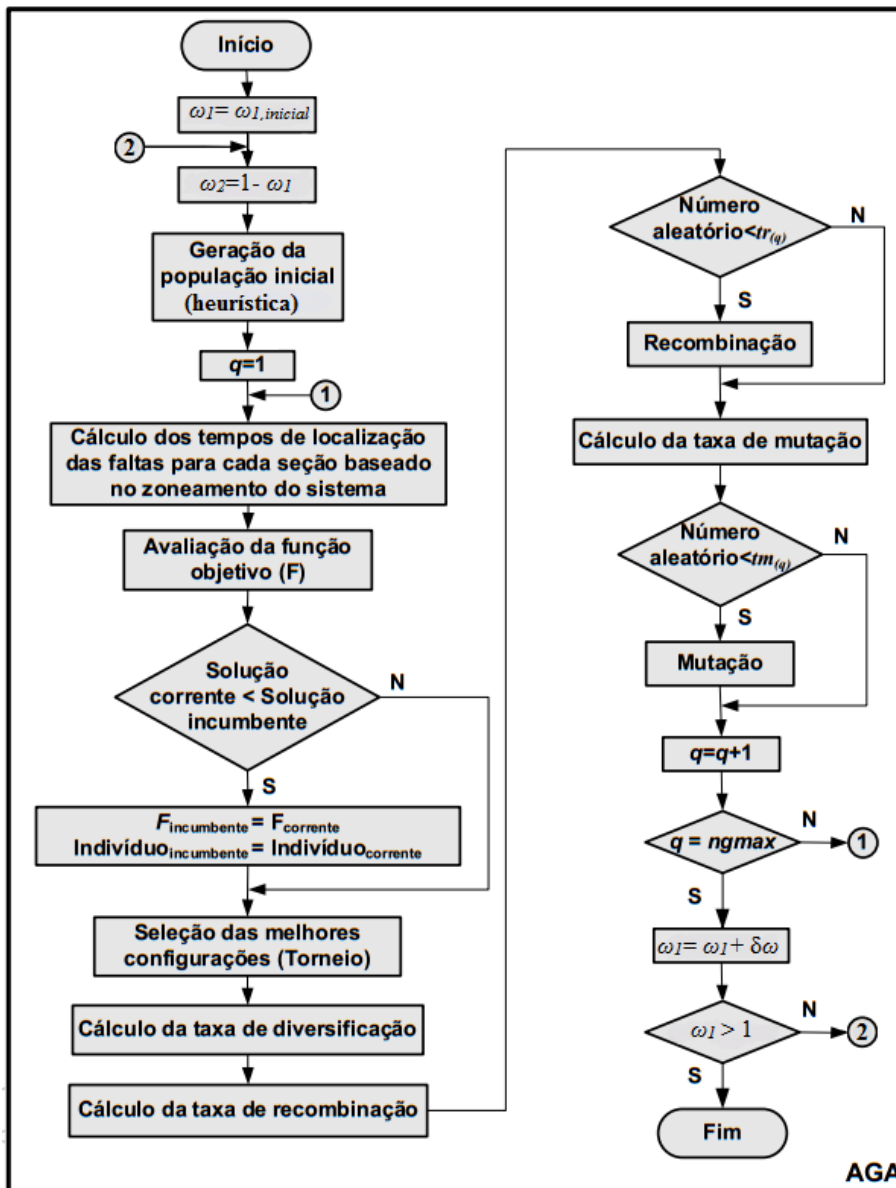


Fonte: Próprio autor.

Para cada indivíduo é necessário calcular os tempos de localização da falta e o valor do CENS. Depois, com o valor do CINV e do CENS para cada configuração, pode-se obter o valor da função objetivo. A Figura 6 ilustra o diagrama de blocos do AGA implementado neste trabalho. Na Figura 6  $ngmax$  é o número máximo de gerações do AGA que é definido como critério de parada.

Para resolver o problema multiobjetivo foi escolhido o método dos pesos como foi exposto em Zitzler et al. (2004). Para gerar um conjunto de soluções em uma Fronteira de Pareto aproximada, os pesos  $\omega_1$  e  $\omega_2$  são variados em passos desde 0 até 1, sujeito as restrições (13) e (14). A primeira solução otimizada é determinada quando  $\omega_{1, inicial}=0$  e, portanto,  $\omega_2 = 1$  calculado a partir de (13).

Figura 6 – Diagrama de blocos para o AGA multiobjetivo.



Fonte: Adaptado de (LEÃO; PEREIRA; MANTOVANI, 2014) .

O AGA determina a melhor solução para a função objetivo para cada um dos valores dos pesos, sendo os pesos modificados através de um passo  $\delta\omega$ . Os pesos são modificados somando o passo  $\delta\omega$  em cada iteração até que  $\omega_1$  atinja o valor de 1. Desta forma tem-se que  $\omega_1$  e  $\omega_2$  são complementares e  $\omega_2$  é calculado conforme a restrição (13). Com as soluções obtidas no processo a Fronteira de Pareto aproximada, ou otimizada, pode ser obtida.

Com os pesos  $\omega_1$  e  $\omega_2$  determinados, o primeiro passo do algoritmo é gerar a população inicial. Uma estratégia muito utilizada é gerar a população inicial de forma completamente

aleatória. Isto implicaria para cada indivíduo da população e para cada barra gerar aleatoriamente um 0 ou um 1. A grande vantagem desta estratégia é garantir uma boa diversidade no começo do algoritmo. Por outro lado, se há informações úteis sobre o sistema, e os custos envolvidos na alocação dos sensores, é possível formular uma heurística eficiente para gerar a população inicial que possua soluções de boa qualidade e assim melhorar a convergência do algoritmo.

A partir da realização de diversos testes foi notado que alguns dados do sistema e alguns custos relacionados aos IFs são importantes para determinar a quantidade de barras com IFs que é razoável considerar como um ponto de partida para a alocação otimizada dos sensores. A equação (23) descreve a quantidade inicial de barras para alocar IFs.

$$\text{Barras}_{IF} = \frac{(L_T * l_T * \lambda * C_e) * C_{IF}}{C_{INV}_{IF}} \quad (23)$$

Sendo:

$\text{Barras}_{IF}$ : O número de barras onde alocar IFs em cada configuração da primeira população (barras);

$L_T$ : A carga total do sistema (kW);

$l_T$ : O comprimento total de linhas/ramos do sistema (km);

$\lambda$ : A taxa de falhas média global do sistema (falhas/ano-km);

$C_{IF}$ : Uma constante para definir o valor de  $\text{Barras}_{IF}$  apropriado para cada sistema (barras-h/falha); e


$C_{INV}_{IF}$ : O custo de investimento para cada IF a instalar (R\$/ano).

Primeiro, deve-se determinar o valor de  $C_{IF}$  a ser utilizado em (23). O cálculo é feito depois de resolver os três sistemas gerando a primeira população de forma completamente aleatória. É observado que as soluções considerando a população inicial aleatória para os sistemas de 19, de 34 e de 134 barras é alocar IFs em 3, 7 e 2 barras respectivamente. Se são usados estes números em (23) pode ser obtido que um bom valor para  $C_{IF}$  é 0,1, o qual é o valor utilizado neste trabalho

O  $CINV_{IF}$  é obtido dividindo o  $CINV$  em (18) pelo o número de IFs a instalar  $N$ . Desta forma  $CINV_{IF}$  é constante e depende dos custos envolvidos na alocação de cada sensor.

Por exemplo, para o sistema de 19 barras que será utilizado neste trabalho como um dos sistemas teste, o valor calculado de  $Barras_{IF}$  é igual a 3.16. Isso significa que cada configuração da população inicial terá um total de 3 IFs alocados. Uma possível configuração é mostrada na Figura 7 com um total de 3 IFs alocados. Na Figura 7 pode-se observar que os IFs foram alocados aleatoriamente nos ramos 2, 7 e 19.

Figura 7 – Codificação exemplo da população inicial para o sistema de 19 barras.



Fonte: O próprio autor .

Para cada indivíduo da população inicial é calculado o tempo de restabelecimento do serviço expresso em (16) baseado no zoneamento do sistema. Com os tempos é avaliado o CENS utilizando (15) para cada configuração da população. O  $CINV$  é calculado com (18) e com os dois custos, é calculado o valor da função objetivo para cada configuração da população.

Em cada geração é escolhida a melhor solução da população e é comparada com a incumbente (na primeira geração a melhor configuração da população é a primeira incumbente). Se é encontrada uma solução melhor que a incumbente então esta solução é a nova solução incumbente.

A seleção dos melhores indivíduos é feita por meio da seleção por torneio que mostrou ser efetiva na resolução do problema e é descrita em Romero e Lavorato (2012). Na seleção por torneio são eleitos  $np$  configurações de  $np$  jogos, onde  $np$  também é o tamanho da população.

A partir das configurações selecionadas para gerar a próxima população deve-se calcular a taxa de diversidade da população corrente como é apresentado em (20). Com esta taxa deve-se calcular as taxas de recombinação e mutação conforme as equações (21) e (22), respetivamente. Após o cálculo de cada taxa deve-se aplicar os operadores de recombinação e

mutação. A variação das taxas destes operadores é o ponto chave do processo de evolução do AGA pois as taxas são calculadas em função da diversidade da população corrente. Para aplicar o operador de recombinação um número aleatório entre 0 e 1 é gerado para cada par de configurações selecionadas no torneio. Isto é feito para todos os pares. Se o número é menor que a taxa de recombinação, então a recombinação é feita. Se o número é maior que a taxa, a recombinação não é feita, e o par de configurações simplesmente formam parte da seguinte geração. No processo de mutação um número entre 0 e 1 deve ser gerado aleatoriamente para cada bit de cada configuração da nova população. Se o número é menor do que a taxa de mutação, então a mutação é feita (o bit é mudado de 0 para 1 ou de 1 para 0, conforme o caso). Se o número é maior que a taxa de mutação então, a mutação não é feita.

Com os processos de recombinação e de mutação completos tem-se a população da geração seguinte. Se o número da geração corrente ainda é menor que  $ngmax$  o algoritmo deve realizar uma nova iteração até atingir o  $ngmax$ , sendo o número máximo de gerações o critério de parada do algoritmo para este problema.



## 4 TESTES E RESULTADOS

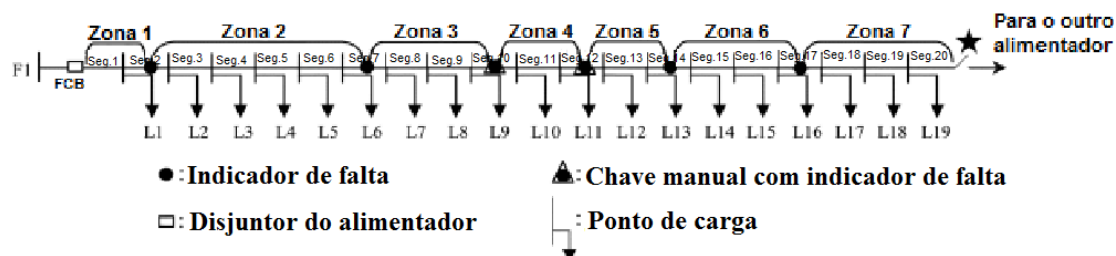
Neste capítulo são expostos os resultados do trabalho. Na seção 4.1 são apresentados os três sistemas de distribuição utilizados para os testes. Na seção 4.2 são apresentados os resultados onde o primeiro teste foi determinar a melhor solução para cada sistema utilizando o AGA quando  $\omega_1$  e  $\omega_2$  são fixos em 0,5 cada um. Nesta etapa os resultados do AGA são comparados com um AG clássico. Na seção 4.3 são obtidas as Fronteiras de Pareto aproximadas para cada sistema teste através da variação dos pesos da função objetivo.

### 4.1 SISTEMAS TESTES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Para os testes neste trabalho foram utilizados três sistemas de distribuição. Os sistemas são de 19, 34 e de 134 barras, obtidos de Ho et al. (2011), IEEE PES (2010) e Silva et al. (2005) respectivamente (informações no Anexo A). Destes sistemas foram consideradas informações do alimentador como as cargas em cada barra, os comprimentos dos ramos, as taxas de falhas médias por ano (falhas/ano-km), os tempos médios de localização e de reparo das falhas e o número de fases de cada ramo.

O primeiro sistema teste tem 19 barras, um comprimento de ramos total de 19 km e uma carga instalada total de 4.615 kW, e é mostrado na Figura 8. Para este sistema teste os dados dos comprimentos dos ramos não são fornecidos; e, portanto, foram considerados iguais a 1km neste trabalho.

Figura 8 – Sistema de distribuição de 19 barras.



Fonte: (HO; LEE; LIN, 2011) .

Os dados das cargas são extraídos de Ho et al. (2011) e os seguintes dados são ainda adotados: taxa média de falhas: 0,149 falhas/ano-km; tempo médio de reparo: 60 min; tempo de localização da falta sem IF: 20 min; tempo de localização da falta com IF: 5 min.

Adicionalmente a velocidade média de deslocamento das equipes de manutenção para zonas urbanas é de 25 km/h, obtida de Muniz et al. 2009.

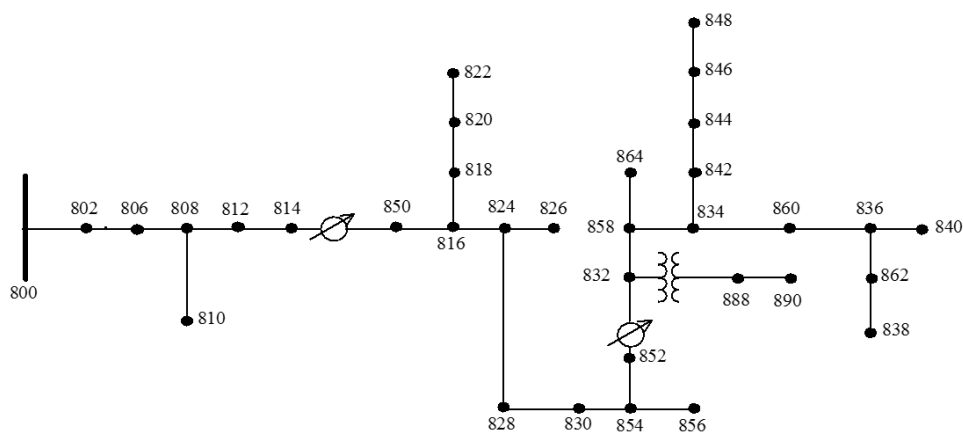
Para a solução deste sistema consideram-se as seguintes informações dos IFs remotos a alocar: preço de compra de cada sensor em três fases: \$960,00; custo de instalação do sensor: 5% do preço de compra do sensor (\$) de Usida et al. (2012); custo de manutenção do sensor: 5% do preço de compra do sensor (\$) de Usida et al. (2012); tempo de vida útil média do sensor (anos): 10 anos (Bjerkman, Nortroll, 2009). Além disso, o custo da energia utilizada foi de 0.4535 R\$/KWh. As quantidades cotizadas em dólares (\$) devem ser convertidas para reais (R\$). A taxa de cambio utilizada neste trabalho é de 3.78 R\$/

O segundo sistema teste de 34 barras ilustrado na Figura 9, foi obtido de IEEE PES (2010) com uma carga total instalada de 1.769 kW e 93,914 km.

As informações como as cargas nas barras e os comprimentos das linhas são extraídas de IEEE PES (2010) e são apresentadas no Anexo A.

Para outras informações como a taxa média de falhas por ano-km, os tempos médios de reparo e de localização de faltas foram consideradas iguais às fornecidas para o sistema de 19 barras assim como os custos de investimento dos sensores indicadores de faltas.

Figura 9 – Sistema de distribuição de 34 barras.

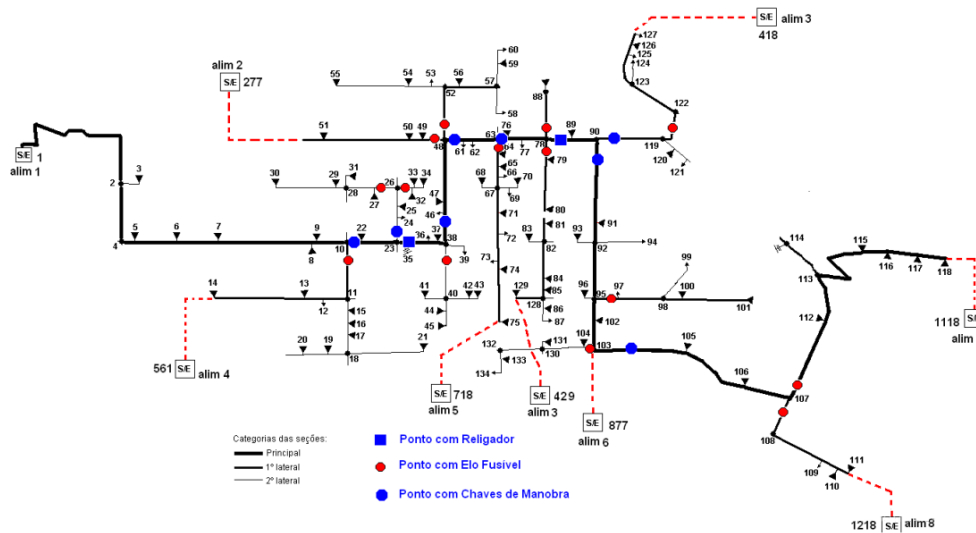


Fonte: IEEE PES (2010).

O terceiro sistema teste considerado neste trabalho é o sistema de 134 barras obtido de (DA SILVA; MANTOVANI, 2005) onde foi escolhida a configuração 1 para a distribuição das chaves de manobras. O sistema, representado na Figura 10, tem uma carga total instalada de 6.427 kW e 8,89 km.

Para outras informações como a taxa média de falhas por ano-km, os tempos médios de reparo e de localização de faltas também foram consideradas iguais as fornecidas pelo sistema de 19 barras assim como os custos de investimento dos sensores indicadores de faltas.

Figura 10 – Sistema de distribuição e 134 barras.



Fonte: (DA SILVA; MANTOVANI, 2005) .

#### 4.2 SIMULAÇÕES CONSIDERNADO PESOS $\omega_1 = \omega_2 = 0,5$

Para obtenção de resultados de qualidade é necessário calibrar os parâmetros das técnicas de solução aqui empregadas para resolver o problema considerando cada um dos sistemas testes. Para o AGA é necessário calibrar o tamanho da população e o número máximo de gerações. Foram realizadas 100 execuções do AGA e os parâmetros foram calibrados de modo que o algoritmo obtivesse a menor solução para todas as execuções. Estes resultados são mostrados na Tabela 1.

Além desses dados os valores de  $\omega_1$  e  $\omega_2$  foram fixados em 0,5 de modo a priorizar igualmente cada um dos custos conflitantes. Com o algoritmo calibrado com os valores da Tabela 1 e permitindo que o método ficasse livre para alocar uma quantidade de IFs em um número de barras máxima igual ao número total de barras do sistema o AGA encontrou a solução mínima para cada um dos sistemas teste.

**Tabela 1 – Melhores parâmetros de simulação para o AGA**

<b>Sistema</b>	19 barras	34 barras	134 barras
<b>np</b>	50	100	200
<b>ngmax</b>	20	50	100

Fonte: Próprio autor.

Na Tabela 2 são mostrados os principais resultados obtidos para cada sistema: o número de IFs; a quantidade de pontos de instalação; e a configuração obtida. Também mostra os valores da função objetivo (F.O.), o custo da energia não suprida (CENS), o custo de investimento (CINV) e o tempo médio de execução para 100 execuções. Deve-se mencionar que a medida do tempo é utilizada como referência da eficiência do AGA (para comparação com a AG). Isto porque para resolver o problema de alocação de IFs em sistemas de distribuição o tempo não é variável determinante e tão pouco limitante pois trata-se de um problema mais fortemente relacionado a área de planejamento do que da operação de sistemas de distribuição de energia elétrica. Para a realização dos testes foi usado um Notebook Dell® com processador Intel® Core i5 1,7 GHz com 4 GB de memória RAM sendo o algoritmo programado em linguagem C++.

**Tabela 2 – Melhores respostas das simulações do AGA.**

<b>Sistema</b>	19 barras	34 barras	134 barras
<b>Quantidade de IFs</b>	9	15	6
<b>Quantidade de barras</b>	3	7	2
<b>Alocação nas Barras</b>	6, 10, 13	11, 12, 14, 16, 23, 24, 32	37, 89
<b>F.O. (R\$/ano)</b>	1882,83	2469,10	1355,31
<b>CENS (R\$/ano)</b>	2078,23	2125,87	1585,69
<b>CINV (R\$/ano)</b>	1687,39	2812,32	1124,93
<b>Tempo médio de execução (s)</b>	0,023	0,166	4,003

Fonte: Próprio autor.

Pode-se observar nos resultados que nos sistemas de 19 e de 134 barras há 9 IFs em 3 barras e 6 IFs em 2 barras respectivamente; isto é devido à essas alocações serem feitas em ramos trifásicos do sistema. Mas no sistema de 34 barras os resultados mostram 15 IFs em 7 barras e isto é devido as barras 11, 12 e 14 pertencerem a ramais monofásicos enquanto as barras 16, 23, 24 e 32 a ramais trifásicos. Então o total de IFs nas 7 barras é 15.

O desempenho do AGA é comparado a de um AG clássico considerando os mesmos testes. Para os testes o AG é executado 100 vezes e são calibrados os valores do tamanho da população, número máximo de gerações, taxas de recombinação ( $tr$ ) e mutação ( $tm$ ) de modo que o algoritmo encontre as melhores soluções para todos os sistemas testes (Tabela 3).

Na Tabela 4 são mostrados os resultados da melhor resposta encontrada e o tempo médio de execução para o AG.

**Tabela 3 – Melhores parâmetros de simulação para o AG.**

<b>Sistema</b>	19 barras	34 barras	134 barras
<b><math>t_r</math></b>	0,4	0,4	0,3
<b><math>t_m</math></b>	0,05	0,03	0,01
<b>np</b>	80	120	280
<b>ngmax</b>	30	60	140

Fonte: Próprio autor.

**Tabela 4 – Melhores respostas das simulações do AG**

<b>Sistema</b>	19 barras	34 barras	134 barras
<b>Quantidade de IFs</b>	9	15	6
<b>Quantidade de barras</b>	3	7	2
<b>Alocação nas Barras</b>	6, 10, 13	11, 12, 14, 16, 23, 24, 32	37, 89
<b>F.O. (R\$/ano)</b>	1882,83	2469,10	1355,31
<b>CENS (R\$/ano)</b>	2078,23	2125,87	1585,69
<b>CINV (R\$/ano)</b>	1687,39	2812,32	1124,93
<b>Tempo médio de execução (s)</b>	0,045	0,241	7,987

Fonte: Próprio autor.

Pode-se observar nos resultados obtidos para cada sistema utilizando o AG que as configurações correspondem às encontradas pelo AGA, mas os tempos de execução são maiores. Para convergir para as mesmas respostas os valores para o tamanho da população e o número máximo de gerações do AG são maiores. Como resultado os tempos de execução são também maiores. Para analisar ainda mais a comparação do desempenho entre o AGA e o AG os tempos mínimo, médio e máximo das simulações são mostrados na Tabela 5. Pode-se observar nas Tabelas 3 e 4 que para o sistema de 134 barras o AG possui maior tempo computacional de execução comparado com o AGA devido aos valores de  $np$  e  $ngmax$  necessitarem ser maiores; portanto, os tempos de execução também são maiores.


**Tabela 5 – Tempos computacionais de convergência para o AGA e o AG.**

<b>Sistema</b>	19 barras	34 barras	134 barras
<b>AGA (s)</b>			
<b>t<sub>min</sub></b>	0,012	0,156	3,969
<b>t<sub>médio</sub></b>	0,023	0,166	4,003
<b>t<sub>max</sub></b>	0,040	0,203	4,233
<b>AG (s)</b>			
<b>t<sub>min</sub></b>	0,043	0,221	7,795
<b>t<sub>médio</sub></b>	0,045	0,241	7,987
<b>t<sub>max</sub></b>	0,048	0,285	8,621

Fonte: Próprio autor.

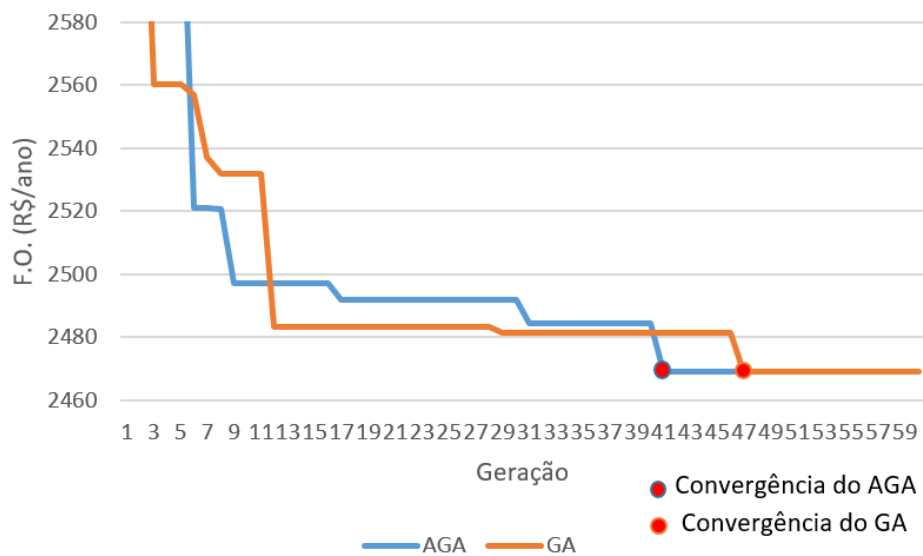
Nas Figuras 11, 12 e 13 são ilustrados os gráficos referentes a uma das simulações realizadas indicando o comportamento do valor da função objetivo incumbente em relação as gerações de cada algoritmo para cada sistema, respectivamente. É destacado em cada gráfico o ponto de convergência para a solução mínima obtidas pelo AGA e AG, respectivamente.

Figura 11 – Evolução do AGA e o AG para o sistema de 19 barras.



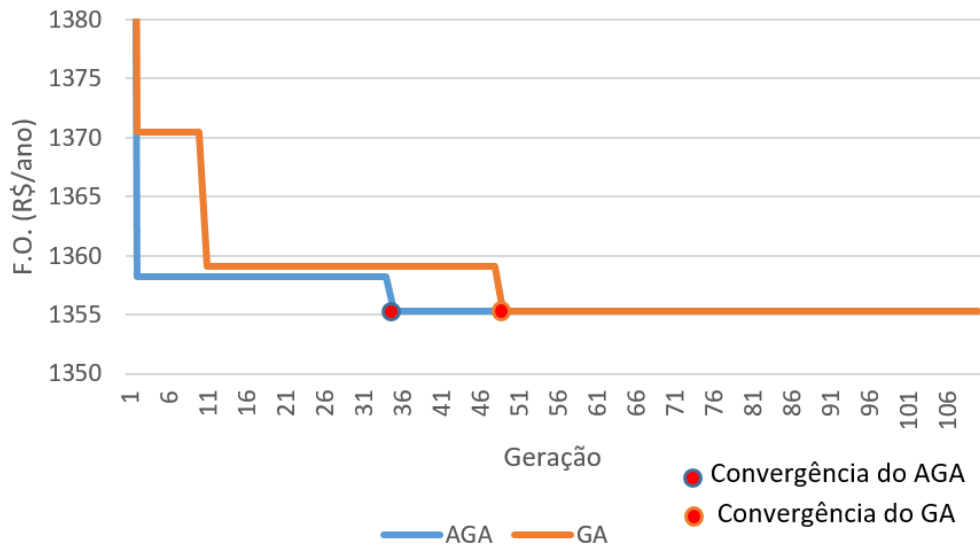
Fonte: Elaboração do próprio autor.

Figura 12 – Evolução do AGA e o AG para o sistema de 34 barras.



Fonte: Elaboração do próprio autor.

Figura 13 – Evolução do AGA e o AG para o sistema de 134 barras.




Fonte: Elaboração do próprio autor.

Pode ser observado em algumas partes dos gráficos das Figuras 11 e 12 que o AG tem melhores valores da função objetivo incumbente que o AGA entretanto o AGA tende a convergir em um número menor de gerações.

Nas Figuras 14, 15 e 16 são ilustradas as evoluções das taxas de diversidade, recombinação e mutação do AGA para cada sistema teste para uma das simulações realizadas.


Figura 14 – Evolução da diversidade, recombinação e mutação para o sistema de 19 barras.



Fonte: Elaboração do próprio autor.




Figura 15 – Evolução da diversidade, recombinação e mutação para o sistema de 34 barras.



Fonte: Elaboração do próprio autor.

Figura 16 – Evolução da diversidade, recombinação e mutação para o sistema de 134 barras.



Fonte: Elaboração do próprio autor.

#### 4.3 RESULTADOS PARA A ANÁLISE MULTIOBJETIVO DO PROBLEMA DE ALOCAÇÃO DE IFs EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Até agora, somente foram realizados testes utilizando para  $\omega_1$  e  $\omega_2$  o valor de 0,5 considerando que tanto o CENS como o CINV têm a mesma prioridade para classificar as configurações candidatas. Nesta seção os pesos  $\omega_1$  e  $\omega_2$  são variados de forma iterativa e para

cada par de valores o AGA encontra a melhor solução. As melhores soluções para todos os pesos constituem a Fronteira de Pareto aproximada para o problema. A partir da Fronteira de Pareto aproximada a concessionária de energia poderá escolher a solução que melhor satisfaz seus interesses priorizando o CENS e/ou o CINV.

Conforme anteriormente apresentado, os valores dos pesos modificados devem obedecer às restrições (13) e (14). A partir destas restrições os pesos podem assumir valores nos intervalos  $0 \leq \omega_1 \leq 1$  e  $0 \leq \omega_2 \leq 1$ .

Para a obtenção de uma gama de soluções e assim traçar a Fronteira de Pareto aproximada, o valor de  $\omega_1$  foi variado no intervalo de 0 até 1 em passos discretos. Observa-se que se o passo é grande, então são obtidas poucas soluções, o que pode não representar adequadamente o espaço de busca do problema. Por outro lado, se o passo é muito pequeno, a discretização é maior, resultando em muitas soluções. Neste trabalho o passo  $\delta\omega$  empregado é de 0,01. Portanto, os valores de  $\omega_1$  e  $\omega_2$  podem assumir valores entre 0 e 1 em passos de 0,01 o que representa 101 soluções para compor a Fronteira de Pareto.

Pode-se observar na Tabela 6 para o sistema de 19 barras o valor da função objetivo mínima, e os valores das parcelas CENS e CINV para cada valor dos pesos. Nesta tabela é destacada a solução obtida com ponderações iguais que é a solução com melhor compromisso simultâneo para os custos conflitantes, ou seja, a solução cujo ponto localiza-se mais próximo dos eixos CENS e CINV simultaneamente (“joelho” da curva da Fronteira de Pareto aproximada).

**Tabela 6 – Resultados para a Fronteira de Pareto do sistema de 19 barras.**

$w_1$	$w_2$	IFs	barras	F.O. (R\$/ano)	CENS (R\$/ano)	CINV (R\$/ano)	Tempo (s)
0	1	0	0	0	10193,2	0	0,025
0,01	0,99	0	0	101,932	10193,2	0	0,021
0,02	0,98	0	0	203,864	10193,2	0	0,023
0,03	0,97	0	0	305,795	10193,2	0	0,022
0,04	0,96	0	0	407,727	10193,2	0	0,021
0,05	0,95	0	0	509,659	10193,2	0	0,022
0,06	0,94	0	0	611,591	10193,2	0	0,022
0,07	0,93	0	0	713,522	10193,2	0	0,022
0,08	0,92	0	0	815,454	10193,2	0	0,023
0,09	0,91	0	0	917,386	10193,2	0	0,022

0,1	0,9	3	1	1005,34	4991,19	562,464	0,023
0,11	0,89	3	1	1049,62	4991,19	562,464	0,023
0,12	0,88	3	1	1093,91	4991,19	562,464	0,023
0,13	0,87	3	1	1138,2	4991,19	562,464	0,022
0,14	0,86	3	1	1182,49	4991,19	562,464	0,022
0,15	0,85	3	1	1226,77	4991,19	562,464	0,021
0,16	0,84	3	1	1271,06	4991,19	562,464	0,022
0,17	0,83	3	1	1315,35	4991,19	562,464	0,022
0,18	0,82	3	1	1359,63	4991,19	562,464	0,022
0,19	0,81	3	1	1403,92	4991,19	562,464	0,022
0,2	0,80	3	1	1448,21	4991,19	562,464	0,025
0,21	0,79	6	2	1486,94	2848,8	1124,93	0,023
0,22	0,78	6	2	1504,18	2848,8	1124,93	0,021
0,23	0,77	6	2	1521,42	2848,8	1124,93	0,022
0,24	0,76	6	2	1565,68	2961,41	1124,93	0,022
0,25	0,75	6	2	1555,9	2848,8	1124,93	0,022
0,26	0,74	6	2	1573,13	2848,8	1124,93	0,013
0,27	0,73	6	2	1590,37	2848,8	1124,93	0,035
0,28	0,72	6	2	1607,61	2848,8	1124,93	0,03
0,29	0,71	6	2	1624,85	2848,8	1124,93	0,025
0,3	0,7	6	2	1642,09	2848,8	1124,93	0,023
0,31	0,69	6	2	1659,33	2848,8	1124,93	0,023
0,32	0,68	6	2	1676,57	2848,8	1124,93	0,023
0,33	0,67	6	2	1693,8	2848,8	1124,93	0,021
0,34	0,66	6	2	1711,04	2848,8	1124,93	0,021
0,35	0,65	6	2	1728,28	2848,8	1124,93	0,021
0,36	0,64	6	2	1745,52	2848,8	1124,93	0,021
0,37	0,63	6	2	1762,76	2848,8	1124,93	0,021
0,38	0,62	6	2	1780	2848,8	1124,93	0,023
0,39	0,61	6	2	1797,24	2848,8	1124,93	0,023
0,4	0,6	6	2	1814,48	2848,8	1124,93	0,023
0,41	0,59	6	2	1831,71	2848,8	1124,93	0,023
0,42	0,58	6	2	1848,95	2848,8	1124,93	0,022
0,43	0,57	9	3	1865,19	2100,87	1687,39	0,022
0,44	0,56	9	3	1859,38	2078,28	1687,39	0,023
0,45	0,55	9	3	1863,29	2078,28	1687,39	0,022
0,46	0,54	9	3	1867,2	2078,28	1687,39	0,023
0,47	0,53	9	3	1871,11	2078,28	1687,39	0,023
0,48	0,52	9	3	1875,02	2078,28	1687,39	0,024
0,49	0,51	9	3	1878,92	2078,28	1687,39	0,022
<b>0,5</b>	<b>0,5</b>	<b>9</b>	<b>3</b>	<b>1882,83</b>	<b>2078,28</b>	<b>1687,39</b>	<b>0,023</b>
0,51	0,49	9	3	1886,74	2078,28	1687,39	0,023
0,52	0,48	9	3	1890,65	2078,28	1687,39	0,023
0,53	0,47	9	3	1894,56	2078,28	1687,39	0,023
0,54	0,46	9	3	1898,47	2078,28	1687,39	0,022

0,55	0,45	9	3	1902,38	2078,28	1687,39	0,022
0,56	0,44	9	3	1906,29	2078,28	1687,39	0,022
0,57	0,43	12	4	1905,52	1645,76	2249,86	0,022
0,58	0,42	12	4	1899,48	1645,76	2249,86	0,021
0,59	0,41	12	4	1893,44	1645,76	2249,86	0,022
0,6	0,4	12	4	1887,4	1645,76	2249,86	0,021
0,61	0,39	12	4	1881,36	1645,76	2249,86	0,021
0,62	0,38	12	4	1875,31	1645,76	2249,86	0,022
0,63	0,37	12	4	1869,27	1645,76	2249,86	0,022
0,64	0,36	12	4	1863,23	1645,76	2249,86	0,022
0,65	0,35	12	4	1857,19	1645,76	2249,86	0,023
0,66	0,34	12	4	1851,15	1645,76	2249,86	0,022
0,67	0,33	12	4	1845,11	1645,76	2249,86	0,022
0,68	0,32	15	5	1835,78	1376,23	2812,32	0,023
0,69	0,31	15	5	1821,42	1376,23	2812,32	0,023
0,7	0,3	15	5	1807,06	1376,23	2812,32	0,022
0,71	0,29	18	6	1783	1132,83	3374,78	0,022
0,72	0,28	18	6	1761,8	1134,53	3374,78	0,022
0,73	0,27	18	6	1738,16	1132,83	3374,78	0,022
0,74	0,26	18	6	1715,74	1132,83	3374,78	0,023
0,75	0,25	18	6	1693,32	1132,83	3374,78	0,022
0,76	0,24	18	6	1670,9	1132,83	3374,78	0,023
0,77	0,23	18	6	1648,48	1132,83	3374,78	0,023
0,78	0,22	18	6	1626,06	1132,83	3374,78	0,022
0,79	0,21	18	6	1603,64	1132,83	3374,78	0,022
0,8	0,2	21	7	1578,31	988,575	3937,25	0,023
0,81	0,19	21	7	1548,82	988,575	3937,25	0,022
0,82	0,18	21	7	1519,34	988,575	3937,25	0,023
0,83	0,17	24	8	1484,78	867,269	4499,71	0,022
0,84	0,16	24	8	1446,17	864,544	4499,71	0,023
0,85	0,15	24	8	1409,82	864,544	4499,71	0,022
0,86	0,14	24	8	1373,47	864,544	4499,71	0,022
0,87	0,13	27	9	1336,95	780,301	5062,18	0,022
0,88	0,12	27	9	1294,13	780,301	5062,18	0,021
0,89	0,11	27	9	1251,31	780,301	5062,18	0,022
0,9	0,1	27	9	1208,49	780,301	5062,18	0,022
0,91	0,09	30	10	1162,71	721,419	5624,64	0,023
0,92	0,08	39	13	1102,42	562,458	7312,03	0,022
0,93	0,07	39	13	1034,93	562,458	7312,03	0,021
0,94	0,06	39	13	967,433	562,458	7312,03	0,023
0,95	0,05	39	13	899,937	562,458	7312,03	0,022
0,96	0,04	42	14	829,435	535,891	7874,5	0,022
0,97	0,03	51	17	749,165	476,607	9561,89	0,023
0,98	0,02	54	18	653,24	459,952	10124,4	0,023
0,99	0,01	54	18	556,596	459,952	10124,4	0,022


1	0	57	19	459,952	459,952	10686,8	0,021
---	---	----	----	---------	---------	---------	-------

Fonte: Elaboração do próprio autor.

Analisando a Tabela 6 vale notar que para valores pequenos de  $\omega_1$  correspondem valores grandes de  $\omega_2$ . Isso implica que a grande importância da função objetivo é concentrada no CINV e o método tende a alocar um menor número de IFs. O inverso ocorre com grandes valores para  $\omega_1$  onde a grande importância é concentrada no CENS. Nesta situação o método tende a alocar maior quantidade de IFs elevando o valor do CINV mas reduzindo o valor do CENS.


Para o mesmo sistema teste, na Figura 17 é ilustrada a Fronteira de Pareto aproximada que relaciona a variação do CENS com o valor correspondente de CINV. Pode ser observado que a relação entre os custos é inversa ou conflitante. Uma ampliação do joelho da curva da Fronteira de Pareto com os eixos em escala adequada é apresentado na Figura 18.

Figura 17 – Fronteira de Pareto para o sistema de 19 barras.



Fonte: Elaboração do próprio autor.


Figura 18 – Ampliação da Figura 17 para o sistema de 19 barras.



Fonte: Elaboração do próprio autor.


Similarmente para os sistemas de 34 barras e de 134 barras, são ilustradas nas Tabelas 10 e 11 os resultados para a construção das Fronteiras de Pareto (Apêndice A). Nas Figuras 19 e 20 são ilustrados os gráficos da Fronteira de Pareto aproximada para o sistema de 34 barras e nas Figuras 21 e 22 para o sistema de 134 barras.

Figura 19 – Fronteira de Pareto para o sistema de 34 barras.




Fonte: Elaboração do próprio autor.

Figura 20 – Ampliação da Figura 19 para o sistema de 34 barras.




Fonte: Elaboração do próprio autor.

Figura 21 – Fronteira de Pareto para o sistema de 134 barras.



Fonte: Elaboração do próprio autor.

Figura 22 – Ampliação da Figura 21 para o sistema de 134 barras.



Fonte: Elaboração do próprio autor.

É importante notar que nos três sistemas, nos casos em que  $\omega_1=0$ , onde toda a importância da função objetivo estava no CINV (F.O. = CINV), o algoritmo não alocou IFs na solução do problema. Gradualmente, quando o valor de  $\omega_1$  aumenta em passos  $\delta\omega=0,01$  o algoritmo tende a alocar mais IFs progressivamente. Ao final, quando  $\omega_1=1$  e  $\omega_2=0$ , significa que toda a importância do critério de avaliação é minimizar o CENS e o algoritmo aloca IFs em todas as barras do sistema não considerando o custo de investimento.



## 5 CONCLUSÕES E TRABALHOS FUTUROS

### 5.1 CONCLUSÕES

Pode-se concluir com os resultados obtidos que o AGA é um algoritmo adequado e eficiente para resolver o problema de alocação de sensores indicadores de faltas. Na primeira parte dos testes com o AGA pode ser observado que se os dois pesos da função objetivo são de igual valor, portanto permitindo que o CENS e o CINV tenham igual importância, as melhores soluções são aquelas que apresentam o menor custo total.

Na comparação do AGA com o AG, é concluído que o AGA necessita de menores valores no tamanho das populações e de gerações máximas para convergir para a melhor solução resultando em menores tempos computacionais de execução para convergir que o AG.

Na segunda parte dos testes os pesos são variados de forma iterativa no AGA com o objetivo de traçar a Fronteira de Pareto aproximada para o problema. Com valores altos do peso do CENS, é priorizado minimizar o custo da energia não-suprida, e o método tende a alocar maior número de IFs no sistema elevando o custo de investimento. Por outro lado, com valores altos do peso referente ao CINV, é priorizado minimizar o custo de investimento dos IFs, elevando o custo da energia não suprida.

Dependendo dos interesses da concessionária, e a partir da Fronteira de Pareto traçada, a concessionária pode escolher a(s) solução(ões) que melhor descreve(m) sua priorização de custos, buscando a minimização do CENS, ou a minimização do CINV em sensores.

## 5.2 TRABALHOS FUTUROS

Para avaliar o desempenho do AGA, pode ser interessante comparar o desempenho do AGA com o de outros métodos, como algoritmos de busca multiobjetivo como o NSGA-II ou uma ferramenta de otimização clássica existente no mercado.

Neste trabalho foram utilizados sistemas testes de 19, 34 e 134 barras. Seria interessante obter a solução de um sistema de grande porte para avaliar o desempenho do método proposto. O tempo de execução do método não tem uma relação linear com o tamanho do sistema, mas é necessário ter mais resultados considerando sistemas de maior porte para determinar essa relação.

A taxa de falha é calculada com base em dados históricos da concessionária cujo valor pode ser impreciso dependendo do método e da exatidão dos dados coletados pela operação do sistema. Portanto como trabalho futuro pode-se propor realizar uma análise de sensibilidade da formulação proposta em relação a taxa de falha do sistema

## REFERÊNCIAS

- ALMEIDA, M. C. de.; COSTA, F. F.; XAVIER-DE-SOUZA, S.; SANTANA, F. Optimal placement of faulted circuit indicators in power distribution systems. **Electric Power Systems Research**, Amsterdam, v. 81, n. 2, p. 699-706, 2011.
- BEZERRA, J.; CORDEIRO, G.; FURTADO, R. Multiobjective optimization algorithm for switch placement in radial power distribution networks. **IEEE Transactions on Power Systems**, Piscataway, v. 30, n. 2, p. 545-552, 2015.
- BJERKAN, E.; NORTROLL, A. Efficient fault management using remote fault indicators. In: INT. CONF. EXHIB. ELECTRICITY DISTRIBUTION-PART, 20. Prague. **Proceedings...** [S. l.: s. n.], 2009. p. 8-11.
- DA SILVA, W. L.; MANTOVANI, J. **Desenvolvimento de uma metodologia integrada para alocação otimizada de dispositivos de controle e proteção em sistemas de distribuição de energia elétrica.** [S. l.: s. n.], 2005.
- CAVENAGHI, R. M. F. **Estudo da localização de equipes de manutenção.** 2009. 121 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Produção) – Universidade de São Paulo, São Paulo, 2009.
- DE SOUZA, D.; DA SILVA, I.; ZIOLKOWSKI, V.; FLAUZINO, R. Efficient allocation of fault indicators in distribution circuits using fuzzy logic. In: IEEE POWER & ENERGY SOCIETY GENERAL MEETING, 2009, Calgary. **Proceedings...** Piscataway: IEEE, 2009. p. 1-6.
- HO, C.-Y.; LEE, T.-E.; LIN, C.-H. Optimal placement of fault indicators using the immune algorithm. **IEEE Transactions on Power Systems**, Piscataway, v. 26, n. 1, p. 38-45, Feb. 2011.
- IEEE. **PES: Power & Energy Society.** Piscataway, 2010. 34-bus feeder (XLS and DOC). Disponível em: <<http://ewh.ieee.org/soc/pes/dsacom/testfeeders/>>. Acesso em: 22 nov. 2016.
- LEÃO, F.; PEREIRA, R.; MANTOVANI, J. Fast fault section estimation in distribution control centers using adaptive genetic algorithm. **International Journal of Electrical Power & Energy Systems**, London, v. 63, p. 787–805, 2014.
- MICHALEWICZ, Z. **Genetic algorithm + data structures = evolution programs.** 3. ed. New York: Springer-Verlag, 1996. 387 p.
- RAISON, B.; ROGNON, J.-P.; BONNIOT, S.; MANJAL, B. Optimization of fault indicators placement with dispersed generation insertion. In: IEEE POWER ENGINEERING SOCIETY GENERAL MEETING, 2005, San Francisco CA. **Proceedings...** Piscataway, 2005. p. 1530-1537.

SAL, R. F. G.; ALMEIDA, M. C. Estratégias para a alocação otimizada de indicadores de falta em redes de distribuição de energia. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA – CB, 2014, Belo Horizonte. **Proceedings...** [S. l.: s. n.], 2014. p. 3580-3587.

USIDA, W.; COURY, D. Efficient placement of fault indicators in an actual distribution system using evolutionary computing. **IEEE Transactions on Power Systems**, Piscataway, v. 27, n. 4, p. 1841-1849, 2012.

USIDA, W.; COURY, D.; FLAUZINO, R.; SILVA, I. N. Alocação eficiente indicadores de faltas em um sistema de distribuição real usando computação evolutiva. **Sba: Controle & Automação**, Heidelberg, v. 23, n. 3, p. 306-302, 2012.

USIDA, W.; COURY, D. V.; FLOUZINO, R.; SILVA, I. N. Alocação de dispositivos indicadores de faltas em alimentadores primários usando algoritmos genéticos. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA, 2010, São Paulo, São Paulo. **Anais...** Curitiba: UFPR, 2010. p. 1244-1251.

ZITZLER, E.; LAUMANN, M.; BLEULER, S. A tutorial on evolutionary multiobjective optimization. **Metaheuristics for Multiobjective Optimization**, v. 535, p. 3-37, 2004.

ZITZLER, E. **Evolutionary Algorithms for multiobjective optimization**: methods and applications. 1999. 132 f. Tese (Doutorado) - Instituto Federal Suíço de Tecnologia de Zurique, Zurique, 1999.

## APÊNDICE A – Dados de entrada dos sistemas testes

Neste anexo são apresentados os dados de entrada dos três sistemas testes.

**Tabela 7 – Dados de entrada do sistema teste de 19 barras.**

<b>Barra Final</b>	<b>Barra Inicial</b>	<b>Carga (kW)</b>	<b>Comprimento (m)</b>	<b>Quantidade de fases</b>
1	SE	70	1000	3
2	1	143	1000	3
3	2	168	1000	3
4	3	113	1000	3
5	4	100	1000	3
6	5	265	1000	3
7	6	251	1000	3
8	7	331	1000	3
9	8	188	1000	3
10	9	1205	1000	3
11	10	210	1000	3
12	11	989	1000	3
13	12	43	1000	3
14	13	96	1000	3
15	14	129	1000	3
16	15	44	1000	3
17	16	80	1000	3
18	17	75	1000	3
19	18	115	1000	3

Fonte: Elaboração do próprio autor.

**Tabela 8 – Dados de entrada do sistema teste de 34 barras**

<b>Barra Final</b>	<b>Barra Inicial</b>	<b>Carga (kW)</b>	<b>Comprimento (m)</b>	<b>Quantidade de fases</b>
1	SE	0	0	3
2	1	0	786	3
3	2	55	527	3
4	3	0	9.823	3
5	4	16	1.769	1
6	4	0	11.430	3
7	6	0	9.061	3
8	7	0	3	3
9	8	0	94	3
10	9	0	521	1
11	10	34	14.676	1
12	11	135	4.188	1
13	9	5	3.112	3
14	13	40	923	1
15	13	4	256	3
16	15	52	6.230	3
17	16	0	158	3
18	17	0	11.225	3
19	17	4	7.111	1
20	18	0	3	3
21	20	15	1.493	3
22	20	0	0	3
23	22	450	3.218	3
24	21	32	1.777	3
25	21	2	493	1
26	24	206	615	3
27	26	82	816	3
28	27	67	262	3
29	27	0	85	3
30	29	28	1.481	1
31	24	0	85	3
32	3	414	411	3
33	32	45	1.109	3
34	33	23	161	3

Fonte: Elaboração do próprio autor.

Tabela 9 – Dados de entrada do sistema teste de 134 barras

Barra Final	Barra Inicial	Carga (kW)	Comprimento (m)	Quantidade de fases
1	SE	0	0	3
2	1	0	900	3
3	2	41,4	50	3
4	2	0	100	3
5	4	69	40	3
6	5	69	20	3
7	6	103,5	20	3
8	7	69	20	3
9	8	69	10	3
10	9	0	50	3
11	10	0	100	3
12	11	7,91	60	3
13	12	69	30	3
14	13	69	160	3
15	11	103,5	30	3
16	15	41,4	10	3
17	16	103,5	20	3
18	17	0	40	3
19	18	69	40	3
20	19	103,5	50	3
21	18	103,5	150	3
22	10	103,5	30	3
23	22	0	70	3
24	23	2,76	50	3
25	24	41,4	20	3
26	25	0	30	3
27	26	103,5	120	3
28	27	0	20	3
29	28	69	20	3
30	29	103,5	5	3
31	28	103,5	25	3
32	26	103,5	60	3
33	32	103,5	40	3
34	33	103,5	20	3
35	23	0	10	3
36	35	11,41	70	3
37	36	103,5	10	3
38	37	0	10	3
39	38	2	70	3
40	38	0	100	3
41	40	69	60	3
42	40	69	50	3
43	42	69	10	3

44	40	103,5	30	3
45	44	41,4	40	3
46	38	0,92	660	3
47	46	103,5	20	3
48	47	0	120	3
49	48	103,5	50	3
50	49	69	20	3
51	50	103,5	171	3
52	48	0	100	3
53	52	1,1	60	3
54	53	103,5	30	3
55	54	69	130	3
56	52	69	20	3
57	56	0	80	3
58	57	9,2	50	3
59	57	103,5	60	3
60	59	3,5	20	3
61	48	2,76	40	3
62	61	5,06	10	3
63	62	0	50	3
64	63	69	30	3
65	64	69	20	3
66	65	3,22	30	3
67	66	0	20	3
68	67	103,5	30	3
69	67	6,44	20	3
70	69	103,5	20	3
71	67	69	50	3
72	71	7,82	40	3
73	72	1,75	40	3
74	73	103,5	20	3
75	74	103,5	110	3
76	63	103,5	20	3
77	76	5,43	30	3
78	77	0	50	3
79	78	69	70	3
80	79	103,5	70	3
81	80	103,5	30	3
82	81	0	30	3
83	82	69	50	3
84	82	69	50	3
85	84	103,5	30	3
86	128	103,5	30	3



87	86	69	20	3
88	78	69	5	3
89	78	41,4	0130	3
90	89	0	50	3
91	90	103,5	180	3
92	91	0	20	3
93	92	21,62	30	3
94	92	69	70	3
95	92	0	100	3
96	95	5,52	40	3
97	95	21	50	3
98	97	0	60	3
99	98	69	110	3
100	98	103,5	40	3
101	100	103,5	110	3
102	95	69	60	3
103	102	0	40	3
104	103	69	30	3
105	103	69	150	3
106	105	99	210	3
107	106	0	30	3
108	107	0	100	3
109	108	103,5	100	3
110	109	103,5	30	3
111	110	69	20	3
112	107	27,6	170	3
113	112	0	110	3
114	113	0	110	3
115	113	27,6	300	3
116	115	27,6	200	3
117	116	27,6	200	3
118	117	27,6	200	3
119	90	0	110	3
120	119	50,6	70	3
121	120	27,6	70	3
122	119	0	70	3
123	122	0	130	3
124	123	14,26	20	3
125	123	41,4	20	3
126	125	14,26	40	3
127	126	14,26	40	3
128	85	0	20	3
129	128	41,4	60	3

130	104	0	70	3
131	130	103,5	20	3
132	130	0	100	3
133	132	103,5	40	3
134	133	103,5	40	3

Fonte: Elaboração do próprio autor.

## APÊNDICE B – Resultados para a Fronteira de Pareto aproximada

Neste apêndice são apresentados os resultados da construção da fronteira de Pareto aproximada para os sistemas testes de 34 e de 134 barras, respectivamente.

**Tabela 10 – Resultados para a Fronteira de Pareto do sistema de 34 barras.**

w1	w2	IFs	barras	F.O. (R\$/ano)	CENS (R\$/ano)	CINV (R\$/ano)	Tempo (s)
0	1	0	0	0	31228,1	0	0,57
0,01	0,99	0	0	312,281	31228,1	0	0,588
0,02	0,98	0	0	624,562	31228,1	0	0,56
0,03	0,97	3	1	823,784	9273,14	562,464	0,576
0,04	0,96	3	1	910,891	9273,14	562,464	0,562
0,05	0,95	3	1	997,998	9273,14	562,464	0,564
0,06	0,94	3	1	1085,1	9273,14	562,464	0,561
0,07	0,93	4	2	1159,92	6606,59	749,952	0,567
0,08	0,92	4	2	1218,48	6606,59	749,952	0,561
0,09	0,91	4	2	1277,05	6606,59	749,952	0,558
0,1	0,9	4	2	1335,62	6606,59	749,952	0,561
0,11	0,89	4	2	1394,18	6606,59	749,952	0,563
0,12	0,88	4	2	1452,75	6606,59	749,952	0,569
0,13	0,87	4	2	1511,32	6606,59	749,952	0,561
0,14	0,86	4	2	1569,88	6606,59	749,952	0,562
0,15	0,85	4	2	1628,45	6606,59	749,952	0,558
0,16	0,84	4	2	1687,01	6606,59	749,952	0,567
0,17	0,83	4	2	1745,58	6606,59	749,952	0,561
0,18	0,82	4	2	1804,15	6606,59	749,952	0,375
0,19	0,81	4	2	1862,71	6606,59	749,952	0,566
0,2	0,80	4	2	1921,28	6606,59	749,952	0,6
0,21	0,79	4	2	1979,85	6606,59	749,952	0,571
0,22	0,78	4	2	2038,41	6606,59	749,952	0,558
0,23	0,77	7	3	2087,53	4682,46	1312,42	0,563
0,24	0,76	7	3	2121,23	4682,46	1312,42	0,565
0,25	0,75	7	3	2154,93	4682,46	1312,42	0,571
0,26	0,74	7	3	2188,63	4682,46	1312,42	0,567
0,27	0,73	7	3	2222,33	4682,46	1312,42	0,565
0,28	0,72	7	3	2256,03	4682,46	1312,42	0,57
0,29	0,71	8	4	2287,72	4216,52	1499,9	0,682
0,3	0,7	9	5	2314,23	3776,84	1687,39	0,562
0,31	0,69	9	5	2335,12	3776,84	1687,39	0,558
0,32	0,68	9	5	2356,01	3776,84	1687,39	0,576

0,33	0,67	9	5	2376,91	3776,84	1687,39	0,54
0,34	0,66	9	5	2397,8	3776,84	1687,39	0,451
0,35	0,65	10	6	2415,51	3419,54	1874,88	0,566
0,36	0,64	10	6	2430,96	3419,54	1874,88	0,586
0,37	0,63	10	6	2446,4	3419,54	1874,88	0,601
0,38	0,62	10	6	2461,85	3419,54	1874,88	0,588
0,39	0,61	12	6	2452,78	2770,18	2249,86	0,463
0,4	0,6	12	6	2457,99	2770,18	2249,86	0,65
0,41	0,59	12	6	2463,19	2770,18	2249,86	0,375
0,42	0,58	12	6	2468,39	2770,18	2249,86	0,357
0,43	0,57	12	6	2473,59	2770,18	2249,86	0,488
0,4	0,56	12	6	2478,8	2770,18	2249,86	0,59
0,5	0,55	13	7	2480,33	2532,88	2437,34	0,428
0,46	0,54	13	7	2481,29	2532,88	2437,34	0,581
0,47	0,53	13	7	2482,24	2532,88	2437,34	0,576
0,48	0,52	15	7	2482,82	2125,87	2812,32	0,567
0,49	0,51	15	7	2475,96	2125,87	2812,32	0,566
<b>0,5</b>	<b>0,5</b>	<b>15</b>	<b>7</b>	<b>2469,1</b>	<b>2125,87</b>	<b>2812,32</b>	<b>0,568</b>
0,51	0,49	15	7	2462,23	2125,87	2812,32	0,566
0,52	0,48	15	7	2455,37	2125,87	2812,32	0,566
0,53	0,47	16	8	2447,77	1958,23	2999,81	0,569
0,54	0,46	16	8	2437,36	1958,23	2999,81	0,541
0,55	0,45	16	8	2426,94	1958,23	2999,81	0,436
0,56	0,44	16	8	2416,52	1958,23	2999,81	0,6
0,57	0,43	16	8	2406,11	1958,23	2999,81	0,566
0,58	0,42	16	8	2395,69	1958,23	2999,81	0,597
0,59	0,41	16	8	2385,28	1958,23	2999,81	0,565
0,6	0,4	17	9	2372,15	1828,72	3187,3	0,575
0,61	0,39	17	9	2358,57	1828,72	3187,3	0,565
0,62	0,38	17	9	2344,98	1828,72	3187,3	0,558
0,63	0,37	19	9	2325,01	1598,36	3562,27	0,588
0,64	0,36	19	9	2305,37	1598,36	3562,27	0,574
0,65	0,35	19	9	2285,73	1598,36	3562,27	0,562
0,66	0,34	19	9	2266,09	1598,36	3562,27	0,564
0,67	0,33	19	9	2246,45	1598,36	3562,27	0,567
0,68	0,32	20	10	2224,32	1506,47	3749,76	0,56
0,69	0,31	20	10	2195,83	1497,69	3749,76	0,561
0,7	0,3	20	10	2173,31	1497,69	3749,76	0,568
0,71	0,29	24	12	2146,36	1185,14	4499,71	0,585
0,72	0,28	24	12	2113,22	1185,14	4499,71	0,588
0,73	0,27	24	12	2080,07	1185,14	4499,71	0,568
0,74	0,26	24	12	2046,93	1185,14	4499,71	0,562
0,75	0,25	24	12	2013,78	1185,14	4499,71	0,565
0,76	0,24	24	12	1980,63	1185,14	4499,71	0,563
0,77	0,23	24	12	1947,49	1185,14	4499,71	0,564

0,78	0,22	24	12	1914,34	1185,14	4499,71	0,561
0,79	0,21	24	12	1881,2	1185,14	4499,71	0,586
0,8	0,2	24	12	1848,05	1185,14	4499,71	0,565
0,81	0,19	27	13	1810,94	1048,3	5062,18	0,565
0,82	0,18	27	13	1770,8	1048,3	5062,18	0,561
0,83	0,17	29	13	1702,57	937,658	5437,15	0,564
0,84	0,16	29	13	1657,58	937,658	5437,15	0,567
0,85	0,15	29	13	1612,58	937,658	5437,15	0,569
0,86	0,14	29	13	1567,59	937,658	5437,15	0,572
0,87	0,13	29	13	1522,59	937,658	5437,15	0,571
0,88	0,12	32	14	1473,29	856,069	5999,62	0,566
0,89	0,11	32	14	1421,86	856,069	5999,62	0,564
0,9	0,1	32	14	1370,42	856,069	5999,62	0,56
0,91	0,09	32	14	1318,99	856,069	5999,62	0,575
0,92	0,08	32	14	1267,55	856,069	5999,62	0,571
0,93	0,07	32	14	1216,12	856,069	5999,62	0,568
0,94	0,06	32	14	1164,68	856,069	5999,62	0,592
0,95	0,05	36	16	1109,02	812,148	6749,57	0,57
0,96	0,04	36	16	1049,65	812,148	6749,57	0,572
0,97	0,03	42	18	982,967	769,827	7874,5	0,571
0,98	0,02	42	18	911,921	769,827	7874,5	0,587
0,99	0,01	46	20	838,358	759,711	8624,45	0,567
1	0	86	34	750,528	750,528	16124	0,569

Fonte: Elaboração do próprio autor.

**Tabela 11 – Resultados para a Fronteira de Pareto do sistema de 134 barras.**

w1	w2	IFs	barras	F.O.	CENS	CINV	tempo
0	1	0	0	0	4961,59	0	6,212
0,01	0,99	0	0	49,616	4961,59	0	6,063
0,02	0,98	0	0	99,2319	4961,59	0	6,104
0,03	0,97	0	0	148,848	4961,59	0	6,045
0,04	0,96	0	0	198,464	4961,59	0	6,087
0,05	0,95	0	0	248,08	4961,59	0	6,01
0,06	0,94	0	0	297,696	4961,59	0	6,064
0,07	0,93	0	0	347,311	4961,59	0	6,064
0,08	0,92	0	0	396,927	4961,59	0	6,064
0,09	0,91	0	0	446,543	4961,59	0	6,106
0,1	0,9	0	0	496,159	4961,59	0	6,069
0,11	0,89	0	0	545,775	4961,59	0	6,046
0,12	0,88	0	0	595,391	4961,59	0	6,085
0,13	0,87	0	0	645,007	4961,59	0	6,125
0,14	0,86	0	0	694,623	4961,59	0	6,116
0,15	0,85	0	0	744,239	4961,59	0	6,041

0,16	0,84	0	0	793,855	4961,59	0	6,041
0,17	0,83	0	0	843,471	4961,59	0	6,083
0,18	0,82	0	0	893,086	4961,59	0	6,073
0,19	0,81	3	1	923,316	2461,68	562,464	6,055
0,2	0,80	3	1	942,308	2461,68	562,464	6,038
0,21	0,79	3	1	961,3	2461,68	562,464	6,111
0,22	0,78	3	1	980,293	2461,68	562,464	6,07
0,23	0,77	3	1	999,285	2461,68	562,464	6,019
0,24	0,76	3	1	1018,28	2461,68	562,464	6,067
0,25	0,75	3	1	1037,27	2461,68	562,464	6,062
0,26	0,74	3	1	1056,26	2461,68	562,464	6,069
0,27	0,73	3	1	1075,25	2461,68	562,464	6,126
0,28	0,72	3	1	1094,25	2461,68	562,464	6,049
0,29	0,71	3	1	1113,24	2461,68	562,464	6,033
0,3	0,7	3	1	1132,23	2461,68	562,464	6,042
0,31	0,69	3	1	1151,22	2461,68	562,464	6,095
0,32	0,68	3	1	1170,21	2461,68	562,464	6,061
0,33	0,67	3	1	1189,21	2461,68	562,464	6,017
0,34	0,66	3	1	1208,2	2461,68	562,464	6,125
0,35	0,65	3	1	1227,19	2461,68	562,464	6,07
0,36	0,64	3	1	1246,18	2461,68	562,464	6,021
0,37	0,63	3	1	1265,18	2461,68	562,464	6,045
0,38	0,62	3	1	1284,17	2461,68	562,464	6,082
0,39	0,61	3	1	1303,16	2461,68	562,464	6,282
0,4	0,6	6	2	1309,23	1585,69	1124,93	6,088
0,41	0,59	6	2	1313,84	1585,69	1124,93	6,101
0,42	0,58	6	2	1318,45	1585,69	1124,93	6,078
0,43	0,57	6	2	1323,06	1585,69	1124,93	6,085
0,44	0,56	6	2	1327,66	1585,69	1124,93	6,114
0,45	0,55	6	2	1332,27	1585,69	1124,93	6,088
0,46	0,54	6	2	1336,88	1585,69	1124,93	6,179
0,47	0,53	6	2	1341,49	1585,69	1124,93	6,144
0,48	0,52	6	2	1346,09	1585,69	1124,93	6,033
0,49	0,51	6	2	1350,7	1585,69	1124,93	6,079
<b>0,5</b>	<b>0,5</b>	<b>6</b>	<b>2</b>	<b>1355,31</b>	<b>1585,69</b>	<b>1124,93</b>	<b>6,079</b>
0,51	0,49	6	2	1359,92	1585,69	1124,93	6,102
0,52	0,48	6	2	1364,52	1585,69	1124,93	6,072
0,53	0,47	6	2	1369,13	1585,69	1124,93	6,047
0,54	0,46	6	2	1373,74	1585,69	1124,93	6,097
0,55	0,45	6	2	1378,35	1585,69	1124,93	6,014
0,56	0,44	6	2	1382,95	1585,69	1124,93	6,013
0,57	0,43	6	2	1387,56	1585,69	1124,93	6,099
0,58	0,42	6	2	1392,17	1585,69	1124,93	6,076
0,59	0,41	6	2	1396,78	1585,69	1124,93	6,08
0,6	0,4	6	2	1401,38	1585,69	1124,93	6,06

0,61	0,39	9	3	1401,41	1218,57	1687,39	6,208
0,62	0,38	9	3	1396,72	1218,57	1687,39	6,118
0,63	0,37	9	3	1391,68	1218,01	1687,39	6,079
0,64	0,36	9	3	1386,99	1218,01	1687,39	6,138
0,65	0,35	9	3	1382,3	1218,01	1687,39	6,055
0,66	0,34	9	3	1377,6	1218,01	1687,39	6,132
0,67	0,33	9	3	1372,91	1218,01	1687,39	6,204
0,68	0,32	9	3	1368,21	1218,01	1687,39	6,261
0,69	0,31	9	3	1363,52	1218,01	1687,39	6,127
0,7	0,3	12	4	1348,39	962,046	2249,86	6,103
0,71	0,29	12	4	1335,51	962,046	2249,86	6,05
0,72	0,28	12	4	1312,2	947,555	2249,86	6,091
0,73	0,27	12	4	1297,56	945,336	2249,86	6,021
0,74	0,26	12	4	1284,51	945,336	2249,86	6,112
0,75	0,25	12	4	1271,47	945,336	2249,86	6,046
0,76	0,24	12	4	1258,42	945,336	2249,86	6,269
0,77	0,23	12	4	1245,38	945,336	2249,86	6,099
0,78	0,22	15	5	1225,91	778,462	2812,32	6,123
0,79	0,21	15	5	1203,01	775,222	2812,32	6,137
0,8	0,2	15	5	1182,64	775,222	2812,32	6,117
0,81	0,19	15	5	1162,27	775,222	2812,32	6,088
0,82	0,18	15	5	1141,9	775,222	2812,32	6,121
0,83	0,17	15	5	1121,53	775,222	2812,32	6,081
0,84	0,16	15	5	1101,16	775,222	2812,32	6,031
0,85	0,15	21	7	1070,97	565,156	3937,25	6
0,86	0,14	21	7	1037,25	565,156	3937,25	6,198
0,87	0,13	21	7	1003,53	565,156	3937,25	6,097
0,88	0,12	21	7	969,807	565,156	3937,25	6,089
0,89	0,11	21	7	934,495	563,368	3937,25	6,109
0,9	0,1	24	8	898,196	498,028	4499,71	6,017
0,91	0,09	24	8	858,179	498,028	4499,71	5,986
0,92	0,08	30	10	802,612	383,305	5624,64	6,04
0,93	0,07	30	10	747,983	380,923	5624,64	6,081
0,94	0,06	30	10	695,53	380,906	5624,64	6,171
0,95	0,05	36	12	638,854	317,238	6749,57	6,693
0,96	0,04	39	13	567,158	286,122	7312,03	6,272
0,97	0,03	45	15	492,597	246,895	8436,96	6,184
0,98	0,02	51	17	405,474	218,608	9561,89	6,116
0,99	0,01	81	27	280,554	129,989	15186,5	6,227
1	0	402	134	25,8454	25,8461	75370,2	6,747

Fonte: Elaboração do próprio autor.