

**LUCAS FERNANDES CAMILO SIMONE**

**RECONFIGURAÇÃO DE REDES  
PARA RESTABELECIMENTO DE  
ENERGIA EM UM SISTEMA DE  
DISTRIBUIÇÃO REAL**

São Carlos

2012



**LUCAS FERNANDES CAMILO SIMONE**

**RECONFIGURAÇÃO DE REDES  
PARA RESTABELECIMENTO DE  
ENERGIA EM UM SISTEMA DE  
DISTRIBUIÇÃO REAL**

ORIENTADOR: Prof. Dr. João Bosco A. London Júnior

Trabalho de Conclusão de Curso apresentado  
à Escola de Engenharia de São Carlos da  
Universidade de São Paulo

Curso de Engenharia Elétrica com Ênfase em  
Sistemas de Energia e Automação

São Carlos

2012

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Simone, Lucas Fernandes Camilo

S598r Reconfiguração de redes para restabelecimento de energia em um sistema de distribuição real / Lucas Fernandes Camilo Simone ; orientador João Bosco Augusto London Junior. - São Carlos, 2012.

Monografia (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e automação) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2012.

1. Algoritmos evolutivos multi-objetivo. 2. Representação nó-profundidade. 3. Restabelecimento de energia. 4. Sistema de distribuição de grande porte. II. Título.

# FOLHA DE APROVAÇÃO

Nome: Lucas Fernandes Camilo Simone

Título: “Reconfiguração de Redes para Restabelecimento de Energia em Sistemas de Distribuição”

*Trabalho de Conclusão de Curso defendido e aprovado  
em 28 / 11 / 2012,*

*com NOTA 9,3 (nove, três), pela Comissão Julgadora:*

*Prof. Associado João Bosco Augusto London Jr. (Orientador)  
SEL/EESC/USP*

*Prof. Dr. José Carlos de Melo Vieira Júnior  
SEL/EESC/USP*

*Eng. M.Sc. Alexandre Vieira de Oliveira  
CPFL*

Coordenador da CoC-Engenharia Elétrica - EESC/USP:  
Prof. Associado Homero Schiabel



## Agradecimentos

Primeiramente, agradeço ao Deus Criador e Sustentador de todas as coisas, pois, tamanha é a complexidade das coisas que Ele criou, que nem todos meus esforços são suficientes para começar a entender a natureza e a beleza do universo, mas ainda assim Ele me alcança dia após dia com sua graça e seu favor.

Agradeço também aos meus pais Luis Fernando e Déborah, ao meu irmão Rafael e aos meus avós Orlando e Marlene, que durante estes 5 anos de graduação me forneceram todo apoio e encorajamento necessário para continuar. Obrigado pela paciência e consolo.

À minha namorada Bruna, que a cada dia ocupa um lugar mais especial e único na minha vida. Obrigado por cada momento junto e por todo carinho e compreensão durante o desenvolvimento deste trabalho.

Aos amigos, Gustavo, Jonatas, Josué, Luciano, Rubens, Ariela, Tatiane (tem mais gente), que foram uma verdadeira família durante estes anos de graduação. Obrigado pelas incontáveis horas de conversa, vocês fizeram toda diferença.

Aos amigos da Aliança Bíblica Universitária – ABU – que me ajudaram a enxergar que há coisas muito mais importantes e profundas na vida do que ser, simplesmente, formado e bem-sucedido. Obrigado por compartilharem momentos únicos de estudo da Bíblia, vocês me fizeram descobrir uma nova vocação!

Aos amigos de curso pelas horas de estudo, reclamações e risadas juntos. Obrigado por me ajudarem a me formar. Édson, valeu pelas anotações e resoluções de todas as listas de exercício, nossa turma deve muito a você!

Aos colegas da CPFL, especialmente, Alexandre, João Paulo, Donato e Ricardo, aprendi muito com vocês durante estes meses de estágio. Obrigado por não entregar tudo pronto e me fazer quebrar a cabeça.

Aos professores e funcionários da Escola de Engenharia de São Carlos, em especial, do departamento de Engenharia Elétrica.

Ao professor João Bosco pela orientação neste trabalho. Obrigado por todas as correções e auxílio.

Aos colegas do LACO, Remy, Danilo e Murilo, pelas reuniões até tarde da madrugada, via Skype (!), para ajustar os dados e tornar este trabalho possível. Sinceramente, impossível agradecer o apoio que vocês me deram.

Por fim, a Jesus Cristo, que veio a este mundo, viveu uma vida perfeita, morreu injustamente numa cruz, pagando o preço do meu pecado e recebendo a ira que estava sobre mim, mas que ressuscitou e hoje vive! Obrigado por seu imenso amor!





## SUMÁRIO

<b>Resumo .....</b>	<b>ix</b>
<b>Abstract .....</b>	<b>xi</b>
<b>LISTA DE FIGURAS .....</b>	<b>xiii</b>
<b>LISTA DE TABELAS .....</b>	<b>xv</b>
<b>LISTA DE SIGLAS E ABREVIATURAS .....</b>	<b>xvii</b>
<b>1 Introdução.....</b>	<b>19</b>
1.1 Revisão Bibliográfica .....	22
1.2 Objetivos .....	23
1.3 Organização do Trabalho .....	24
<b>2 Sistema Elétrico de Potência.....</b>	<b>25</b>
2.1 Estrutura de um SEP .....	25
2.2 Principais equipamentos dos SDR's .....	28
2.2.1 Transformador .....	28
2.2.2 Banco de capacitor .....	28
2.2.3 Regulador de tensão.....	29
2.2.4 Chaves para proteção e manobra.....	29
2.3 Representação de SDRs .....	30
2.4 Cálculo de Fluxo de carga .....	32
2.4.1 Método de soma de correntes.....	34
2.4.2 Método de Soma de Potência.....	36
2.5 Modelagem de carga .....	39
2.5.1 Carga de impedância constante com a tensão.....	40
2.5.2 Carga de potência constante com a tensão.....	40
2.5.3 Carga de corrente constante com a tensão .....	41
2.6 Conclusão .....	42
<b>3 O problema de reconfiguração de redes em SDR.....</b>	<b>43</b>
3.1 Exemplo de reconfiguração de redes para restabelecimento de energia .....	43
3.2 Formulação matemática .....	46
<b>4 Metodologia eficiente para reconfiguração de redes em SDRs .....</b>	<b>51</b>

4.1 Fundamentos da RNP.....	51
4.2 Operadores da RNP .....	52
4.2.1 Operador PAO.....	54
4.2.2 Operador CAO.....	56
4.3 Fluxo de carga a partir da RNP.....	58
4.4 Fluxo de carga de varredura direta/inversa com RNP .....	62
4.5 Cálculo do número de manobras .....	65
4.6 Algoritmo Evolutivo Multi-Objetivo em Tabelas.....	69
4.6.1 Algoritmo principal do MEAN .....	70
4.7 Conclusão .....	71
<b>5 Testes e resultados .....</b>	<b>73</b>
5.1 Obtenção e trabalho dos dados do SRD de Marília .....	74
5.2 Parâmetros utilizados no MEAN.....	76
5.3 Resultados das simulações .....	77
5.3.1 Falta única no alimentador 1.....	79
5.3.2 Falta única no alimentador 3.....	84
<b>6 Conclusão .....</b>	<b>91</b>
<b>Referências Bibliográficas.....</b>	<b>93</b>
<b>Apêndice A – Introdução aos Algoritmos Evolutivos .....</b>	<b>97</b>

## Resumo

Devido às demandas do mercado consumidor de energia elétrica torna-se cada vez mais necessário, por parte das concessionárias, o fornecimento de energia dentro dos padrões estabelecidos, principalmente, sem grandes intervalos de interrupção no fornecimento. Para isso, são necessários planos de restabelecimento de energia (PREs) adequados e de forma rápida. Considerando a natureza radial de grande parte dos sistemas de distribuição, este restabelecimento de energia geralmente envolve reconfiguração de redes para restaurar eletricidade às áreas fora de serviço.

Dentre os objetivos de um PRE, destacam-se: (i) atender o maior número de consumidores com fornecimento interrompido, (ii) minimizar o número de operações de chaveamento. Tais objetivos devem ser atingidos sem violar as restrições operacionais do sistema. Também é importante que este plano seja eficiente e que, se possível, ocorra em tempo real. Pode-se notar, então, que a obtenção de um PRE em sistemas de distribuição radiais (SDRs) é um problema com múltiplos objetivos, alguns conflitantes.

Dentre as principais técnicas propostas para obtenção de PREs, as técnicas que utilizam Algoritmos Evolutivos (AEs) têm se destacado. Muitas delas apresentam limitações, pois exigem muitas simplificações na rede, quando lidam com SDRs de grande porte, limitando a possibilidade de utilização.

Neste trabalho foi analisado e utilizado um algoritmo computacional, baseado em um AE Multi-Objetivo, capaz de lidar com SDRs de grande porte, sem a necessidade de simplificações, devido ao uso de uma estrutura de dados adequada que produz configurações exclusivamente radiais e conexas, denominada Representação Nó-Profundidade (RNP).

O algoritmo foi aplicado para obtenção de PREs para o SDR real da cidade de Marília/SP.

**Palavras chave:** Algoritmos Evolutivos Multi-Objetivo, Representação Nó-Profundidade, Restabelecimento de Energia, Sistema de Distribuição de grande porte.



## Abstract

Due to the high demand of electric energy consumption, electricity suppliers, more than ever, must keep distribution within the standards, especially with non-interrupt distribution. To this end suitable energy restoration plans (ERP) are needed quickly. Knowing that much of the distribution networks are radial this usually takes a network reconfiguration to restore electricity on an outage zone

Among the objectives of an ERP, include: (i) meet the largest number of consumers on outage zone, (ii) minimize the number of switching operations. These objectives must be achieved without violation the network restrictions. It is important that it must be an efficient plan and, if it is possible, that it occurs in real time. It can be noted therefore that obtaining an ERP in a radial distribution system (RDS) is a problem with multiple objectives, some of them conflicting.

Among the main techniques proposed for obtaining ERP, techniques that use Evolutionary Algorithms (EAs) have been highlighted. Many of them have limitations because they require many simplifications in the network when dealing with large-scale RDS, making your usability limited.

In this work it was analyzed and used a Multi-objective EA, capable of handling large-escale RDS, not needing simplifications and that is due to the use of a suitable data structure that produces exclusively radial and interconnected configurations that are called Node-Depth Ecoding (NDE).

The algorithm was applied to obtain an ERP for a real DRS of the city of Marilia – SP - Brazil.

**Keywords:** Multiobjective Evolutionary Algorithms, Node-Depth Representation, Power Restoration, Large Distribution System.



## LISTA DE FIGURAS

Figura 2.1. Representação de um SEP.....	25
Figura 2.2. Representação de um SDR .....	27
Figura 2.3. SDR em média tensão, onde SB é o barramento da subestação e S são chaves de manobra (linhas contínuas chaves NF e linhas pontilhadas chaves NA) .....	28
Figura 2.4. Exemplo de grafo .....	31
Figura 2.5. Representação de um SDR através de grafo (Marquez, 2012) .....	32
Figura 2.6. Exemplo de SDR.....	34
Figura 2.7. Passo Etapa <i>Backward</i> .....	36
Figura 2.8. Duas barras de um sistema genérico .....	36
Figura 2.9. SDR de duas barras.....	39
Figura 3.1. Representação em grafo de um SDR em falta .....	44
Figura 3.2. Detalhe da área isolada com a abertura das chaves A e B.....	44
Figura 3.3. Rede reconfigurada pelo fechamento da chave E .....	45
Figura 4.1. RNP para as três árvores da figura 2.5.....	52
Figura 4.2. $T_{de}$ e $T_{para}$ e suas respectivas RNPs .....	55
Figura 4.3. $T_{tmp}$ e sua RNP .....	55
Figura 4.4. $T'_{de}$ e sua RNP .....	55
Figura 4.5. $T'_{para}$ e sua RNP .....	56
Figura 4.6. $T_{de}$ e sua RNP .....	57
Figura 4.7. Subárvores enraizadas nos nós do caminho $r$ a $p$ .....	57
Figura 4. 8. RNP da subárvore podada.....	57
Figura 4. 9. Árvore $T'_{para}$ e sua RNP.....	58
Figura 4.10. SDR com dois alimentadores.....	58
Figura 4.11. Agrupamento das barras e linhas em setores .....	59
Figura 4.12. Grafo representando setores do SDR da figura 4.11 .....	59

Figura 4.13. Operações necessárias para manter o setor em falta.....	66
Figura 5.1. SDR real da cidade de Marília/SP (REDE) .....	75
Figura 5.2. Traçado original do alimentador 1 .....	78
Figura 5.3. Traçado original do alimentador 3 .....	79
Figura 5.4 Destaque de parte da RNP do alimentador 1 (com falta no setor 606) .....	80
Figura 5.5. Trecho fora de serviço (em rosa) devido à contingência no setor 606 .....	80
Figura 5.6. Destaque de parte da RNP do alimentador 3 (com falta no setor 43) .....	85
Figura 5.7. Trecho fora de serviço (em rosa claro) devido a contingência no setor 43 .....	85



## LISTA DE TABELAS

Tabela 2.1. Grau de cada um dos nós do grafo da figura 2.4.....	31
Tabela 4.1. Lista de adjacências para os nós do grafo da figura 2.5.....	53
Tabela 4.2. Árvores dos setores com o nó adicional .....	61
Tabela 4.3. RNPs dos setores mostrados na tabela 4.2.....	62
Tabela 4.4. Manobras de chaves: caso 1 .....	67
Tabela 4.5. Manobras de chaves: Caso 2.....	67
Tabela 4.6. Manobras de chaves: Caso 3.....	68
Tabela 5.1. Valores médios dos objetivos e restrições para todas as soluções encontradas para cada tabela de indivíduos .....	81
Tabela 5.2. Valores médios dos objetivos e restrições das melhores soluções encontradas .....	82
Tabela 5.3. Valores mínimo, médio e máximo dos objetivos e restrições para as melhores soluções encontradas para cada tabela de indivíduos .....	83
Tabela 5.4. Valores médios dos objetivos e restrições para todas as soluções encontradas.....	86
Tabela 5.5. Valores médios dos objetivos e restrições das melhores soluções encontradas .....	87
Tabela 5.6. Valores mínimo, médio e máximo dos objetivos e restrições para as melhores soluções encontradas para cada tabela de indivíduos .....	88



## LISTA DE SIGLAS E ABREVIATURAS

AE – Algoritmo Evolutivo

AEMO – Algoritmo Evolutivo Multi-Objetivo

ANEEL – Agência Nacional de Energia Elétrica

BC – Banco de Capacitor

CAO – *Change Ancestor Operator*

CPFL – Companhia Paulista de Força e Luz

$G_{\max}$  – número máximo de gerações

MEAN – *Multiobjective EA with node-depth encoding*

MEAN-NDS – *MEAN Non-Dominated Sorting*

MPF – Modelo Pai-Filho

NA – Normalmente Aberta

NF – Normalmente Fechada

NSGA II – *Elitist Non-dominated Sorting Genetic Algorithm II*

PAO – *Preserve Ancestor Operator*

PM – Programação Matemática

PRE – Plano de Restabelecimento de Energia

PRODIST – Procedimentos da Distribuição

RNP – Representação Nó-Profundidade

SDR – Sistema de Distribuição Radial

SE - Subestação

SEP – Sistema Elétrico de Potência

$SP_i$  – tamanho da população



## 1 Introdução

A energia elétrica tem se tornado um recurso cada vez mais necessário para a manutenção das estruturas da sociedade contemporânea. Desde grandes consumidores, como indústrias, shopping centers e centros comerciais, até pequenos e médios consumidores, como condomínios prediais, edifícios e residências, todos dependem da energia elétrica para o funcionamento de cada uma de suas partes.

Entretanto, para manter o fornecimento de energia elétrica para tão amplo sistema de consumidores independentes entre si, porém interligados um com o outro, é necessário um complexo sistema de redes elétricas. Esse sistema, constituído por centrais geradoras de todos os portes, extensas linhas de transmissão e uma rede altamente diversificada de distribuição, recebe o nome de Sistema Elétrico de Potência (SEP).

Nas últimas décadas os SEPs não passaram apenas por um amplo processo de expansão em escala, mas também receberam um aumento expressivo no número de cargas que utilizam eletrônica de potência, cargas estas potencialmente perturbadoras ao sistema, além da interligação de centrais de cogeração, tornando o sistema cada vez mais complexo de se operar (Santos, 2009).

Devido a esta complexidade e também a eventos externos, como falhas mecânicas, intempéries climáticas e outras falhas na operação do sistema, acontecem as interrupções no fornecimento de energia ao consumidor final. Estas interrupções variam em termos de duração e número de consumidores afetados, porém geram transtornos relacionados com a falta de energia elétrica. Mesmo com o avanço da engenharia e das técnicas de operações do sistema, as falhas não podem ser totalmente evitadas e devem ser um fator levado no estudo dos SEP (Penteado, 2011).

Ao mesmo tempo, encontra-se, por parte do mercado consumidor, uma exigência cada vez maior por qualidade na energia fornecida. Tanto os desligamentos quanto as variações no nível de tensão são indesejados e as concessionárias são fiscalizadas para manter um determinado padrão no fornecimento de energia. A Agência Nacional de Energia Elétrica (ANEEL) é o órgão do governo responsável por fiscalizar este padrão de normas e por multar as concessionárias que não se mantêm dentro dele. Conforme citado em (Santos, 2009), essa qualidade no fornecimento pode ser avaliada pelos seguintes itens:

- Continuidade do fornecimento;
- Nível de tensão;
- Oscilações rápidas de tensão;
- Desequilíbrio de tensão;
- Distorções harmônicas de tensão;
- Nível de interferência em sistemas de comunicações.

Para suprir estas exigências no fornecimento, cada concessionária de distribuição tem um conjunto de normas que devem ser seguidas tanto na operação, quanto numa possível expansão da rede elétrica. Estas normas, que seguem as premissas apresentadas nos Procedimentos de Distribuição (PRODIST) da ANEEL, apresentam pré-requisitos a serem observados nos estudos de planejamento da expansão da rede elétrica. Basicamente, os pré-requisitos analisados são: carregamento de alimentadores e subestações, número de clientes por alimentador, regulação de tensão e compensação reativa, perdas técnicas e confiabilidade (CPFL, 2011). Observando estes requisitos, tanto levando em conta o período de execução das obras (chamado de ano base) quanto tendo em vista o aumento de carga nos anos seguintes (ano horizonte), melhora-se a qualidade no fornecimento de energia elétrica.

Entretanto, há mais um elemento a ser considerado dentro deste contexto, que é a configuração das redes e as consequências que isto traz. Devido a fatores econômicos e operativos, a maioria dos sistemas de distribuição apresenta uma configuração radial (ver figura 2.3). Esta característica radial simplifica a operação e a proteção, porém diminui a confiabilidade desses sistemas em relação aos fatores apresentados para a qualidade no fornecimento da energia (Mansour, 2009). No caso de uma falta no tronco do alimentador que cause atuação da proteção e desligamento do trecho, por exemplo, todos os ramais subsequentes a este ponto são afetados com falta de energia elétrica.

Surge então a necessidade de se ter um plano de restabelecimento de energia (PRE) que seja eficiente, de maneira a não haver desligamentos de grandes áreas, por longos períodos de tempo, seja em decorrência de fenômenos climáticos, como a queda de um raio próximo ao alimentador, ou em decorrência de alguma manutenção na rede de distribuição. Até os dias da confecção deste texto, estes planos de restabelecimento são usualmente determinados por técnicos nos centros de operação das distribuidoras, com auxílio de alguns algoritmos computacionais apenas, sem muita eficiência no processo.

A grande dificuldade de se propor algoritmos computacionais eficientes deve-se ao fato de um PRE ser um problema com vários objetivos. De acordo com (Santos, 2009) e com o que vem sendo discutido, um PRE adequado envolve os seguintes objetivos:

- Encontrar um plano em um curto intervalo de tempo (em tempo real);
- Minimizar o número de manobras;
- Reduzir o número de consumidores interrompidos;
- Nenhum componente sobrecarregado;
- Manter a estrutura radial do sistema;
- Reduzir o total de perdas de potência;
- Reduzir quedas de tensão.

É importante destacar que na prática estes objetivos podem ser conflitantes e nem sempre é possível atingir todos. Além disso, dependendo da necessidade momentânea do sistema, outros objetivos podem surgir.

Diversos métodos e propostas têm surgido para tentar resolver o problema do restabelecimento de energia em tempo real através de procedimentos de reconfiguração. Entretanto, devido à característica combinatória desse problema, as técnicas de programação matemática não são adequadas para tratamento desse problema em sistemas de grande porte. Os algoritmos evolutivos (AEs) são uma técnica alternativa que têm se demonstrado capazes de lidar com esta dificuldade produzindo, porém, muitas soluções ineficazes quando considera redes de tamanho real (Santos, 2004).

Mesmo propondo algumas soluções ineficazes, os AEs possibilitam a determinação de soluções adequadas ou, utilizando os termos de otimização em sistemas, mesmo não propondo ótimos globais, propõem soluções que são ótimos locais. Do ponto de vista da operação de Sistemas de Distribuição Radiais (SDRs) em tempo real, boas soluções, mesmo que não seja a melhor solução, tornam a utilização do método vantajosa e interessante.

Conforme observado por Mansour (2009), um dos fatores que influenciam o desempenho de um AE convencional (aquele que faz uso de uma função objetivo), é a estrutura de dados adotada. Para se elaborar um PRE utilizando AEs é necessário um algoritmo de busca em grafo, sendo assim o desempenho do AE afetado pela forma com que as árvores de grafos são representadas computacionalmente.

Para melhorar o desempenho dos AEs aplicados à formação de PREs, em Santos et al. (2010) foi empregada uma nova estrutura de dados, chamada Representação Nó-profundidade (RNP), que foi proposta em Delbem et al. (2004). Esta estrutura possui dois operadores, que permitem a realização de poda ou enxerto nas árvores da floresta de grafo armazenada na RNP, as quais representam os alimentadores de um SDR, de forma a gerarem novas árvores, que correspondem a configurações factíveis, isto é,

redes radiais capazes de fornecer energia para todo o sistema<sup>1</sup> (Camillo, 2011). Esta última característica concede à ferramenta maior eficiência, pois diminui a quantidade de soluções não factíveis (configurações factíveis que atendem à todas as demais restrições operacionais do problema), já mencionadas como um dos problemas encontrados na utilização de AEs.

Além disto, a utilização da RNP ainda possui outra vantagem que merece destaque no que diz respeito ao tratamento do problema de restabelecimento de energia. Esta vantagem provém do fato de que todas as configurações geradas através da RNP e de seus operadores apresentarem cada um de seus nós ordenados segundo a relação conhecido como Modelo Pai-Filho (MPF). Esta ordenação possibilita a execução do fluxo de carga seguindo um método de varredura direta e inversa, que, conforme foi exposto em (Pigatin e London, 2009), é um método extremamente rápido quando se trabalha tanto com sistemas radiais, quanto com sistemas malhados, apesar de que no segundo caso há perda na eficiência computacional. Ao se trabalhar com outras estruturas de dados, que não a RNP, para possibilitar a varredura direta e inversa é necessária a criação de um algoritmo para a ordenação dos dados segundo o MPF, o que diminui a velocidade final do processo.

Em virtude do que vem sendo exposto, as técnicas envolvendo Algoritmos Evolutivos “Multi-Objetivo” (AEMO) têm sido aplicadas para o problema de restabelecimento de energia em SDRs, apresentando resultados bastante promissores, haja vista tratar-se de um problema multi-objetivo e combinatorial.

## 1.1 Revisão Bibliográfica

Muita literatura tem sido produzida nesta área de pesquisa de algoritmos para restabelecimento de energia em sistemas de distribuição. Conforme já exposto dois fatores críticos para utilização de AEs, em problema de reconfiguração de redes de forma geral, são: a estrutura de dados utilizada para representar a topologia dos SDRs e os operadores genéticos utilizados, que podem gerar soluções infactíveis e não-radiais.

Nas metodologias para reconfiguração de redes desenvolvidas em (Moussa et al, 2009; Santos et al, 2010; Sanches et al, 2011), foi utilizada a estrutura de dados denominada Representação Nó-Profundidade (RNP), e seus correspondentes operadores genéticos (Delbem et al, 2004).

---

1 O termo todo o sistema significa que todas as partes do sistema estão conectadas. Ocasionalmente, não há nenhuma chave para conectar uma zona fora de serviço para a permanência da rede.



A diferença entre as metodologias desenvolvidas em (Moussa et al, 2009; Santos et al, 2010; Sanches et al, 2011) é o AEMO utilizado. A metodologia proposta em (Santos et. al., 2010), denominado MEAN, faz uso da RNP em conjunto com um AEMO baseado no método de Tabelas. Por outro lado, o método apresentado em (Mansour et. al., 2009), denominado NSDE, baseia-se na combinação da RNP com uma versão modificada do NSGA-II. A metodologia proposta em (Sanches et al, 2011), denominada MEAN-NDS, procura combinar os melhores aspectos das metodologias MEAN e NSDE, para tratamento do problema de redução de perdas em SDs. Assim como a metodologia MEAN, a MEAN-NDS trabalha em paralelo com várias subpopulações armazenadas em tabelas, onde as melhores soluções (ou configurações do SD), para cada característica do problema, são armazenadas em suas respectivas tabelas. Entretanto, a MEAN-NDS faz uso de tabelas adicionais de subpopulações não dominadas, que armazenam as soluções não dominadas obtidas durante as gerações (calculadas da mesma forma que no NSDE).

Neste trabalho será utilizada como referência principal (Santos et al., 2010), logo, o algoritmo em estudo será o MEAN.

## **1.2 Objetivos**

O objetivo principal deste trabalho é apresentar, estudar e aplicar, em um sistema de distribuição real, um programa computacional eficiente, capaz de propor planos de restabelecimento de energia para SDRs de grande porte, a partir de situações propostas pelo operador do programa. O sistema de distribuição que será utilizado neste trabalho é o sistema da cidade de Marília/SP. Serão levados em conta todos os trechos de linha da cidade, considerando suas cargas, níveis de corrente e chaves. O programa computacional que será utilizado consiste da implementação da metodologia para tratamento do problema de restabelecimento de energia, proposta em (Santos et al., 2010) que faz uso de um AEMO e da estrutura de dados RNP.

Os dados utilizados neste trabalho são dados reais do sistema de distribuição da cidade de Marília, e foram fornecidos pela Companhia Paulista de Força e Luz (CPFL), empresa líder de mercado, responsável pela distribuição de mais de 13% da energia elétrica do país, atendendo 7,1 milhões de clientes de 559 municípios. O trabalho foi desenvolvido juntamente com o estágio supervisionado realizado na empresa, nas áreas de Proteção do Sistema de Distribuição, Análise de Viabilidade de Projetos e Qualidade de Energia, dentro da gerência da Gestão de Ativos.

### 1.3 Organização do Trabalho

Nesta capítulo foi feita uma apresentação geral do problema de restabelecimento de energia em sistemas de distribuição de energia, assim como das metodologias utilizadas, focando em uma metodologia específica que visa possibilitar a obtenção de soluções em tempo real para sistemas de grande porte (com milhares de chaves e barras). Deu-se destaque para os principais trabalhos que têm sido desenvolvidos nesta área, em especial o apresentado em (Santos et al., 2010), que servirá de base para este presente trabalho.

O capítulo 2 traz uma visão geral sobre os SEPs, destacando suas partes constituintes e seus principais equipamentos. Apresenta uma revisão da teoria de grafos, como uma importante ferramenta para representar no computador os sistemas de energia. Por fim, revisa métodos para cálculo de fluxo de potência, destacando o método de varredura direta e inversa que é usualmente empregado nos métodos desenvolvidos para tratamento do problema de restabelecimento de energia em SDRs.

O capítulo 3 retoma o tema principal da reconfiguração de redes para restabelecimento de energia, apresentando uma formulação matemática para o problema.

O capítulo 4 apresenta a RNP, algumas de suas características e seus principais operadores. Em seguida, é apresentado o MEAN, metodologia que será utilizada para desenvolvimento sete trabalho proposta em (Santos et al., 2010).

O capítulo 5 apresenta os testes realizados com dados reais do sistema de distribuição da cidade de Marília. São realizados testes com vários objetivos, com uma única falta. Por fim é feita uma análise dos resultados obtidos, observando-se a eficiência do processo para os diferentes casos.

O capítulo 6 apresenta as conclusões do trabalho, assim como a relevância e possibilidade de aplicação para os sistemas de distribuição atuais e futuros.

## 2 Sistema Elétrico de Potência

Este capítulo apresenta o que é um SEP e quais os principais equipamentos de um sistema de distribuição, dando atenção especial àqueles que são utilizados para reconfiguração da rede. Também é feita uma revisão da teoria básica de grafos, importante ferramenta na representação computacional de SDRs, e uma revisão de metodologias para cálculo de fluxo de carga. O objetivo é dar uma visão geral sobre os elementos básicos e ferramentas que serão utilizados no decorrer deste trabalho.

### 2.1 Estrutura de um SEP

O SEP pode ser dividido em três partes principais: geração, transmissão e distribuição. A figura 2.1 é uma representação simplificada de um SEP e suas principais partes constituintes.

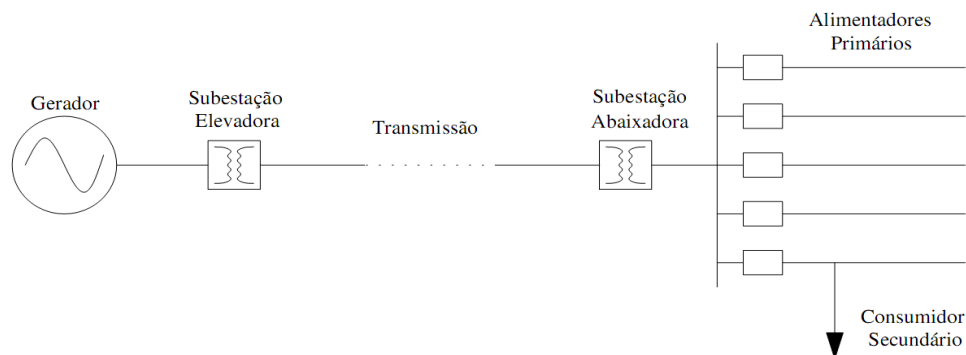


Figura 2.1. Representação de um SEP

O primeiro bloco é o da Geração. Na geração encontram-se as usinas de geração de energia elétrica (representado pelo “gerador” na figura), que transformam energia mecânica em energia elétrica através do acionamento de um gerador por meio de uma turbina. As fontes utilizadas para produção de energia mecânica podem ser de origem hídrica, fissão nuclear, solar, eólica ou da queima de algum combustível fóssil. Os níveis de tensão da geração variam de um gerador para outro, porém geralmente estão no intervalo de 10 a 30kV, sendo, no caso do Brasil, toda geração feita na frequência de 60Hz.

De acordo com o Banco de Informações da Geração da ANEEL, em 2012 o Brasil possui um total de 2.674 empreendimentos em operação, gerando 119.337.593 kW de potência, sendo que 69,76% desta potência são provenientes da geração em pequenas e grandes centrais hidrelétricas.

O segundo bloco é o da Transmissão. O sistema de transmissão é composto basicamente por chaves de manobra e linhas de transmissão. No Brasil o nível de tensão na transmissão varia de 138kV até 750kV, sendo necessária a instalação de subestações elevadoras de tensão na saída de cada unidade geradora. A transmissão geralmente é feita em corrente alternada, mas também pode ser feita em corrente contínua. No caso das linhas de transmissão da Hidrelétrica de Itaipu, por exemplo, tem-se transmissão em 750kV corrente alternada e  $\pm 600$ kV corrente contínua. As futuras linhas de transmissão do complexo de hidrelétricas do Rio Madeira, no estado de Rondônia, também terão transmissão em corrente contínua, visando à diminuição das perdas por efeito Joule devido às grandes distâncias percorridas até os centros consumidores.

O terceiro bloco representa a Distribuição. O sistema de distribuição é composto basicamente por subestações abaixadoras de tensão e pelas redes de distribuição de energia, compostas por linhas aéreas e equipamentos de proteção e transformação. A distribuição opera na faixa de tensão de 127/220V (na rede secundária) até 34,5kV (na rede primária). A distribuição atende, na tensão adequada, tanto os grandes consumidores de energia elétrica, quanto os pequenos consumidores. No Brasil, desde o processo de privatização ocorrido durante a década de 90, as concessionárias de energia são as principais responsáveis pela distribuição de energia elétrica, entre as quais se encontra a CPFL.

A figura 2.2 é uma representação simplificada de um sistema de distribuição.

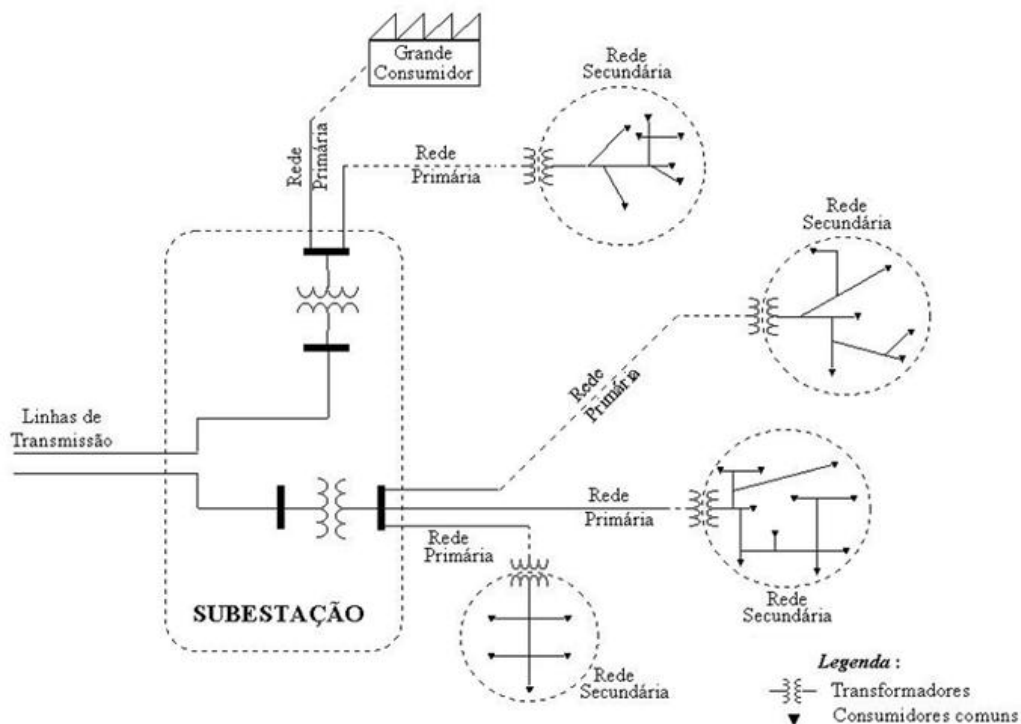


Figura 2.2. Representação de um SDR

O sistema de distribuição pode ser subdividido em:

- Rede de distribuição primária:** é a distribuição em redes aéreas radiais, feita em média tensão, isto é, de 11,9 a 34,5kV. Nesta parte do sistema estão instaladas as chaves de manobras que possibilitam a transferência de carga entre diferentes circuitos (ou alimentadores). Esta transferência de carga pode ser necessária devido à atuação dos equipamentos de proteção em decorrência de faltas no sistema, ou devido à manutenção em algum ponto do alimentador, tornando possível a continuidade no fornecimento de energia elétrica. Empreendimentos com alta demanda de energia (grandes centros comerciais, *shopping centers*, condomínios prediais, grandes hospitais e muitas indústrias) e a rede secundária são alimentados pela rede de média tensão.
- Rede de distribuição secundária:** é a distribuição em redes aéreas (ou subterrâneas) feita em baixa tensão, isto é, em 220/127V ou 380/220V. É alimentada pela rede de distribuição primária por meio de transformadores que variam de 15 a 1000kVA de potência. Pequenos consumidores, como condomínios residenciais, edifícios, pontos comerciais e residências, são alimentados por esta rede em baixa tensão.

A figura 2.3 ilustra uma parte de SDR em média tensão que será o principal alvo de estudo deste trabalho. As chaves utilizadas para manobra do sistema são as chaves normalmente fechadas (NF) e as chaves normalmente abertas (NA).

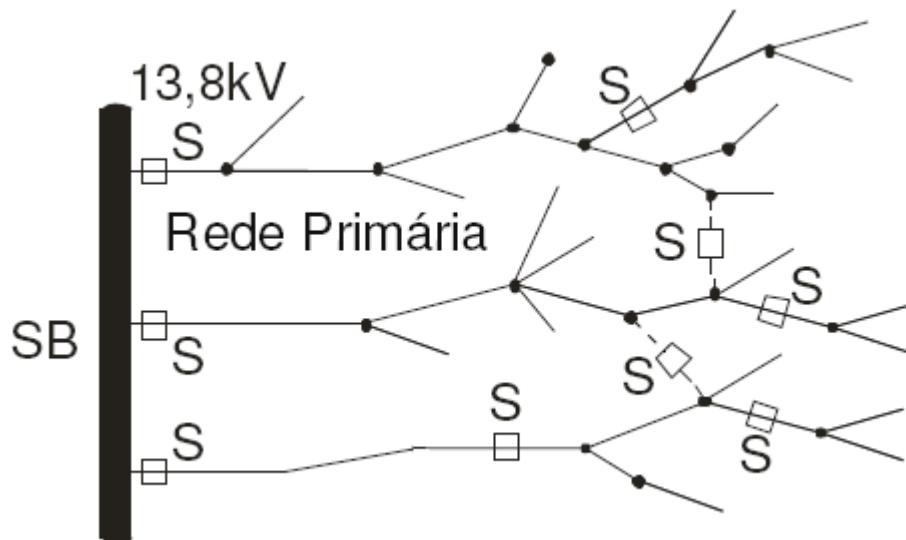


Figura 2.3. SDR em média tensão, onde SB é o barramento da subestação e S são chaves de manobra (linhas contínuas chaves NF e linhas pontilhadas chaves NA)

## 2.2 Principais equipamentos dos SDR's

### 2.2.1 Transformador

Equipamento mais utilizado em um sistema de distribuição, sendo responsável por abaixar o nível de tensão da rede primária para a secundária. No caso da cidade de Marília/SP, por exemplo, com 95.583 consumidores e um consumo médio mensal de 41.056.032kWh, há 4.414 transformadores instalados, atendendo uma demanda total de, aproximadamente, 110.300kVA. Os transformadores comumente utilizados em sistemas de distribuição variam de 15kVA a 1000kVA de capacidade.

### 2.2.2 Banco de capacitor

Em virtude das altas correntes conduzidas pelos cabos nas redes de distribuição, a tendência é que o fluxo de potência reativa (indutiva) na rede aumente, diminuindo o valor do fator de potência. Com o objetivo de corrigir o fator de potência para um valor adequado podem ser instalados bancos de capacitores (BCs) em paralelo com o circuito. Além de aumentar o fator de potência, este procedimento também tem outros benefícios, como: redução do carregamento nos transformadores das subestações e na

rede de distribuição, redução das perdas e aumento do nível de tensão (CPFL, 2011). Em casos bastante particulares, podem ser instalados BCs em série com o circuito, um procedimento que pode ser adotado para possibilitar a partida de grandes cargas em locais onde o nível de tensão não pode ser elevado.

### **2.2.3 Regulador de tensão**

A circulação de correntes de carga, além de gerar reativos na rede, também gera queda de tensão ao longo dos alimentadores devido às perdas por efeito Joule. Conforme legislação vigente a tensão a ser contratada por clientes atendidos em tensão nominal superior a 1kV deve-se situar entre 95% e 105% da tensão nominal de operação do sistema no ponto de conexão (PRODIST, 2012). Um dos procedimentos que pode ser adotado para acertar a queda de tensão já foi apresentado, que é a instalação de BCs. Porém, uma medida mais eficiente, para compensação das quedas de tensão na rede de distribuição, é a instalação de reguladores de tensão. Os reguladores de tensão em uso pela CPFL Paulista permitem uma regulação de  $\pm 10\%$  quando ligados em delta aberto (2 unidades) e  $\pm 15\%$  em delta fechado (3 unidades) (CPFL, 2011).

### **2.2.4 Chaves para proteção e manobra**

A utilização de chaves que possibilitam o seccionamento e manobra da rede elétrica é de suma importância ao sistema, pois permite o rearranjo da rede (ou reconfiguração da rede) aumentando a flexibilidade operacional do sistema elétrico, melhorando a confiabilidade e a qualidade no fornecimento de energia. Outro tipo de chave importante à rede elétrica são as chaves de proteção, que visam proteger tanto os equipamentos do sistema, quanto os consumidores finais contra danos que possam sofrer devido à grandes variações nos níveis de tensão.

São exemplos de chaves utilizadas para manobra e proteção dos SDRs:

- Chaves trifásicas: utilizadas na interligação entre troncos de alimentadores, possibilitando a manobra de carga entre eles, sem a necessidade de desligamento total;
- Chaves facas: podem operar conjugadas às chaves trifásicas, ou na saída dos alimentadores das subestações, possibilitando o desligamento total para fins de manutenção;

São exemplos de equipamentos de proteção e manobra:

- Chave fusível / Elo fusível: dispositivo mais empregado em saídas de ramais, devido ao seu baixo custo. No caso da CPFL, são padronizadas para 100 A e devem ser instaladas nas derivações dos troncos dos alimentadores (CPFL, 2011). Se utilizadas com lâminas desligadoras podem transportar uma corrente de até 300 A. Atua na proteção de sobrecorrentes, de acordo com o elo especificado. Pode ser instalada na interligação de ramais de alimentadores na posição NA, sendo utilizada para manobra de cargas, porém tendo seu uso bastante limitado pela corrente máxima permitida pelo elo.
- Religadores: podem ser usados tanto para a proteção da saída dos alimentadores, como para a proteção ao longo dos alimentadores. Apresentam unidades de proteção de fase e neutro. Atuam de forma temporizada, contando um tempo pré-estabelecido e religa o circuito, caso o defeito transitório desapareça. Caso a falta persista nos tempos pré-estabelecidos, ele atua de forma instatânea, abrindo o circuito instataneamente se a corrente de fase ou neutro exceder à corrente ajustada, e somente poderá ser religado manualmente. Pode ser instalada na interligação de troncos ou ramais de alimentadores na posição NA, sendo utilizada para manobras de cargas.

São exemplos de equipamentos apenas de proteção:

- Disjuntores e relés: os disjuntores são equipamentos usados nas saídas dos alimentadores, sendo comandado por relés de sobrecorrente de fase e neutro. São utilizados para proteção dos transformadores das subestações contra surtos de corrente.

### 2.3 Representação de SDRs

A fim de apresentar uma formulação para o problema de restabelecimento de energia, é necessário antes revisar alguns conceitos da teoria de grafos. Muitas situações podem ser representadas por meio de conjuntos de pontos, que são interligados por linhas. Um exemplo disso é a representação de uma rede elétrica, constituída por barras e chaves que se interligam. Tomando as barras por pontos e as chaves por linhas, pode-se propor uma representação adequada de um SDR. A teoria de grafos surge da abstração matemática deste conceito de pontos e linhas interligados.

Um grafo  $G$  é um par  $(N(G), E(G))$ , em que  $N(G)$  é um conjunto de vértices ou nós do grafo, e  $E(G)$  é um conjunto de pares de nós não-ordenados, que são as arestas do grafo. Se  $u$  e  $v$  são dois nós de um grafo, e se o par  $\{u, v\}$  é uma aresta denotada por  $y$ ,



então diz-se que  $y$  conecta  $u$  e  $v$ , como pode ser notado na figura 2.4. Para este caso, a aresta  $\{u, v\}$  é dita incidente ao nó  $u$  e ao nó  $v$ .

A **ordem** de um grafo é dada pelo número de elementos do conjunto  $N(G)$ , isto é, pelo número de nós de  $G$ . A ordem do grafo apresentado na figura 2.4 é 4. O tamanho de um grafo é dado pelo número de elementos do conjunto  $E(G)$ , isto é, pelo número de arestas de  $G$ . Para o grafo em questão, seu tamanho também é 4. O **grau** de um nó é dado pelo número de arestas que lhe são incidentes. A tabela 2.1 apresenta o grau de cada um dos nós do grafo.




Figura 2.4. Exemplo de grafo

Tabela 2.1. Grau de cada um dos nós do grafo da figura 2.4

Nó	Grau
$w$	1
$u$	2
$v$	2
$z$	3

Define-se **caminho** como sendo uma sequência de nós, tal que de cada um dos nós exista apenas uma aresta distinta. Por exemplo, para um grafo  $G$ , uma sequência de arestas  $\{s_0, s_1\}, \{s_1, s_2\}, \dots, \{s_{m-2}, s_{m-1}\}, \{s_{m-1}, s_m\}$ , em que todas as arestas são distintas, esta sequência é um caminho. Se nenhum dos nós se repete ao longo do caminho, este caminho é chamado caminho simples ou **cadeia**. O comprimento do caminho é dado pelo número de arestas que ele usa. Se os nós  $s_0$  e o nó  $s_m$  forem iguais, este caminho é chamado de **ciclo**.

Para a figura 2.4, tem-se que:

- $\{w, z\}, \{z, u\}$  e  $\{u, v\}$  constitui um exemplo de caminho;
- $\{u, v\}, \{v, z\}$  e  $\{z, w\}$  constitui exemplo de uma cadeia;
- $\{u, v\}, \{v, z\}$  e  $\{z, u\}$  constitui exemplo de um ciclo.

Um par de nós em um grafo é um **par conexo**, se existir um caminho entre eles. Um grafo  $G$  é um **grafo conexo**, se todo par de nós em  $G$  for um par conexo.

Diz-se que H é um **subgrafo conexo máximo** de um grafo G, se o único subgrafo conexo contendo H é o próprio H. Um subgrafo conexo H máximo também é chamado de **componente**. Um grafo G é conexo, se o número de seus componentes for igual a um.

Um grafo que não contém ciclos é chamado um **grafo acíclico**. Uma **árvore** é um grafo conexo acíclico. Um grafo formado por um conjunto de árvores é chamado de **floresta**. Logo, cada componente de uma floresta é uma árvore. Se uma floresta tem apenas uma árvore ela é uma floresta conexa. Assim, uma árvore é uma floresta conexa.

Chama-se de **nó raiz** o nó que é tomado como referência, geralmente é ele marca o início de uma árvore. Ele pode ter grau maior ou igual a um. Exceto se for o nó raiz, nós com grau igual a um são chamados de **nós terminais**.

Conforme já foi dito, a topologia elétrica de um SDR pode ser representada computacionalmente por meio de grafos. Para ilustrar este conceito, a figura 2.5 apresenta um SDR com 3 alimentadores. Cada barra (nó) do sistema representa um setor<sup>2</sup> e as arestas interligando as barras são chaves seccionadoras. As arestas em linhas cheias representam as chaves NF e as arestas em linhas tracejadas representam as chaves NA. As barras 1, 2 e 3 se encontram em uma subestação.




Figura 2.5. Representação de um SDR através de grafo (Marquez, 2012)

## 2.4 Cálculo de Fluxo de carga

Para o estudo e escrita dos itens 2.4 e 2.5 foi utilizado como base Marquez (2012). Antes de se analisar a formulação do problema é necessária uma revisão dos métodos para cálculo de fluxo de carga, visto que este cálculo estabelece os objetivos e

<sup>2</sup> Um setor corresponde a um conjunto de barras e linhas sem a presença de chaves seccionadoras.

restrições na implantação de uma nova configuração para solução do problema de restabelecimento de energia. A partir do cálculo de fluxo de carga obtém-se as condições de operações de uma rede elétrica, isto é, tensão complexa nas barras e os fluxos de potência ativa e reativa nas linhas e nos transformadores. Para este cálculo assume-se que a topologia da rede, potência instalada e demanda requerida (ou corrente de carga) são conhecidas.

Os métodos tradicionais para cálculo de fluxo de carga para sistemas de transmissão, como Newton-Raphson, Desacoplado Rápido e versões modificadas dos mesmos, são, em geral, inadequados no cálculo de fluxo de carga para SDRs. Isto ocorre devido à necessidade de fatoração de matrizes que podem se tornar mal condicionadas em função das características particulares dos SDRs, como, por exemplo, baixa relação  $X/R$  (reatância/resistência) dos parâmetros dos alimentadores, trechos com impedâncias relativamente baixas associados com trechos com impedâncias altas e grande número de cargas distribuídas. Por isso, nas últimas décadas foram desenvolvidos métodos específicos para cálculo de fluxo de carga em SDRs. Um destes métodos é o método de varredura direta/inversa.

Os métodos de varredura direta/inversa recebem este nome devido ao seu processo iterativo, que percorre a rede a partir de suas extremidades até a subestação e vice-versa. Primeiramente, realiza-se a varredura inversa (*Backward*), que consiste em, partindo dos nós extremos e de uma estimativa dos valores das tensões nodais, calcular os valores das correntes ou dos fluxos de potência até a subestação, ou nó raiz. A partir do valor obtido para corrente no nó raiz e da tensão previamente conhecida nesta barra, procede-se com a varredura direta (*Forward*), que consiste em recalculando os valores de tensão de cada barra da rede até sua extremidade, nos nós extremos. Repete-se este processo até que algum critério de convergência pré-estabelecido seja atendido.

Na figura 2.6 pode-se observar a representação de um SDR como uma árvore, em que o nó 1 é o nó raiz e representa a subestação. Os nós 3, 4, 5, 7, 9 e 11 são nós extremos da rede.

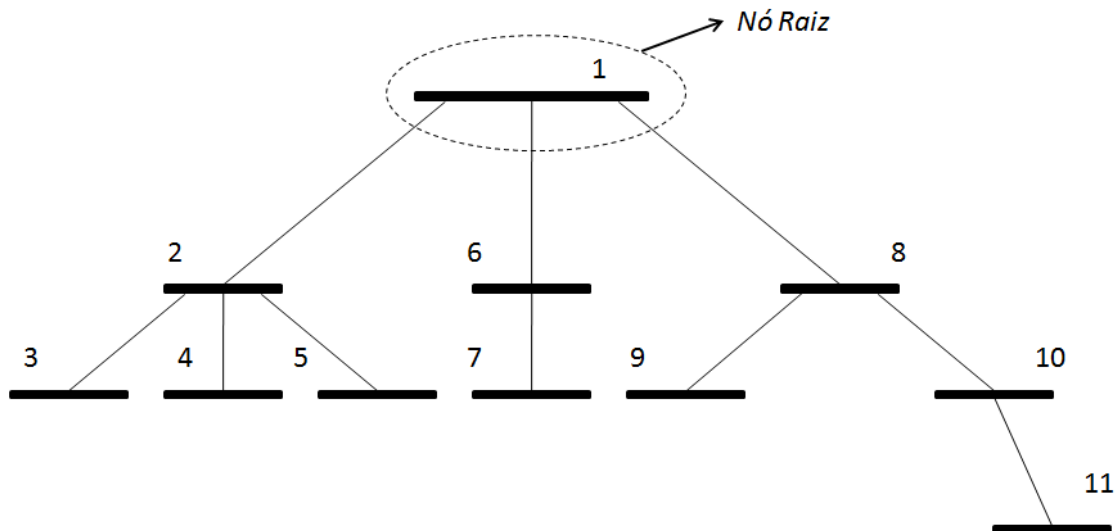


Figura 2.6. Exemplo de SDR

Existem, basicamente, duas versões do método para cálculo de fluxo de carga direta/inversa, são eles: soma de correntes e soma de potências.

#### 2.4.1 Método de soma de correntes

O método de soma de correntes foi desenvolvido para SDRs, entretanto, também pode ser aplicado a sistema de distribuição fracamente malhados. É um método conceitualmente simples, e apresenta um bom desempenho na resolução de problemas de fluxo de carga em SDRs.

Considerando um sistema de distribuição radial com  $n$  nós e ramos, dada a tensão no nó raiz e assumindo a tensão com magnitude igual a 1 (um) p.u., com ângulo igual a 0 (zero) graus para todas as demais barras do sistema, o método de resolução consiste em três passos:

- 1. Cálculo da corrente nodal:** na iteração  $k$ , as injeções de correntes nodais são calculadas através da seguinte expressão:

$$I_n = \frac{P_n + jQ_n}{V_n} + \sum_{i=1}^{n-1} I_{shunt,i} \quad (2.1)$$

em que  $V_n$  é a tensão na barra  $n$ , calculada durante a iteração  $k$ ,  $P_n + jQ_n$  é a injeção de potência complexa especificada na barra  $n$ ,  $\sum_{i=1}^{n-1} I_{shunt,i}$  é a soma de todos os elementos *shunt* da barra  $n$ ; e  $n$  é o número total da representação radial do sistema de distribuição.

**2. Etapa Backward (varredura Inversa):** esta etapa se inicia a partir das linhas conectadas às barras mais extremas do sistema (barras com maiores profundidades) e movendo-se até as linhas conectadas à subestação, ou seja, ao nó raiz (com profundidade zero), calculam-se as correntes na linha , que liga uma barra à sua antecessora , conforme ilustrado na figura 2.7, da seguinte forma:

$$(2.2)$$

onde é a injeção no nó e é o número de linhas do sistema;

**3. Etapa Forward (varredura Direta):** nesta etapa atualizam-se as tensões complexas nas barras, iniciando pelas barras que estão conectadas ao nó raiz (subestação) e seguindo até as barras extremas. Por exemplo, para atualização da tensão na barra , utilizando a tensão na iteração de e o fluxo de corrente na linha calculado no passo 2, tem-se:

$$(2.3)$$

onde é a impedância série da linha ;

**4. Etapa de teste de convergência:** os passos 2, 3 e 4 são repetidos até que seja alcançado o critério de convergência. Usualmente o critério adotado é o maior erro de potência ativa e reativa nas barras do sistema, tal que esse erro seja menor que uma tolerância  $\epsilon$  previamente estabelecida. Assim, a potência complexa injetada na barra , na iteração , é calculada da seguinte forma:

$$(2.4)$$

Portanto o erro de potência ativa e reativa na barra é calculado utilizando a expressão 2.5:

$$(2.5)$$




Figura 2.7. Passo Etapa *Backward*

### 2.4.2 Método de Soma de Potência

O método de soma de potência é um método relativamente simples, do ponto de vista conceitual, e apresenta um desempenho eficiente na resolução de problemas de fluxo de carga em SDRs.

A Figura 2.8 ilustra duas barras ( e ), de um alimentador, ligadas por um ramo que possui uma impedância . Então as equações de fluxo de carga utilizadas na etapa *Backward* (varredura Inversa) são:




Figura 2.8. Duas barras de um sistema genérico

- Fluxo de potência na impedância do ramo chegando na barra  $m$ :

$$P_m = \sum_{i \in \mathcal{L}_m} P_{mi} - \sum_{i \in \mathcal{L}_m} P_{im} + P_L$$

onde  $L$  significa carga;  $F$  fluxo e  $I$  injeção.

Escrevendo em termos de potência ativa e reativa:

- Fluxo de potência no ramo  $ij$  saindo da barra  $i$  :

onde:

desse modo:

Assim:

$$P_{ij} = V_i^2 G_{ij} - V_i V_j B_{ij} \cos \theta_{ij} \quad (2.10)$$

$$Q_{ij} = V_i V_j B_{ij} \sin \theta_{ij} - V_i^2 B_{ij} \quad (2.11)$$

- $P_{ij}$  é o fluxo de potência ativa que sai da barra  $i$  no ramo  $ij$  ;
- $Q_{ij}$  é o fluxo de potência reativa que sai da barra  $i$  no ramo  $ij$  ;
- $P_{ji}$  é o fluxo de potência ativa que chega na barra  $j$  no ramo  $ij$  ;
- $Q_{ji}$  é o fluxo de potência reativa que chega na barra  $j$  no ramo  $ij$  ;
- $V_i$  tensão na barra  $i$  ;
- $G_{ij}$  resistência no ramo  $ij$  ;
- $B_{ij}$  reatância no ramo  $ij$  ;

A seguir apresentam-se as equações utilizadas na etapa *Forward* (varredura direta):

Considerando  $V_i$  (  $\theta_i$  será apenas módulo):

$$P_i = \sum_{j \in \mathcal{N}} V_i V_j G_{ij} \cos \theta_{ij} - V_i^2 \sum_{j \in \mathcal{N}} G_{ij} \quad (2.12)$$

$$Q_i = \sum_{j \in \mathcal{N}} V_i V_j B_{ij} \sin \theta_{ij} - V_i^2 \sum_{j \in \mathcal{N}} B_{ij} \quad (2.13)$$

$$\frac{V_{i+1}}{V_i} = \frac{V_{i+1}}{V_i} \frac{V_{i+1}}{V_i} \frac{V_{i+1}}{V_i} \quad (2.12)$$

A partir da equação 2.12, tem-se a equação para atualização das magnitude das tensões nas barras:

$$\frac{V_{i+1}}{V_i} = \frac{V_{i+1}}{V_i} \frac{V_{i+1}}{V_i} \quad (2.13)$$

onde:

- tensão na barra ;
- tensão na barra ;
- resistência no ramo ;
- reatância no ramo .

Da equação 2.12 encontra-se a equação de atualização do ângulo da tensão nas barras:

$$\frac{\theta_{i+1}}{\theta_i} = \frac{\theta_{i+1}}{\theta_i} \quad (2.14)$$

Se  $\theta_{i+1} \rightarrow \theta_i$  , onde:

- $\frac{\theta_{i+1}}{\theta_i}$  ;
- $\frac{\theta_{i+1}}{\theta_i}$  .

O algoritmo deste método para o cálculo do fluxo de carga é composto pelos seguintes passos:

1. Assumir que as tensões iniciais em todas as barras são iguais à tensão da subestação (nó raiz);
2. **Etapa Backward (varredura Inversa):** iniciando pelas barras extremas do sistema, calculam-se os fluxos de potência ativa e reativa para cada ramo utilizando as equações 2.10 e 2.11;
3. **Etapa Forward (varredura Inversa):** partindo do nó raiz (subestação) calculam-se as atualizações da magnitude e do ângulo das tensões nas barras utilizando as equações 2.13 e 2.14;
4. **Etapa de teste de convergência:** verificar a variação da magnitude e da fase das tensões nodais obtidas na iteração atual na anterior. Se as diferenças



forem maiores ou iguais a uma tolerância próxima de zero, o processo é repetido a partir do passo 2; caso contrário, encerram-se os cálculos.

## 2.5 Modelagem de carga

As cargas apresentam grande dificuldade para sua modelagem, isto ocorre em virtude das diferenças existentes dentro de um conjunto de consumidores ligados a um mesmo barramento, e ao consumo nem sempre previsível de cada um. Aliado a esta variedade, também destaca-se a variação no tempo como um fator que também dificulta a modelagem. Portanto, deve-se encarar a carga como uma representação esquemática na qual se faz referência ao fato de serem variáveis e apresentarem duas componentes, potência ativa e reativa (Sanches, 2012).

No estudo de fluxo de potência, a modelagem da carga assume um papel importante nos resultados obtidos, possuindo influência decisiva na qualidade dos resultados, podendo conduzir a valores imprecisos com prejuízo significativo para o sistema elétrico, à medida que a representação das cargas não conduz a realidade do estado de regime permanente (Souza, 2005).

Qualquer carga depende da tensão aplicada e da frequência da tensão de suprimento. Entretanto, no contexto deste trabalho a modelagem da carga será realizada considerando apenas a sua dependência da tensão aplicada. Há vários modelos para representar o comportamento da carga em função da tensão aplicada, dentre os quais se destacam: carga de impedância constante com a tensão, carga de potência constante com a tensão e carga de corrente constante com a tensão. A seguir, são apresentados cada um destes modelos, sendo que, para melhor ilustrar cada um deles será considerando o sistema da figura 2.9.




Figura 2.9. SDR de duas barras

### 2.5.1 Carga de impedância constante com a tensão

O modelo da carga de impedância constante com a tensão possui característica de ter sua impedância invariante independentemente do valor da tensão aplicada, e é obtida a partir da potência ativa e reativa absorvida pela carga quando alimentada com tensão nominal ou de referência. Com isso, quando aplicado tensão nominal sobre a carga da figura 2.9, tem-se que:

assim, a potência absorvida pela carga suprida por tensão nominal resulta para a impedância:

$$\frac{P}{V^2}$$

Então, se for aplicada, por exemplo, uma tensão sobre a carga, o valor da potência absorvida será:

$$\frac{P}{V^2} = \frac{P}{V^2} \quad (2.15)$$

Pode-se observar da equação 2.15 que a impedância permanece constante, e que a potência absorvida varia com o quadrado da tensão aplicada.

### 2.5.2 Carga de potência constante com a tensão

O modelo de carga de potência constante com a tensão possui característica de ter sua potência ativa e reativa invariante, ou seja, independentemente do valor da tensão aplicada os valores de potência são iguais aos valores nominais. Portanto, baseado na figura 2.9 tem-se que a potência absorvida por uma carga monofásica, com tensão nominal, dada pela expressão:

é constante para qualquer valor de tensão.

Então, se for aplicada, por exemplo, uma tensão sobre a carga, o valor da corrente será:

$$I = \frac{P}{V} \quad (2.16)$$

Pode-se observar, pela equação 2.16, que a potência absorvida se mantém constante, e que a corrente absorvida é inversamente proporcional à tensão aplicada.

Para cargas trifásicas equilibradas o equacionamento é idêntico, desde que se considerem as grandezas envolvidas em p.u.

### 2.5.3 Carga de corrente constante com a tensão

Para esta modelagem, as cargas apresentam uma característica de manter os valores da intensidade da corrente e do ângulo de defasagem invariantes, independentemente do valor da tensão aplicado. É importante destacar que para este modelo os valores da intensidade de corrente e ângulo de defasagem são aqueles obtidos com a carga suprida por tensão nominal. Assim, quando aplicada uma tensão nominal sobre a carga da figura 2.9, a potência absorvida vale:

Portanto, a corrente absorvida por essa carga é nesta circunstância é:

$$I = \frac{P}{\sqrt{3} V \cos \theta}$$

Agora, quando se aplica uma tensão qualquer sobre a carga, o valor da corrente será:

Ou seja, o módulo da corrente e o ângulo de defasagem permanecem constantes, e a potência absorvida é dada por:

Conclui-se que a potência absorvida pela carga varia linearmente com a tensão aplicada.

Quando o estudo de fluxo de carga é realizado assumindo-se carga modelada por corrente constante com a tensão, o processo de solução torna-se direto, isto é, sem iteração. Isto ocorre quando se despreza a rotação de fase da tensão, que permite o cálculo da queda de tensão, nos trechos dos alimentadores, através de números reais. O fluxo de carga assumindo-se carga modelada por corrente constante com a tensão será iterativo quando se considera a rotação de fase da tensão. Nessa situação, realiza-se o cálculo da queda de tensão, nos trechos dos alimentadores, através de números complexos (representação complexa da rede).

Importa destacar que estudos demonstram que os resultados obtidos através da solução direta, que se baseia em aproximações, estão muito próximos aos valores exatos.

## 2.6 Conclusão

Dentre os vários conceitos apresentados neste capítulo, destacam-se os métodos para cálculo de fluxo de carga e os para modelos de carga. Dentre os dois métodos de fluxo de carga apresentados, será utilizado neste trabalho o método de soma de correntes. E dentre as três modelagens de corrente citadas, será utilizada a modelagem por carga de corrente constante com a tensão (seção 4.3 e 4.4).

Apresentados estes conceitos, que são importantes no desenvolvimento de uma metodologia para reconfiguração de redes em SDRs, no próximo capítulo será apresentada a formulação matemática para este problema. O desenvolvimento desta formulação será de suma importância, pois determinará as funções e restrições que devem ser levadas em conta no estudo e aplicação de um programa computacional eficiente para reconfiguração de redes para restabelecimento de energia, que é o objetivo último deste trabalho. Notar que no próximo capítulo far-se-á uso da representação de SDRs por meio de grafos, para ilustração do problema de reconfiguração.

### **3 O problema de reconfiguração de redes em SDR**

Para estudo e escrita deste capítulo foi tomado como base o capítulo 3 de Santos (2009). O objetivo deste capítulo é apresentar o problema de reconfiguração de redes de energia e uma formulação matemática geral que modela o problema de restabelecimento, redução de perdas e planejamento de expansão do sistema, entre outras finalidades.

Antes de rever esta formulação, será retomada a teoria de grafos exposta no capítulo 2, aplicada aqui à representação do problema de reconfiguração a fim de ilustrar o que será formulado em seguida.

#### **3.1 Exemplo de reconfiguração de redes para restabelecimento de energia**

Considere a representação em grafo de uma rede na figura 3.1. Esta rede é semelhante à rede da figura 2.5, porém, naquele caso, a rede tinha 3 alimentadores, e, neste caso, a rede apresenta 4 alimentadores. As barras 1, 2, 3 e 4 encontram-se na subestação, as demais barras representam as cargas, as linhas contínuas representam chaves NF e as linhas tracejadas chaves NA. Há uma falta no setor 14, logo este setor deverá ser isolado do restante do sistema. Este procedimento pode ser realizado pela abertura das chaves A e B. Se estas duas chaves forem abertas, os setores 15, 16 e 17 também ficarão isolados do sistema e sofrerem falta de energia. Esta situação pode ser observada na figura 3.2, onde a área sombreada representa a área com falta de fornecimento de energia.

O problema de reconfiguração de redes para restabelecimento de energia visa justamente situações como esta. O objetivo é encontrar a melhor reconfiguração possível, a fim de que estes setores possam ter o serviço restabelecido, sem violar as restrições operacionais do sistema. É necessário, então, encontrar outro caminho para alimentar os setores sadios (sem falta) sem fornecimento. Para este exemplo, existem três caminhos possíveis para restaurar o fornecimento nos setores 15, 16 e 17. São eles:

1. Fechar a chave C, conectando a área fora de serviço ao alimentador 1.

2. Fechar a chave D, conectando a área fora de serviço ao alimentador 3.
3. Fechar a chave E, conectando a área fora de serviço ao alimentador 4.




Figura 3.1. Representação em grafo de um SDR em falta




Figura 3.2. Detalhe da área isolada com a abertura das chaves A e B

A figura 3.3 apresenta a rede em falta da figura 3.2 reconfigurada, a partir do fechamento da chave E. Notar que foi restabelecido o fornecimento de energia para a área que se encontrava fora de serviço, mantendo apenas o setor 14, em falta, isolado do restante do sistema.




Figura 3.3. Rede reconfigurada pelo fechamento da chave E

Após o isolamento da zona em falta, e o restabelecimento no fornecimento da área que se encontrava fora de serviço, as seguintes restrições devem ser satisfeitas:

1. A estrutura radial deve permanecer após o serviço de restabelecimento;
2. Áreas à jusante do setor em falta (que ficaram fora de serviço) devem ser atendidas quando possível;
3. O montante de carga de cada alimentador do sistema não deve exceder a capacidade limite da subestação;
4. A corrente elétrica em cada ramo não deve ultrapassar a capacidade das linhas e chaves;
5. A queda de tensão em qualquer barra do SDR não deve exceder o limite permissível.

Geralmente, além da busca por configurações que minimize a área fora de serviço, outros dois objetivos são acrescentados ao problema:

1. Minimizar o total de perdas de potência;
2. Minimizar o número de chaveamentos.

A partir destes objetivos e restrições tem-se condições de propor uma formulação matemática para o problema.

### 3.2 Formulação matemática

Uma formulação geral para problemas de reconfiguração de redes de distribuição pode ser feita considerando juntos todos os objetivos e restrições envolvidos. Conforme apresentado, os três objetivos principais são: minimizar as áreas fora de serviço, o número de chaveamentos e o total de perdas de potência resistivas. Além disso, o problema deve respeitar as cinco restrições listadas anteriormente.

Assim, um problema de reconfiguração em redes de SDRs pode ser formulado, de uma forma geral, como segue:

$$(1)$$

onde,

- $F$  – grafo correspondente a uma configuração do sistema, representado por um floresta de grafo, onde cada árvore dessa floresta corresponde a um alimentador conectado a uma subestação;
- $E(F)$  – função objetivo.
- $H(F)$  – restrições de igualdade, representando as equações de fluxo de carga;
- $I(F)$  – restrições de desigualdade, representando as restrições operacionais da rede.

A função objetivo,  $E(F)$ , contém um ou mais dos seguintes componentes:

- $\Phi(F)$  – número de barras com cargas fora de serviço para um topologia de rede radial (uma floresta  $F$ );
- $\varphi(F)$  – perdas de potência no sistema para  $F$ ;
- $\Psi(F, F_0)$  – número de operações de chaveamentos requerido para obter uma dada configuração  $F$ , a partir da configuração original  $F_0$ .

As restrições de igualdade correspondem às equações de fluxo de carga, que podem ser representadas como um sistema linear do tipo  $Ax = B$ , onde:

- $A$  – matriz de incidência de  $F$ ;
- $x$  – vetor de corrente de linha;
- $B$  – vetor contendo as correntes de carga nas barras ou as correntes injetadas nas subestações.

As restrições operacionais  $I(F)$  em problemas de reconfiguração de sistemas de distribuição geralmente incluem:



- Limitante superior de corrente para cada corrente de linha . A maior taxa é denominada de carregamento da rede;
- Máxima injeção de corrente em cada subestação, onde significa a subestação . A maior taxa é denominada carregamento da subestação;
- Limitante inferior para a tensão no nó . Seja a tensão na barra e, a tensão base do sistema. A maior taxa é denominada taxa de tensão.

O vetor de tensão é dado por , onde  $Y$  é a matriz de admitância nodal, que pode ser calculada por meio da expressão , sendo a matriz admitância diagonal.

Em problemas de reconfiguração, em virtude de a função objetivo ser geralmente não linear, descontínua e apresentar vários ótimos locais, a utilização de programação matemática (PM) torna-se inviável para resolução destes problemas. Entretanto, quando AEs são utilizados para resolução de problemas deste tipo, são necessárias algumas modificações na formulação apresentada em (1). São aplicados fatores de penalidades, a fim de penalizar configurações de rede que violem as restrições operacionais  $I(F)$ . Assim, o problema é formulado como se segue:

(2)

onde  $\Omega$  é a matriz diagonal com os seguintes elementos:

–

os pesos , e são valores positivos e,  $|\cdot|$  é a norma usual (Gradshteyn & Ryzhik 2000), isto é a norma de um vetor de tamanho é dada por .

A fim de verificar se uma dada configuração atende às restrições operacionais  $I(F)$ , é necessário a execução de um fluxo de carga, que deve ser computacionalmente eficiente, visto a grande quantidade de configurações que devem ser analisadas em busca da configuração “ótima”. Para tanto, é necessária a utilização de uma estrutura de dados computacionalmente eficiente, para representação de SDRs, além de um algoritmo eficiente para cálculo de fluxo de carga. É importante destacar que para facilitar o cálculo do fluxo de carga, em problemas de reconfiguração, pode-se modelar

as cargas como cargas de corrente constante, e empregar os métodos, já vistos, de cálculo de fluxo de carga de varredura direta/inversa.

Conforme visto no capítulo 2, dentre os métodos de cálculo de fluxo de carga de varredura direta/inversa, o método de soma de correntes se destaca para este tipo de problemas. Para aplicar esse método, as barras da rede devem estar ordenadas segundo o MPF. Assim, pode-se calcular o fluxo de corrente partindo dos nós extremos em direção à subestação, e, ao mesmo tempo, calcular as tensões partindo da subestação e partindo para os nós extremos.

Fazendo uso da RNP, que possui operadores genéticos que produzem exclusivamente configurações factíveis (conforme definido no capítulo 1 são redes radiais capazes de fornecer energia para todas as partes re-conectáveis do sistema), é possível formular o problema descrito em (2) da seguinte forma (Santos et al, 2010):

(3)

Utilizando a RNP, que será apresentada com detalhes no capítulo 4, evita-se o uso de um algoritmo de busca para obter o MPF, pois a RNP, naturalmente, já garante esta ordenação, tornando o fluxo de carga mais eficiente que os fluxos de carga convencionais para SDRs. Além disso, o uso do MPF garante que as restrições de igualdade ( $H(F)$ ) em (3) sejam satisfeitas. Assim, levando em consideração o fato da RNP já possuir os nós ordenados segundo o MPF, o problema genérico de reconfiguração de redes pode ser reescrito da seguinte forma:

(4)

Ao comparar a equação (4) com a (1), constata-se que a utilização da RNP e seus operadores, juntamente com um fluxo e carga pelo MPF com RNP, tornaram a modelagem matemática do problema mais simples. Também merece destaque o fato de a RNP e seus operadores sempre gerarem configurações factíveis, o que possibilita utilizar somente as restrições de queda de tensão, carregamento na rede e carregamento das subestações na formulação do problema.

### 3.3 Conclusão

Neste capítulo foram apresentados detalhes do problema de reconfiguração de redes, a partir da representação por grafos, e uma formulação matemática genérica para o problema. A formulação do problema utilizando as informações da RNP com MPF e conectividade da rede para produção de configurações em árvores, reduz o tempo de processamento pela produção exclusiva de configurações factíveis e pela avaliação relativamente rápida de cada configuração por um fluxo de carga mais eficiente. Outra vantagem que merece destaque, é que fazendo uso da RNP e de seus operadores são geradas somente configurações em árvores, dispensando o uso de uma rotina para verificação e correção de possíveis configurações com ciclo ou desconexas, o que contribuiria para diminuição da eficiência computacional. Dentre as formulações apresentadas, a final (equação (4)) é a mais eficiente do ponto de vista computacional e foi proposta em Santos et al. (2010) para desenvolvimento do reconfigurador de redes para restabelecimento de energia que será utilizado neste trabalho. No próximo capítulo serão explorados os conceitos da RNP e de seus operadores, assim como será apresentada a metodologia que faz uso da formulação proposta neste capítulo, e dos conceitos de AEs Multi-Objetivos (AEMOs).



## 4 Metodologia eficiente para reconfiguração de redes em SDRs

O programa computacional que será utilizado neste trabalho consiste da implementação da metodologia, para tratamento do problema de restabelecimento de energia, proposta em (Santos et al., 2010) denominada MEAN. Conforme mencionado anteriormente, essa metodologia faz uso de um AEMO e da estrutura de dados RNP para representar a topologia elétrica dos SDRs.

Neste capítulo será apresentada a fundamentação teórica da metodologia MEAN, desde a definição da estrutura de dados RNP, seus operadores, até o AEMO em tabelas.

Para melhor compreensão deste capítulo também poderá ser consultado o Apêndice A, que expõe a teoria básica de AEs convencionais AEMOs. Para estudo e escrita deste capítulo foram utilizados como base: Santos (2009) e Santos et. al. (2010).

### 4.1 Fundamentos da RNP

Um sistema de distribuição pode ser visto como um conjunto de alimentadores, sendo cada alimentador composto por um ou mais setores. Considere, por exemplo, a figura 2.5. Ela apresenta uma floresta com três árvores. Os nós 1, 2 e 3 são as raízes das árvores 1, 2 e 3, respectivamente. Esse grafo pode ser visto como um sistema de distribuição com 3 alimentadores, onde os nós são setores e as arestas chaves seccionadoras, sendo que as arestas em linha contínua representam chaves NF e as arestas em linhas tracejadas representam chaves NA. Os nós 1, 2 e 3 podem estar ligados ao barramento de uma mesma subestação, ou a subestações distintas.

A RNP, proposta por Delbem et. al. (2004), baseia-se nos conceitos de caminho e de profundidade do nó em um grafo acíclico e conexo (árvore). Basicamente a RNP é composta por uma lista linear contendo os nós da árvore e suas respectivas profundidades, formando pares do tipo  $(n_x, p_x)$ , onde  $n_x$  é o nó e  $p_x$  a profundidade. A profundidade de um nó num grafo é igual à distância deste nó até o nó raiz do grafo, sendo que esta distância é contada pelo número de nós existentes entre o nó considerado e o nó raiz. A ordem em que os pares estão dispostos na lista linear é importante.

Computacionalmente, esta lista é formada por uma matriz de dimensão  $2 \times n$ , sendo  $n$  o número de nós. Os pares  $p_x$  e  $n_x$  são armazenados na primeira e segunda linha, respectivamente, conforme ilustrado na figura 4.1 (para este caso é considerado o grafo da figura 2.5). Para armazenar um nó e a respectiva profundidade na RNP, utiliza-se um algoritmo de busca em profundidade. Portanto, o processo se inicia a partir do nó raiz da árvore, produzindo uma lista contendo os respectivos nós e sua profundidade em uma sequência apropriada, enquanto um nó  $n_x$  é visitado.

$$T_1 = \begin{bmatrix} \text{Profundidade} \\ \text{Nó} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 2 & 3 & 2 & 3 & 4 & 3 & 4 & 4 \\ 1 & 4 & 5 & 6 & 10 & 11 & 12 & 16 & 22 & 23 \end{bmatrix}$$

$$T_2 = \begin{bmatrix} \text{Profundidade} \\ \text{Nó} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 2 & 3 & 3 & 2 & 3 \\ 2 & 9 & 8 & 7 & 13 & 15 & 14 \end{bmatrix}$$

$$T_3 = \begin{bmatrix} \text{Profundidade} \\ \text{Nó} \end{bmatrix} = \begin{bmatrix} 0 & 1 & 2 & 3 & 4 & 3 & 4 & 5 & 2 & 3 \\ 3 & 27 & 26 & 25 & 24 & 19 & 18 & 17 & 21 & 20 \end{bmatrix}$$

Figura 4.1. RNP para as três árvores da figura 2.5

Uma alternativa interessante para implantação computacional da RNP é a utilização de listas encadeadas (Marquez, 2012). Esta alternativa facilita tanto na construção de representações (visto que a quantidade de elementos que serão gerados é desconhecida), quanto nas operações de corte e inserção de elementos nas árvores de grafo representadas nas RNPs. Para representar uma floresta possuindo ( $N_a$ ) árvores, tem-se um conjunto de ( $N_a$ ) RNPs. A codificação proposta para uma floresta é composta pela união da codificação de todas as árvores desta floresta. Assim, a estrutura de dados de uma floresta pode ser facilmente implementada usando *arrays* de ponteiros, onde cada ponteiro indica a RNP de uma árvore.

## 4.2 Operadores da RNP

Nesta seção serão apresentados dois operadores que geram novas florestas utilizando a RNP. Ambos geram uma  $F'$  de um grafo  $G$ , quando aplicados a uma floresta  $F$  do mesmo grafo  $G$ . Apesar de operarem de maneiras distintas, os resultados apresentados por cada um são similares. Em Delbem et al. (2004) estes operadores receberam o nome de operador **PAO** (do inglês, *Preserve Ancestor Operator*) e **CAO** (do inglês, *Change Ancestor Operator*).

Considere uma floresta com duas árvores ou mais. Ao aplicar o operador PAO (ou CAO) a esta floresta, uma subárvore de uma árvore  $T_{de}$  é transferida para uma outra

árvore  $T_{para}$  da floresta. Na aplicação do operador PAO, a raiz da subárvore cortada de  $T_{de}$  será também a raiz dessa subárvore na árvore  $T_{para}$ . Já para o operador CAO, a subárvore cortada terá um novo nó raiz que poderá ser qualquer nó da subárvore cortada, diferente da raiz original. Essa é a diferença básica entre os dois operadores.

O operador PAO pode produzir mudanças simples e pequenas nas árvores da floresta, enquanto que o operador CAO pode gerar alterações mais complexas.

O operador PAO requer um conjunto de dois nós previamente determinados: um nó de poda  $p$  que indica a raiz da subárvore a ser transferida e o nó adjacente  $a$ , que é um nó em uma árvore diferente da árvore cortada ( $T_{de}$ ) também adjacente a  $p$  em  $G$ . Os nós adjacentes a  $p$  podem ser armazenados em uma lista de adjacência. A tabela 4.1 apresenta a lista de adjacências para o grafo da figura 2.5.

Tabela 4.1. Lista de adjacências para os nós do grafo da figura 2.5

<b>Nó</b>	<b>Adjacentes</b>				
<b>1</b>	4				
<b>2</b>	9				
<b>3</b>	27				
<b>4</b>	1	5	10		
<b>5</b>	4	6	11		
<b>6</b>	5	7	12		
<b>7</b>	6	8	13		
<b>8</b>	7	9	13	14	
<b>9</b>	2	8	15		
<b>10</b>	4	11	16		
<b>11</b>	5	10	12	17	
<b>12</b>	6	11	13	18	
<b>13</b>	7	8	12	14	19
<b>14</b>	8	13	15	20	
<b>15</b>	9	14	21		
<b>16</b>	10	17	22	23	
<b>17</b>	11	16	18	23	
<b>18</b>	12	17	19	24	
<b>19</b>	13	18	20	25	26
<b>20</b>	14	19	21	26	
<b>21</b>	15	20	27		
<b>22</b>	16	23			
<b>23</b>	16	17	22	24	
<b>24</b>	18	23	25		
<b>25</b>	19	24	26		
<b>26</b>	19	20	25	27	
<b>27</b>	3	21	26		

O operador CAO requer um conjunto de três nós previamente determinados: o nó de poda, o nó de adjacência e o novo nó raiz da subárvore a ser transferida. O funcionamento dos operadores PAO e CAO será descrito em mais detalhes nos itens 4.2.1 e 4.2.2.

### 4.2.1 Operador PAO

Ao se aplicar o operador PAO na geração de uma nova floresta  $F'$  de um grafo  $G$ , a partir de uma floresta  $F$  de  $G$ , uma subárvore de uma árvore  $T_{de}$  é transferida para  $T_{para}$  da mesma floresta. Para este operador a raiz da subárvore cortada também será a raiz da subárvore na nova árvore  $T_{para}$ .

Considerando que os nós  $p$  e  $a$  foram determinados previamente, e que a RNP foi desenvolvida utilizando um vetor, os índices de  $p$  ( $i_p$ ) e de  $a$  ( $i_a$ ), nos vetores  $T_{de}$  e  $T_{para}$ , respectivamente, são conhecidos. Para ilustrar a aplicação deste operador, foram selecionadas as árvores  $T_1$  e  $T_3$ , do grafo da figura 2.5, como as árvores  $T_{de}$  e  $T_{para}$ , respectivamente. Os nós  $p$  e  $a$  são, respectivamente, 11 e 17. O operador PAO pode ser descrito pelos seguintes passos:

1. Determinam-se as posições ( $ip-iu$ ) dos índices de  $T_{de}$  correspondente à subárvore que contém o nó  $p$  como raiz. Como  $i_p$  é conhecido, é necessário encontrar apenas  $i_u$ , que corresponde ao índice do último nó na subárvore que tem o nó  $p$  como raiz. O conjunto ( $ip - iu$ ) corresponde ao nó  $p$  em  $i_p$  e aos consecutivos nós  $x$  no vetor  $T_{de}$  de forma que  $i_x > i_p$  e  $p_x > p_p$  (retângulo tracejado da figura 4.2), onde  $p_x$  é a profundidade do nó  $x$  e  $p_p$  a profundidade do nó  $p$ ;
2. Copiam-se os dados do conjunto ( $ip-iu$ ) de  $T_{de}$  em um vetor temporário  $T_{tmp}$  (subárvore que está sendo transferida), ver figura 4.3. A profundidade de cada nó  $x$  do conjunto ( $ip-iu$ ) é atualizada da seguinte maneira:
 
$$p_x = p_x - p_p + p_a + 1.$$
3. Cria-se um vetor  $T'_{para}$  contendo os dados de  $T_{para}$  e  $T_{tmp}$ , inserindo  $T_{tmp}$  a partir da posição  $i_a$ , ver figura 4.5.
4. Constrói-se um vetor  $T'_{de}$  compreendendo os nós de  $T_{de}$  sem os nós de  $T_{tmp}$ , ver figura 4.4.
5. Por fim, copia-se a estrutura de ponteiros da floresta  $F$  para  $F'$  trocando os ponteiros para os arrays  $T_{de}$  e  $T_{para}$  por ponteiros para os arrays  $T'_{de}$  e  $T'_{para}$ , respectivamente.

As figuras 4.2 a 4.5 apresentam a aplicação dos passos acima para o grafo da figura 2.5, considerando os nós de poda e adjacência apontados previamente como escolhidos para esta ilustração.






Figura 4.2.  $T_{de}$  e  $T_{para}$  e suas respectivas RNPs




Figura 4.3.  $T_{imp}$  e sua RNP




Figura 4.4.  $T'_{de}$  e sua RNP




Figura 4.5.  $T'_{para}$  e sua RNP

#### 4.2.2 Operador CAO

Ao se aplicar o operador CAO na geração de uma nova floresta  $F'$  de um grafo  $G$ , a partir de uma floresta  $F$  de  $G$ , uma subárvore de uma árvore  $T_{de}$  com uma nova raiz é transferida para outra árvore  $T_{para}$  da mesma floresta. A nova raiz pode ser qualquer nó da subárvore diferente da raiz original.

A descrição do operador CAO assume que um conjunto de nós seja previamente determinado: o nó de poda  $p$ , o novo nó raiz  $r$  e o nó adjacente  $a$ . Os nós  $p$  e  $r$  pertencem à árvore  $T_{de}$  e o nó  $a$  pertence à  $T_{para}$ . As diferenças entre os dois operadores, PAO e CAO, estão nos passos 2 e 3 do procedimento adotado para o operador PAO (ver seção 4.2.1), isto é, a formação da subárvore cortada e o armazenamento da mesma na *array* temporária  $T_{tmp}$  são diferentes.

O procedimento adotado para cópia de uma subárvore utilizando o operador CAO pode ser descrito pelos seguintes passos:

1. Similar ao passo 2 do operador PAO, entretanto, no operador CAO, troca-se o índice  $i_p$  por  $i_r$ .
2. Consideram-se os nós no caminho de  $r$  até  $p$ , isto é,  $r_0, r_1, r_2, \dots, r_n$ , onde  $r_0 = r$  e  $r_n = p$ , como raízes das subárvores (retângulo tracejado na figura 4.6). O algoritmo para o segundo passo deverá copiar a subárvore com a raiz  $r_i$  ( $i = 1, \dots, n$ ), sem a subárvore com a raiz  $r_{i-1}$ , (figura 4.7) e armazenar a subárvore resultante em um *array* temporário  $T_{tmp}$ , ver figura 4.8. O operador CAO utiliza os *arrays* temporários,  $T_{tmp}$ , para construir  $T'_{para}$ .

Segue uma ilustração do procedimento descrito anteriormente. Para esta ilustração, utilizou-se as mesmas árvores  $T_{de}$  e  $T_{para}$  que foram utilizadas para o operador PAO. Os nós  $p$  e  $r$  são 10 e 16, respectivamente. As profundidades na figura 4.7 e na figura 4.8 são relativas ao sorteio do nó 17 como adjacente.




Figura 4.6.  $T_{de}$  e sua RNPFigura 4.7. Subárvores enraizadas nos nós do caminho  $r$  a  $p$ 

Figura 4.8. RNP da subárvore podada



Ao agrupar as barras e linhas não separadas por chaves da figura 4.10 (ver figura 4.11), tem-se um grafo em que todas as arestas são chaves seccionadoras. Ver figura 4.12.




Figura 4.11. Agrupamento das barras e linhas em setores




Figura 4.12. Grafo representando setores do SDR da figura 4.11

Assim, nota-se que a figura 4.12 apresenta duas RNPs, uma para o alimentador 1 (em vermelho) e outra para o alimentador 2 (em preto), denominadas RNPs do alimentador. As arestas em vermelho e preto são chaves seccionadoras NF e a aresta em verde é uma chave aberta. Assim, tem-se a estrutura  $T_1$  que armazena o endereço de memória da RNP do alimentador 1 e a estrutura  $T_2$  que armazena o endereço de memória do alimentador 2.

A partir da figura 4.11 é também possível associar RNPs aos setores. Em outras palavras, cada trecho de linhas e barras não separadas por chaves pode ser analisado como uma árvore de grafo. Cada setor pode ter mais de um nó raiz, dependendo do sentido em que está sendo alimentado. Assim, pode haver mais de uma árvore representando cada setor. Para a finalidade de fluxo de carga, acrescenta-se a cada uma dessas árvores, o nó adjacente ao seu nó raiz. Para o acréscimo do nó adequado, pode-se utilizar a seguinte regra: todo nó  $i$  adjacente a um nó  $x$ , tal que  $i$  pertença a um setor diferente do setor de  $x$ , sendo  $x$  raiz, é acrescentado à árvore correspondente ao

setor de  $x$ . Exceções ocorrem para os nós em uma subestação, que possuem somente um setor vizinho. A tabela 4.2 mostra as árvores geradas a partir da figura 4.11, acrescentando os nós adjacentes.

A RNP do setor pode ser representada computacionalmente de forma semelhante a RNP do alimentador, onde as árvores foram armazenadas em estruturas denotadas por  $T_i$ . Para RNP do setor, denotar-se-á por  $B_{sr}$ , onde  $s$  representa o setor em análise e  $r$  refere-se ao setor pelo qual a energia chega ao setor  $s$ , setor pai. Para um mesmo setor  $s$  podem existir mais de uma RNP conforme mostra a tabela 4.3.

Como exemplo, considere o setor D da figura 4.12. Fluxo de corrente pode chegar ao setor D por dois caminhos diferentes, através do setor B ou do setor H. Logo, pelo setor B, tem-se  $B_{sr} = B_{DB}$  e para o setor H, tem-se  $B_{sr} = B_{HB}$ . As estruturas que armazenam as RNPs possíveis para o setor D são mostradas a seguir:

A análise da RNP do alimentador informa qual das configurações acima deve ser utilizada. Através da RNP do alimentador 1, nota-se que o setor D está conectado ao setor B. Portanto, no exemplo acima, o  $r$  correto é o setor **B**, conforme RNP abaixo.

Tabela 4.2. Árvores dos setores com o nó adicional

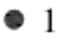

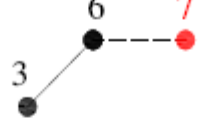
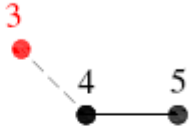
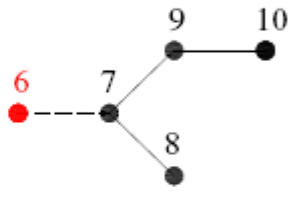
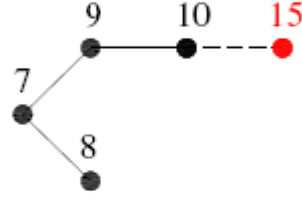


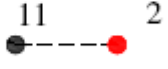
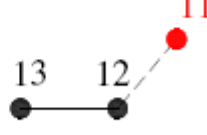
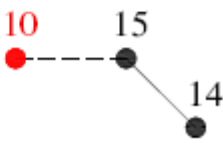
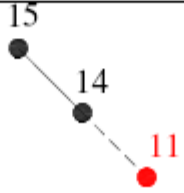
Setor	Árvores	
A		
B		
C		
D		
E		
F		
G		
H		
<p>● Nó    — Aresta    ●----- Aresta e nó adicional</p>		

Tabela 4.3. RNPs dos setores mostrados na tabela 4.2

Setor	RNPs do Setor	
A	0 1	
B	0 1 2 1 3 6	0 1 2 7 6 3
C	0 1 2 3 4 5	
D	0 1 2 2 3 6 7 8 9 10	0 1 2 3 4 15 10 9 7 8
E	0 2	
F	0 1 14 11	0 1 2 11
G	0 1 2 11 12 13	
H	0 1 2 10 15 14	0 1 2 11 14 15

Deve-se observar que a determinação de todas as RNPs de cada setor pode ser executada por um procedimento *off-line*, deixando todos os cálculos prontos para serem utilizados pelo fluxo de carga *on-line*.

#### 4.4 Fluxo de carga de varredura direta/inversa com RNP

Devido às características específicas dos SDRs utilizadas neste projeto (rede puramente radial e com as barras armazenadas na RNP segundo o MPF) e à necessidade de encontrar configurações adequadas em curto tempo de processamento, o aplicativo computacional proposto faz uso do modelo de corrente constante para cálculo de fluxo de carga. Será utilizado fluxo de carga de varredura direta/inversa soma de correntes.



É importante ressaltar que, por utilizar método de corrente constante, as linhas de rede serão representadas por uma impedância constante  $Z_{mn}$  para cada linha entre as barras  $m$  e  $n$ . O cálculo das tensões nas barras é realizado através da diferença de tensão da barra anterior e a queda de tensão no trecho entre a barra anterior e a barra atual ( $V(m) - \Delta V$ ).

O algoritmo para cálculo de fluxo de carga finaliza seu ciclo após a execução de duas sub-rotinas: uma obtém as correntes à jusante por meio de varredura inversa, para todas as barras do alimentador (CORRENTES, ver Algoritmo 1) e a outra utiliza as correntes à jusante para obter as tensões nas barras do mesmo alimentador, utilizando a varredura direta (TENSÕES, Algoritmo 2). Com o modelo de corrente constante, a convergência é atingida em um único ciclo, diferindo de vários modelos usuais de varredura direta/inversa (Srinivas 2000), (Shirmohammadi et al. 1988) e (D. Das et al. 1994).

Conforme descrito anteriormente, a sub-rotina “CORRENTES” utiliza a varredura inversa, ou seja, realiza do seu caminho partindo das barras terminais do sistema até a barra raiz da subestação. Vale destacar ainda que a RNP já impõe esta ordem de maneira natural aos seus elementos. A carga de uma barra  $m$  é denominada  $I_m$  e a corrente à jusante dessa barra é denominada  $J_m$ .

---

**Algoritmo 1:** Pseudocódigo para calcular a corrente a jusante de uma barra (Santos, 2009)

---

### **CORRENTES**

- 1: **PARA**  $k =$  última posição em  $T$ , **ATÉ**  $k = 1$ , **FAÇA**:
  - 2:      $u =$  próxima posição em que a profundidade do nó seja  $(T.\text{prof}(k) - 1)$ ;
  - 3:      $s = T.\text{nó}(k)$ ;
  - 4:      $r = T.\text{nó}(u)$ ;
  - 5:      $J(T) = 0$ ;
  - 6:     **PARA**  $q =$  última posição em  $B_{sr}$ , **ATÉ**  $q = 1$ , **FAÇA**:
  - 7:          $p =$  próxima posição em que a profundidade do nó seja  $(B_{sr}.\text{prof}(q) - 1)$ ;
  - 8:          $m = B_{sr}.\text{nó}(p)$ ;
  - 9:          $n = B_{sr}.\text{nó}(q)$ ;
  - 10:         corrente\_acumulada =  $J(n) + I(n)$
  - 11:          $J(m) = J(m) +$  corrente\_acumulada
  - 12:     **FIM**
  - 13: **FIM**
-

Notar que na linha 5 da sub-rotina CORRENTES atribui-se zero à variável  $J(T)$ . Com isso a corrente a jusante em todas as barras em T recebem zero.

A rotina TENSÕES é apresentada no algoritmo 2. Novamente a ordem em que os nós serão visitados está previamente determinada nas RNPs do alimentador e do setor. As tensões serão obtidas partindo da barra raiz em direção às barras terminais. O algoritmo TENSÕES necessita que as correntes à jusante de tenham sido obtidas previamente pela rotina CORRENTES. Assim, para obter as tensões em cada barra é necessária a corrente na barra  $l_n$ , a tensão à montante da barra  $n$  ( $V_m$ ) e a impedância  $Z_{mn}$  entre as barras  $m$  e  $n$ .

Na rotina TENSÕES, a variável  $V_{sub}$  representa a tensão na barra da subestação e a variável  $\Delta V$  a queda de tensão na rede entre as barras  $m$  e  $n$ .

---

**Algoritmo 2:** Pseudocódigo para calcular as tensões nas barras (Santos, 2009)

---

**TENSÕES**

- 1: **PARA**  $k = 1$ , **ATÉ**  $k =$  última posição em  $T$ , **FAÇA**:
  - 2:      $u =$  próxima posição em que a profundidade do nó seja  $(T.\text{prof}(k) - 1)$ ;
  - 3:      $s = T.\text{nó}(k)$ ;
  - 4:      $r = T.\text{nó}(u)$ ;
  - 5:      $B_{sr}.\text{nó}(0) = V_{sub}$ ;
  - 6:     **PARA**  $q = 1$ , **ATÉ**  $q =$  última posição em  $B_{sr}$ , **FAÇA**:
  - 7:          $p =$  próxima posição em que a profundidade do nó seja  $(B_{sr}.\text{prof}(q) - 1)$ ;
  - 8:          $m = B_{sr}.\text{nó}(p)$ ;
  - 9:          $n = B_{sr}.\text{nó}(q)$ ;
  - 10:          $\Delta V = Z_{mn} \cdot (J(n) + I(n))$
  - 11:          $V(n) = V(m) - \Delta V$  // tensão na barra  $n$
  - 12:     **FIM**
  - 13: **FIM**
- 

Por fim, o algoritmo 3 apresenta a rotina principal do fluxo de carga utilizando a RNP. Como os operadores PAO e CAO modificam pares de árvores de uma floresta, para cada nova floresta, apenas dois alimentadores serão alterados. Assim, as sub-rotinas TENSÕES e CORRENTES são aplicadas somente a esses alimentadores, pois o fluxo de carga para os outros alimentadores não se altera (Santos, 2009). As sub-rotinas TENSÕES e CORRENTES são executadas para cada estrutura  $T_i$  (indicada por um ponteiro) de  $F$ .

---

**Algoritmo 3:**Pseudocódigo para determinar o fluxo de carga em SDR (Santos, 2009)

---

**ALGORITMO PRINCIPAL**

- 1: **PARA**  $i = 0$ , **ATÉ**  $i =$  número de ponteiros em  $F$ , **FAÇA**:
  - 2:     *CORRENTES* ( $F \rightarrow T_i$ );
  - 3:     *TENSÕES* ( $F \rightarrow T_i$ );
  - 4: **FIM**
- 

#### 4.5 Cálculo do número de manobras

Há, basicamente, dois procedimentos utilizados para verificar a adequação de uma determinada configuração gerada pela aplicação dos Operadores PAO ou CAO, são eles: execução do fluxo de carga (ver seção 4.4) e cálculo do número de manobras. Sendo assim, o cálculo do número de manobras, voltado para avaliação das configurações geradas, é um parâmetro importante a ser considerado na resolução de problemas de reconfiguração de redes para restabelecimento de energia.

Em geral, o número de manobras é determinado a partir de comparações entre vetores binários que guardam o estado das chaves (de forma binária) para cada configuração (atual e proposta). Assim, para obter o número de manobras necessárias para gerar uma nova configuração, compara-se o vetor de estados das chaves nesta nova configuração com o vetor de estados das chaves na configuração inicial. O processo, entretanto, envolve custo computacional relativamente alto, visto que a cada configuração gerada, é necessário criar um vetor com o estado atual das chaves e realizar a comparação com o vetor da configuração inicial. Como esses vetores têm o comprimento igual ao número de chaves ( $m$ ) no sistema, o tempo para percorrê-lo uma vez é maior que o tempo de realizar uma modificação no sistema pelos operadores PAO e CAO, que requerem tempo de computação da ordem do tamanho dos alimentadores envolvidos, em geral, bem menor que  $m$  (Santos, 2009).

Com vistas a melhorar o desempenho computacional, Santos et al. (2010) apresenta um algoritmo que determina o número de manobras de forma mais eficiente. É proposta uma formulação que faz uso de apenas dois vetores: um que guarda o estado das chaves na configuração inicial e outro, de tamanho  $g_{max}$ , que guarda a quantidade de chaves alteradas em relação à configuração inicial, sendo  $g_{max}$  o número máximo de gerações.

Quando uma falta ocorre, o procedimento de isolar o setor em falta e conectar os setores à jusante do mesmo SDR exige manobras de chaves que nem sempre ocorrem aos pares. Para ilustrar este conceito, considere a figura 4.13, que é uma reprodução da

figura 3.1, em que o setor 14 sofreu uma falta. O primeiro procedimento é isolar o setor em falta que, para este caso, pode ser feito abrindo-se as chaves A e B (2 manobras). Porém, ao realizar esta manobra, os setores 15, 16 e 17 ficam desconectados do restante do sistema. Para reconectá-los é necessário fechar uma chave que os conecte a algum alimentador, esta manobra pode ser realizada pelo fechamento das chaves C, D ou E (1 manobra de chave). Portanto, para esta primeira alteração de topologia da rede, 3 manobras foram necessárias.




Figura 4.13. Operações necessárias para manter o setor em falta

Após o procedimento descrito anteriormente, as alterações nas chaves que resultarão em mudanças na configuração sempre ocorrerão aos pares, ou seja, quando uma chave é aberta, outra será fechada. Para determinar o número de manobras para originar uma dada configuração, considere o estado das chaves em três configurações específicas: configuração inicial ( $o$ ), configuração alterada durante a etapa para isolamento do trecho defeituoso e recomposição dos demais ( $x$ ) e configuração final ( $y$ ). Dessa forma, considerando que uma configuração  $y$  originou-se de alterações na configuração  $x$ , há três possibilidades para computar o número de chaves alteradas da configuração  $y$  (Santos, 2009):

1. Os estados das duas chaves alteradas em  $y$ , em relação a  $x$ , são diferentes dos estados dessas chaves em  $o$ . Portanto, o número de chaves alteradas de  $y$  será o número de chaves alteradas de  $x$  mais 2. Considere que as chaves 1 e 4 da Tabela 4.4 foram alteradas em  $x$  para originar  $y$ . Como  $y_1 \neq o_1$  e  $y_4 \neq o_4$ , duas manobras de chaves a mais que as manobras para implantar  $x$  são

necessárias. Como de  $o$  para  $x$ , 2 alterações foram realizadas, de  $o$  para  $y$ , são necessárias 4;

Tabela 4.4. Manobras de chaves: caso 1

		Configurações		
		$o$	$x$	$y$
Chaves/Estados	1	1	1	<b>0</b>
	2	1	0	0
	3	0	1	1
	4	0	0	<b>1</b>
	5	1	1	1

2. Os estados das duas chaves alteradas em  $y$ , em relação a  $x$ , são iguais aos estados dessas chaves em  $o$ . Portanto, o número de chaves alteradas de  $y$  será o número de chaves alteradas de  $x$  menos 2. Considere as alterações realizadas nas chaves 2 e 3 da Tabela 4.5. Como  $y_2 = o_2$  e  $y_3 = o_3$ , os estados dessas duas chaves em  $y$  retornaram aos seus estados em  $o$ . Portanto, para implantar  $y$  serão necessárias 2 manobras a menos que o número de manobras para implantar  $x$ ;

Tabela 4.5. Manobras de chaves: Caso 2

		Configurações		
		$o$	$x$	$y$
Chaves/Estados	1	1	1	1
	2	1	0	<b>1</b>
	3	0	1	<b>0</b>
	4	0	0	0
	5	1	1	1

3. O estado de uma das chaves alteradas em  $y$ , em relação a  $x$ , é igual ao estado dessa chave em  $o$ , e o estado da outra chave alterada é diferente. Portanto, o número de chaves alteradas de  $y$  será igual ao número de chaves alteradas de  $x$ .

Tabela 4.6. Manobras de chaves: Caso 3

		Configurações		
		o	x	Y
Chaves/ Estados	1	1	1	1
	2	1	0	1
	3	0	1	1
	4	0	0	0
	5	1	1	0

Na Tabela 4.6, nota-se que  $y_3 \neq o_3$  e  $y_5 \neq o_5$ . Portanto, para originar a configuração  $y$  assim como para originar  $x$ , são necessárias 2 manobras de chaves.

Em todos os casos acima, 2 mudanças de chaves em  $x$  para originar  $y$  são necessárias, porém não garante que essas duas mudanças sejam efetivas, ou seja, em relação à configuração inicial  $o$ . Por esse motivo, não se pode simplesmente dizer que o número de manobras necessárias para implantar  $y$  é o número de manobras para implantar  $x$  mais 2.

O algoritmo 4 mostra os passos necessários para determinar o número de manobras realizadas para obter uma configuração  $y$  a partir de uma configuração  $x$ . Neste algoritmo, para cada configuração  $y$  gerada a partir de uma configuração  $x$ , comparam-se os estados das 2 chaves alteradas com os estados delas na configuração original. Note que a comparação realizada na linha 3 se refere ao Caso 1 (onde o número de manobras da configuração  $x$  mais 2 é atribuído à configuração  $y$ ), já a comparação da linha 5 se refere ao Caso 2 (onde o número de manobras da configuração  $x$  menos 2 é atribuído à configuração  $y$ ). Por fim, a comparação da linha 7 se refere ao Caso 3 (onde o número de manobras da configuração  $x$  é atribuído à configuração  $y$ ).

---

**Algoritmo 4:** Pseudocódigo para determinar o número de manobras (Santos, 2009)

---

#### MANOBRAS

1: **PARA**  $y = 1$ , **ATÉ**  $y = g_{máx}$ , **FAÇA**:

2:

3:     **SE**  $y_i \neq o_i$  e  $y_j \neq o_j$

4:     manobras $y$  = manobras $x$  + 2

5:     **SE**  $y_i = o_i$  e  $y_j = o_j$

6:     manobras $y$  = manobras $x$  – 2

---

---

7: **SE**  $y_i = o_i (y_i \neq o_i)$  e  $y_j \neq o_j (y_j = o_j)$

8: manobras<sub>y</sub> = manobras<sub>x</sub>

9: **FIM**

---

#### 4.6 Algoritmo Evolutivo Multi-Objetivo em Tabelas

AEs são algoritmos de busca aleatória baseados nos princípios da seleção natural e da recombinação. Eles têm sido usados para resolver problemas difíceis com funções objetivo que são multimodais, funções contínuas não determinísticas ou não diferenciáveis. Estes algoritmos mantêm e manipulam um conjunto (chamado população) de soluções candidatas ao ótimo (chamados indivíduos).

Estes indivíduos são avaliados de acordo com uma função aptidão (ou *fitness*), baseada em critérios específicos que se aplicam às soluções dos problemas em questão. As melhores soluções têm uma maior probabilidade de serem selecionadas para reprodução, gerando uma nova população. O processo de construção de uma população a partir de outra é chamado geração. Depois de várias gerações, os indivíduos mais adaptados dominam a população atual, aumentando a qualidade média das soluções geradas.

Um AE não garante uma solução que é um ótimo global. Entretanto, como a literatura apresenta, esta técnica frequentemente encontra soluções usuais para problemas relativamente complexos.

AEs também apresentam uma performance superior ao trabalhar com problemas multi-objetivos. O MEAN faz uso de um AEMO que trabalha com várias subpopulações em paralelo armazenadas em tabela, onde os melhores indivíduos para cada característica do problema são armazenados em sua respectiva subpopulação. Por essa razão, o AE desenvolvido é chamado de AEMO em Tabela (o MEAN). O MEAN é programado utilizando RNP.

Uma subpopulação é criada para armazenar indivíduos avaliados por uma função agregação, também conhecido como método da soma ponderada. Cada subpopulação armazena indivíduos de modo a minimizar características como: (i) perdas de potência; (ii) número de operações de chaveamento; (iii) carregamento da rede; (iv) carregamento da subestação; (v) queda de tensão; e (vi) função agregação. No algoritmo proposto foi utilizada apenas uma tabela de função agregação.

O indivíduo selecionado para a reprodução pode ser proveniente de qualquer subpopulação da tabela. Essa estratégia de seleção aumenta a diversidade entre os indivíduos que reproduzem de forma que as características de um indivíduo de uma

subpopulação possam migrar para as demais subpopulações da tabela. Em consequência, aumenta-se a possibilidade do algoritmo escapar dos ótimos locais, aproximando-se de soluções com avaliações próximas de um ótimo global na fronteira de Pareto-ótima (ver seção A.2).

O MEAN requer que os seguintes parâmetros de entrada sejam seguidos (Santos et al., 2010):

1.  $S_{P_i}$  é o tamanho de uma subpopulação, que indica o número máximo de indivíduos que podem ser armazenados em uma tabela de subpopulação  $P_i$ ;
2.  $G_{máx}$  é o número máximo de indivíduos gerados pelo MEAN. Ele é usado como critério de parada;
3. Pesos,  $w_{ij}$ , penalizando as restrições na função agregação.

Um novo indivíduo gerado ( $I_{novo}$ ) é incluído em uma subpopulação  $P_i$  se esta tabela não estiver completa ou se  $I_{novo}$  é melhor que a pior solução em  $P_i$ , substituindo então este. Este processo de seleção é realizado pelo procedimento ALTER\_POP() do pseudocódigo do MEAN (ver seção 4.6.1). É importante ressaltar que um indivíduo pode ser incluído em mais do que uma subpopulação.

O processo de seleção por reprodução (por aplicação dos operadores PAO ou CAO) inicia-se pela escolha randômica de uma tabela  $P^*$ . Em seguida, um indivíduo  $I^*$  é também selecionado randomicamente a partir de  $P^*$ . Uma nova solução  $I_{novo}$  é gerada por aplicação do PAO ou CAO para  $I^*$ . Este processo continua até o número total de indivíduos gerados pelo MEAN ter alcançado  $G_{máx}$ .

A MEAN escolhe se usa o CAO ou PAO para realizar a reprodução baseado numa taxa de adaptação variável. O algoritmo inicia usando a mesma taxa de probabilidade para ambos os Operadores ( $P_{PAO} = P_{CAO} = 0,50$ ). Suponha que o PAO tenha sido escolhido. Se o indivíduo gerado entrar em pelo menos uma tabela de subpopulações, então  $P_{PAO}$  aumenta para 0,51. Como consequência,  $P_{CAO}$  diminui para 0,49. Este ajuste dinâmico no processo de escolha dos operadores melhora a performance do MEAN (Santos, 2009 e Santos et al. 2010).

Por fim, a avaliação dos indivíduos é feita através do fluxo de carga específico para SDRs, conforme apresentado nas seções 4.3 e 4.4. A cada novo indivíduo gerado, a rotina de fluxo de carga é executada para o par de alimentadores modificados do sistema.

#### 4.6.1 Algoritmo principal do MEAN

O algoritmo 5 apresenta o pseudocódigo do MEAN, conforme Santos et al. (2010).



É importante destacar que, diferentemente do NGSA-II e SPEA2 que geram vários indivíduos por iteração, no MEAN apenas 1 indivíduo é gerado por iteração.

---

**Algoritmo 5:** Pseudocódigo do MEAN (Santos et al., 2010)

---

**ALGORITMO MEAN ( $F_0$ )**

// inicia o contador de gerações

$g := 0;$

// gera subpopulações iniciais  $P_i(g_0)$ , a partir da floresta original  $F_0$

$P(g) := \text{POP\_INIC}(P_i(g_0, F_0));$

// avalia os indivíduos das subpopulações iniciais

AVALIE  $P_i(g_0);$

// teste do critério de parada ( $G_{máx}$ )

**ENQUANTO** critério de parada não é atingido **FAÇA**

// aleatoriamente selecione uma subpopulação ( $P_i$ )

$P_i := \text{ALEATORIAMENTE-SELECIONE}(\text{pop.});$

// aleatoriamente selecione um indivíduo ( $F_s$ ) de  $P_i$

$F_s := \text{ALEATORIAMENTE-SELECIONE}(P_i(g));$

// decida entre PAO ou CAO

$\text{OP} := \text{DECIDE\_OPERADOR}(\text{PAO}, \text{CAO});$

// aplicar OP para produzir um novo indivíduo  $F_g$  de  $F_s$

$F_g := \text{OP}(F_s);$

// avaliação do novo indivíduo  $F_g$

AVALIE( $F_g$ );

//selecione sobreviventes entre  $P(g)$  e  $F_g$

$P(g+1) := \text{ALTER\_POP}(P(g), F_g);$

// incrementa o contador de gerações

$g = g + 1;$

**FIM**

---

## 4.7 Conclusão

Este capítulo apresentou a metodologia MEAN. O próximo capítulo apresentará resultados de testes da MEAN aplicada ao SDR real da cidade de Marília - SP.



## 5 Testes e resultados

Os testes realizados, descritos neste capítulo, avaliam o desempenho do MEAN para reconfiguração de SDRs reais de grande escala. Os testes comprovam duas significativas propriedades do MEAN (Santos et al., 2010):

1. Habilidade para encontrar soluções adequadas requerendo baixo tempo de processamento (computacional) para SDRs de grande escala;
2. Capacidade de melhorar a qualidade de soluções para SDRs de grande escala.

Para realizar os testes foi utilizado um SDR real de grande porte da cidade de Marília/SP sem simplificações (foram consideradas todas as linhas, chaves e barras do sistema). O sistema é composto de: 15.708 barras, 2.092 setores, 2.240 chaves, 3 subestações e 20 alimentadores. A subestação Marília apresenta 2 transformadores, sendo um de 32MVA e outro de 26,6MVA, totalizando 58,6MVA, com uma demanda de 43,028MVA. A subestação Itambé apresenta ainda 2 transformadores, sendo um de 34MVA e outro de 33,25MVA, totalizando 67,25MVA e uma demanda de 42,228MVA. A subestação Tarumã apresenta um único transformador de 30MVA de potência e demanda de 25,580MVA. No total, a capacidade transformadora instalada nas subestações do sistema é de 155,850MVA, e a demanda total é de 110,836MVA. Há vários tipos de cabos utilizados na rede, sendo que, E70, A47, A33, A02, A10, C06, MIG, S02, S04 e S10 são os modelos mais encontrados. Esse SDR corresponde à rede da cidade de Marília/SP no ano de 2012.

A metodologia aqui aplicada pode ser utilizada em problemas de reconfiguração de redes com diversos propósitos, dentre os quais se destacam: restabelecimento de energia após uma contingência, redução de perdas de potência, de queda de tensão, de carregamento na rede e nas subestações, balanceamento de cargas nos transformadores, expansão da rede e alocação ótima de componentes na rede, tais como capacitores, chaves automáticas, etc. Os testes apresentados concentram-se no restabelecimento de energia após a ocorrência de uma única falta. Optou-se pela exploração deste tipo de problema em função da sua maior complexidade computacional e pela necessidade de resposta em tempo real. De certa forma, pode-se dizer que os demais problemas de reconfiguração são casos particulares do problema de restabelecimento (Santos, 2009).

O MEAN foi implementado num computador convencional com processador Core 2Quad – Q2800, 2,33GHz, 8Gbytes de memória RAM, Sistema Operacional Linux, distribuição Ubuntu 10.04; e o GCC 4.4.3 com compilador de linguagem C.

Na seção 5.1 é descrito o processo de obtenção e trabalho dos dados utilizados. Na seção 5.2 são apresentados os parâmetros utilizados no MEAN, para realização dos testes. Na seção 5.3 são apresentados os resultados das simulações com falta única em dois importantes alimentadores do SDR real de Marília.

### **5.1 Obtenção e trabalho dos dados do SRD de Marília**

A CPFL é a concessionária responsável pela distribuição de energia na cidade de Marília/SP. Os dados do sistema de distribuição da cidade foram obtidos, com as devidas autorizações dos superiores, a partir do REDE, software utilizado pela empresa para estudo e planejamento dos SDRs. Quando da obtenção dos dados foi constatada grande diferença entre o perfil de dados utilizado como entrada do REDE e o perfil de dados utilizados como entrada do MEAN. Partiu-se, então, para um longo processo de trabalho dos dados, a fim de deixá-los compatíveis com o arquivo de entrada de dados do MEAN.

A primeira etapa deste processo consistiu em retirar dados que são de uso particular da empresa, como: número operativo de chaves e postos de transformação, observações a respeito de unidades consumidoras, tipo do trecho (da CPFL ou particular), etc. Devido às restrições no cálculo de fluxo de carga do MEAN, também foram desligados todos os 5 bancos reguladores de tensão do sistema de Marília (esta é uma informação importante, pois altera os valores finais de queda de tensão máxima da rede). Na prática, cada banco foi substituído por um valor resistivo bem pequeno, possibilitando a execução do fluxo de carga do MEAN, causando uma alteração desprezível no valor de queda de tensão.

Em seguida, foi necessário acertar a numeração das barras, pois no arquivo de dados do REDE as barras estavam especificadas e ordenadas por coordenadas, e o arquivo de entrada do MEAN necessita que os dados sejam especificados e ordenados por numeração sequencial.

Tendo os dados de entrada ajustados foram geradas as RNPs. Neste ponto foram encontradas algumas inconsistências nos dados e procedeu-se com a correção de pequenos detalhes que ocasionavam problemas na geração das RNPs. Feitas as devidas correções, comparou-se o fluxo de carga utilizado pelo MEAN com o fluxo de carga do REDE, comparando-se os valores de queda de tensão e perdas de potência, alimentador por alimentador. Este último processo serviu como confirmação de que os

dados haviam sido transformados corretamente, pois a resposta do fluxo de carga do MEAN ficou coerente com a resposta do fluxo de carga do REDE (fluxo de carga este utilizado na prática nos trabalhos da empresa). Vale informar que houve uma pequena diferença nos valores encontrados, possivelmente devido ao fato de os métodos para cálculo de fluxo de carga empregados no MEAN e no REDE serem diferentes além de fazerem uso de modelos de carga distintos (ver seções 2.4 e 2.5).

A figura 5.1 apresenta o sistema de distribuição da cidade de Marília, conforme visto na tela do REDE.

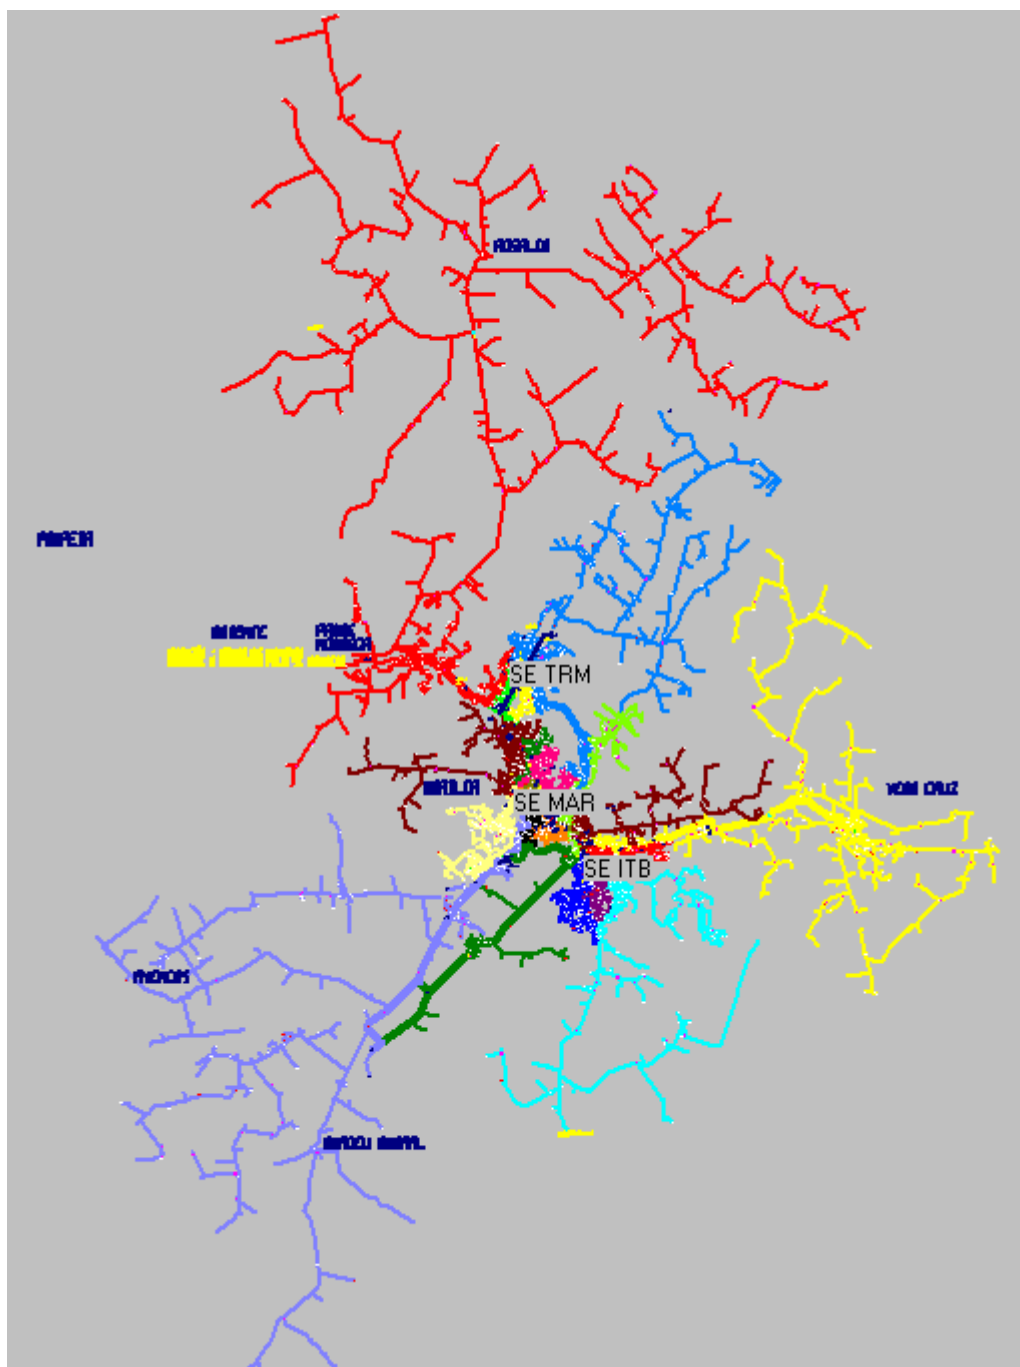


Figura 5.1. SDR real da cidade de Marília/SP (REDE)

## 5.2 Parâmetros utilizados no MEAN

Os parâmetros utilizados para execução do MEAN foram:

1. Número máximo de indivíduos gerados:  $G_{máx} = 30.000$ ;
2. Tamanho da subpopulação  $P_i$ :  $S_{P_i} = 5$ , para  $i = 1, \dots, 5$ ;
3. E pesos como segue:

O MEAN é muito robusto em relação a variações dos pesos . Estes valores devem ser suficientemente altos para penalizar soluções inviáveis, assim, pesos variando de 10 a 100 são geralmente adequados.

A função agregação é descrita como segue:

onde são as perdas resistivas, em kW; é o número de chaveamentos, em valores inteiros; , e foram definidas na seção 3.2. É importante salientar que todas as configurações geradas pelo MEAN restabelecem o fornecimento de energia para todas as cargas que ficaram fora de serviço em detrimento da contingência ocorrida.

A partir disto, a seguinte nomenclatura é utilizada para identificar as tabelas de subpopulações:

- $P_1 - SP_1$ : indivíduos com menor valor de função agregação;
- $P_2 - SP_2$ : indivíduos com menor perdas de potência;
- $P_3 - SP_3$ : indivíduos com menor queda de tensão;
- $P_4 - SP_4$ : indivíduos com menor carregamento de rede;
- $P_5 - SP_5$ : indivíduos com menor carregamento de subestação;
- $P_{5+i} - SP_{5+i}$ : indivíduos com  $i-1$  pares de operações de chaveamento, depois da falta isolada,  $i = 1, \dots, 7$ .

É importante destacar, conforme será visto nos resultados, que para as tabelas de pares de manobras considera-se 1 manobra inicial para restabelecer a energia ao setor afetado para, em seguida, reconfigurar o sistema. Assim, na tabela  $P_6$ , que apresenta as reconfigurações feitas com 0 pares de manobras, constará um total de 1 manobra, o

necessário para restaurar a energia para o setor em falta. Para as tabelas seguintes sempre constará  $i-1$  pares acrescidos de uma manobra.

Para os testes realizados utilizou-se 100% como o limite de capacidade da rede e das subestações. Considerou-se 7% (em relação à tensão nominal da subestação) como a máxima taxa de queda de tensão permissível, conforme especificação da ANEEL para tensões entre 1kV e 69kV. Para todos os casos foram utilizadas 30.000 gerações como o número máximo de indivíduos gerados ( $G_{máx}$ ), visto que já foi verificado experimentalmente que testes com  $G_{máx}$  maior que 30.000 não produzem melhorias significativas para estes casos (Santos, 2009).

### 5.3 Resultados das simulações

Conforme apresentado na seção 4.6, o MEAN trabalha com tabelas de subpopulações em paralelo e não com uma população única, como fazem os AEs convencionais. Cada subpopulação do MEAN armazena os 5 melhores indivíduos para cada uma das características apresentadas na seção 5.2.

Para realização das simulações foram aplicadas faltas nos alimentadores 1 e 3 do SDR de Marília. Estes dois alimentadores estão conectados a uma única subestação e ao mesmo transformador.

O alimentador 1 apresenta uma corrente de 293A na saída da subestação, sendo o quarto maior alimentador do sistema em termos de corrente de saída da subestação, contando com uma grande extensão de rede. Cargas importantes como a do Hospital Universitário e do Departamento de Água e Esgoto estão conectadas a este alimentador. Conforme visto na figura 5.2, ele também supre uma grande área rural, inclusive dois pequenos distritos da cidade de Marília: Avencas e Amadeu Amaral. A figura 5.2 apresenta todo o traçado do alimentador (em azul), desde a subestação até as pontas da rede. O quadro em destaque apresenta alguns dados importantes do alimentador, como demanda, corrente, fator de potência, perdas e maior queda de tensão. Estes dados serão importantes para o estudo da reconfiguração do sistema para restabelecimento de energia na ocasião da falta.

É importante salientar que na tabela de dados nota-se a maior queda de tensão no alimentador como sendo de 7,17%. Na prática essa queda é de 4,06%, porém, a fim de simular o REDE para comparação com o MEAN, foi desligado um banco regulador de tensão que existe neste alimentador (ver seção 5.1), ocasionando este maior valor para queda de tensão.

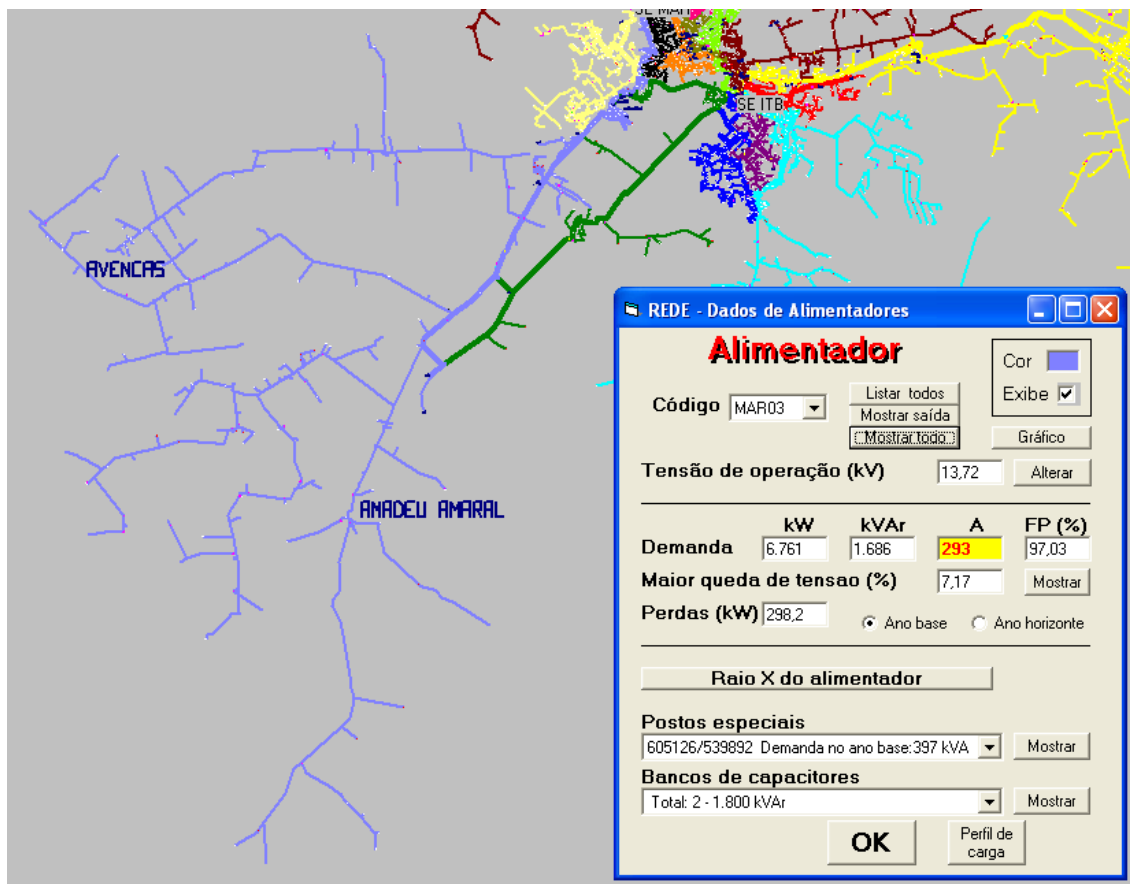


Figura 5.2. Traçado original do alimentador 1

O alimentador 3 apresenta uma corrente de 300A na saída da subestação, sendo o terceiro maior alimentador do sistema em termos de corrente de saída da subestação, apesar de ter uma extensão de rede bem menor que a do alimentador 1. Isto se deve ao fato de este alimentador suprir a região central da cidade de Marília, alimentando várias cargas importantes para o sistema, como: bancos, grandes estabelecimentos comerciais, Faculdade de Medicina de Marília, etc. A figura 5.3 apresenta todo o traçado (em laranja) do alimentador 3, desde a subestação até suas conexões com outros alimentadores. O quadro em destaque apresenta os dados mais importantes do alimentador. Pode se notar que, assim como o alimentador 1, ele também está conectado à subestação “Marília” (SE MAR).



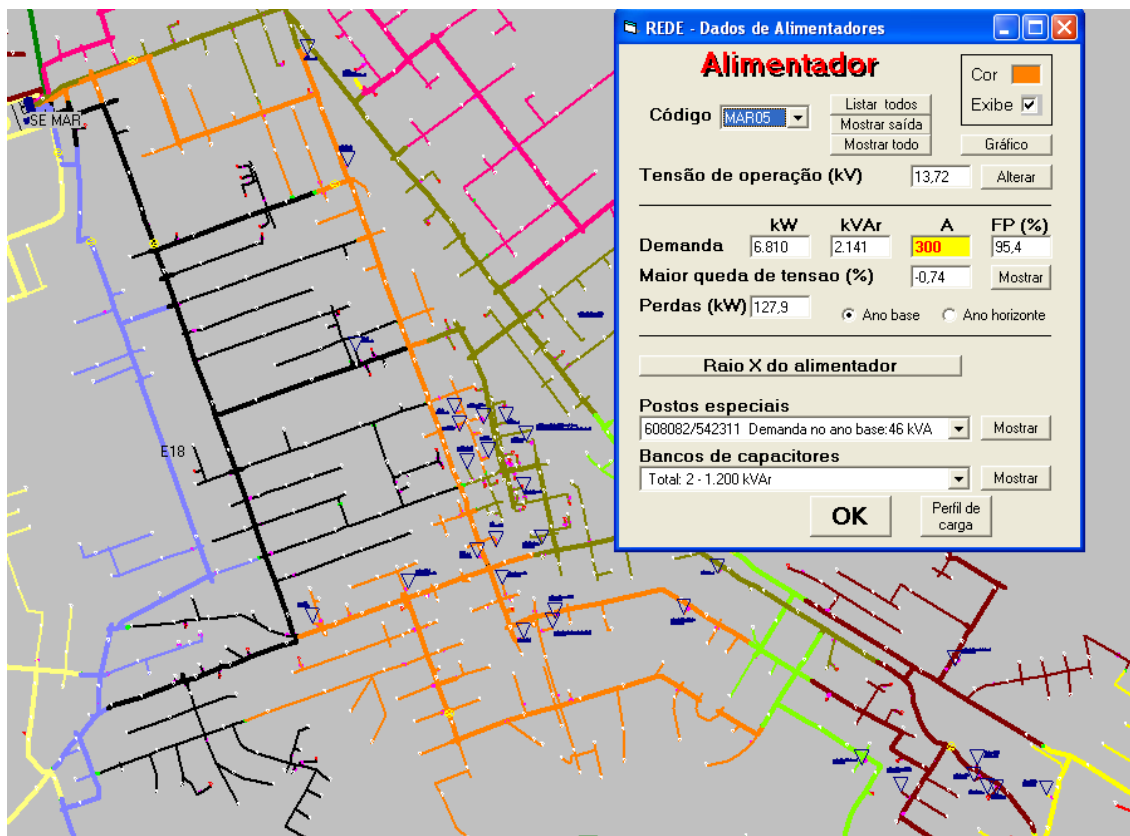


Figura 5.3. Traçado original do alimentador 3

### 5.3.1 Falta única no alimentador 1

Considerou-se então uma falta permanente no setor 606 localizado no início do alimentador 1. O alimentador 1 é composto por 202 setores, sendo que, devido à falta no setor 606, 200 setores ficariam fora de serviço. A figura 5.4 ilustra parte da RNP do alimentador 1 (até os setores com profundidade 12), dando destaque para a falta que ocorre no setor 606. Pode-se notar que ele é o segundo setor do alimentador, tendo à montante apenas o setor raiz 1742.

Abaixo, a RNP representada na figura 5.4 (exceto os setores de profundidade 13, que não foram representados):

Nas figuras 5.4 e 5.6, "Subestação 1" representa a "Subestação Marília".

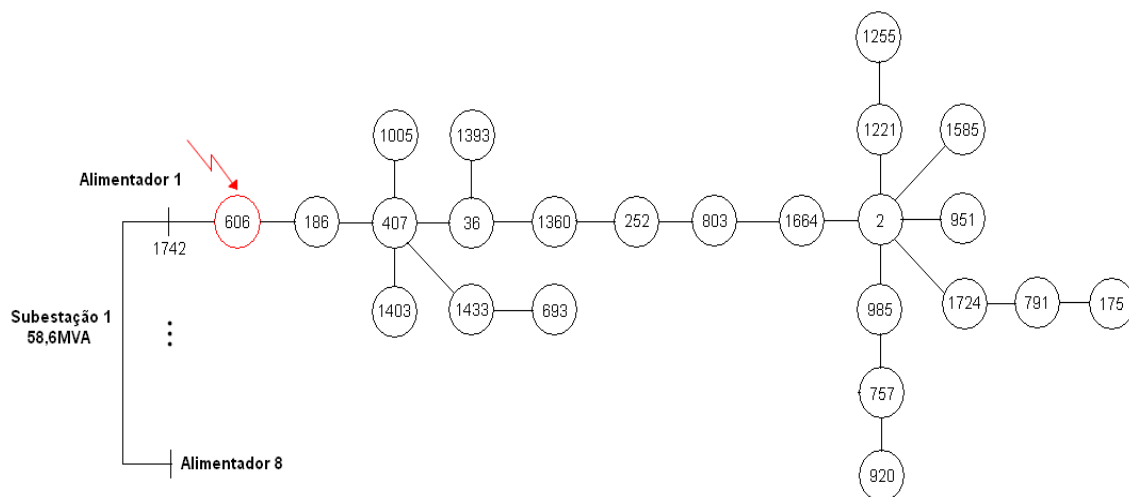


Figura 5.4 Destaque de parte da RNP do alimentador 1 (com falta no setor 606)

A figura 5.5, retirada do REDE, mostra todo o trecho que fica fora de serviço quando uma falta ocorre no setor acima especificado. Ao se comparar a figura 5.2 e a 5.5 constata-se a gravidade de uma falta ocorrido neste setor.




Figura 5.5. Trecho fora de serviço (em rosa) devido à contingência no setor 606

A tabela 5.1 apresenta os valores médio e desvio padrão para cada objetivo e restrições do problema. Para compor esta tabela foram consideradas todas soluções

geradas após 20 simulações do MEAN, inclusive aquelas que ultrapassam os valores das restrições operacionais (soluções infactíveis).

Tabela 5.1. Valores médios dos objetivos e restrições para todas as soluções encontradas para cada tabela de indivíduos

		<b>Perdas</b>	<b>QT</b>	<b>CarRede</b>	<b>CarSE</b>	<b>Man</b>
$P_0$	Média	503,1695	6,365882	63,95953	56,22682	17,28235
	DP	8,291954	0,264216	7,090596	0,839885	3,657745
$P_1$	Média	<b>483,4455</b>	6,317176	65,42694	55,37035	82,95294
	DP	11,41337	0,194275	12,46139	0,994366	4,508569
$P_2$	Média	546,0875	<b>6,147765</b>	73,26976	54,47447	33,02353
	DP	42,84613	0,23388	23,93552	1,227079	18,84549
$P_3$	Média	551,8096	<u>7,226588</u>	<b>42,99047</b>	54,59741	25,37647
	DP	11,10396	0,610224	2,23044	0,571317	12,25415
$P_4$	Média	4907,652	<u>33,16635</u>	<u>634,2918</u>	<b>44,04353</b>	101,0471
	DP	3534,434	19,72469	253,8412	3,14112	17,61544
$P_5$	Média	587,3795	<u>8,517412</u>	71,32718	54,69	<b>3</b>
	DP	64,05776	2,114291	19,40623	0	0
$P_6$	Média	558,0221	<u>7,374353</u>	53,09565	54,69	<b>5</b>
	DP	22,86203	1,167741	3,609615	0	0
$P_7$	Média	558,4487	<u>7,276353</u>	48,20294	54,69882	<b>7</b>
	DP	15,06045	0,815658	1,414695	0,079785	0
$P_8$	Média	554,5074	<u>7,085882</u>	46,71694	54,7	<b>9</b>
	DP	9,531871	0,596549	1,42005	0,092749	0
$P_9$	Média	551,234	6,992588	45,546	54,66976	<b>11</b>
	DP	9,820109	0,525677	1,736793	0,18546	0
$P_{10}$	Média	550,4295	<u>7,038118</u>	44,42306	54,69635	<b>13</b>
	DP	10,18311	0,514863	1,85076	0,043706	0
$P_{11}$	Média	550,5234	<u>7,065059</u>	43,97329	54,66847	<b>15</b>
	DP	11,08248	0,525757	1,943091	0,17819	0

Pode-se notar que para as tabelas de carregamento da rede, carregamento da subestação e de 1 a 3 pares de manobras, os valores médios ultrapassaram os limites de algumas restrições operacionais do sistema, especialmente queda de tensão e carregamento da rede (ver valores grifados).

A tabela 5.2 apresenta, novamente, os valores médio e desvio padrão para cada objetivo e restrição operacional do sistema. Entretanto, para este caso, foram selecionados apenas os melhores indivíduos de cada tabela (indivíduos com melhor *fitness*). Na escolha dos melhores indivíduos das tabelas de pares de manobras, foram considerados como melhores aqueles que apresentam a menor soma, em porcentagem, da queda de tensão mais o carregamento da rede. Para compor esta tabela foram consideradas as mesmas 20 simulações do MEAN da tabela 5.1.

Tabela 5.2. Valores médios dos objetivos e restrições das melhores soluções encontradas para cada tabela de indivíduos

		<b>Perdas</b>	<b>QT</b>	<b>CarRede</b>	<b>CarSE</b>	<b>Man</b>
$P_0$	Média	502,7676	6,332941	63,65294	56,13235	14,64706
	DP	8,207122	0,259451	6,812477	0,700718	3,234759
$P_1$	Média	<b>483,2165</b>	6,312941	65,62118	55,32765	80,52941
	DP	11,50111	0,196012	12,46537	1,03288	4,258108
$P_2$	Média	536,9906	<b>6,141176</b>	66,06706	54,46529	30,41176
	DP	45,19102	0,236167	16,73053	1,228275	18,87126
$P_3$	Média	550,9465	<u>7,221176</u>	<b>42,98294</b>	54,57176	19,47059
	DP	11,16051	0,613408	2,234141	0,542914	10,7928
$P_4$	Média	4907,078	<u>33,11353</u>	<u>634,0424</u>	<b>44,04059</b>	99
	DP	3520,149	19,76464	253,5665	3,141235	17,96729
$P_5$	Média	580,6212	<u>8,362941</u>	67,29353	54,69	<b>1</b>
	DP	55,9025	2,010513	2,280542	0	0
$P_6$	Média	558,9276	<u>7,411765</u>	51,93294	54,69	<b>3</b>
	DP	22,12588	1,185675	2,947104	0	0
$P_7$	Média	557,9547	<u>7,282941</u>	47,72529	54,69	<b>5</b>
	DP	9,612775	0,569125	1,270563	0	0
$P_8$	Média	554,6218	<u>7,127647</u>	46,30706	54,69	<b>7</b>
	DP	9,510654	0,58644	1,580185	0	0
$P_9$	Média	550,1918	6,977059	45,39529	54,58882	<b>9</b>
	DP	9,302998	0,547226	1,761173	0,404706	0
$P_{10}$	Média	550,6247	<u>7,072941</u>	44,22235	54,69	<b>11</b>
	DP	10,21735	0,516422	1,7622	0	0
$P_{11}$	Média	549,0829	<u>7,047059</u>	43,80235	54,59353	<b>13</b>
	DP	10,10669	0,557924	1,969457	0,385882	0

Pode-se notar que os valores encontrados foram, em média, melhores que os valores encontrados no caso anterior, o que era de se esperar, afinal foram escolhidos apenas os melhores indivíduos de cada população. Entretanto, é possível notar que ainda há vários valores que ultrapassam as restrições operacionais do sistema.

A fim de encontrar valores finais e soluções factíveis, ou seja, soluções que podem ser colocadas em prática sem desrespeitar nenhuma restrição operacional, para compor a tabela 5.3 foram escolhidas apenas as soluções factíveis de cada tabela. Nesta tabela estão apresentados não somente os valores médio e desvio padrão, mas também o pior e o melhor indivíduo selecionado de cada população. Pode-se notar a ausência de algumas tabelas como, por exemplo, de carregamento da subestação e de 0 pares de manobras, isto devido ao fato de nenhuma destas tabelas apresentarem soluções factíveis para o restabelecimento de energia no setor 606 em falta.

Tabela 5.3. Valores mínimo, médio e máximo dos objetivos e restrições para as melhores soluções encontradas para cada tabela de indivíduos

		Perdas	QT	CarRede	CarSE	Man
$P_0$	Mín	491,36	6,08	50,05	55,63	11
	Média	502,7676	6,332941	63,65294	56,13235	16,64706
	Máx	516,68	6,81	71,74	57,35	23
	DP	8,207122	0,259451	6,812477	0,700718	3,234759
$P_1$	Mín	469,35	6,11	49,97	52,47	73
	Média	<b>483,2165</b>	6,312941	65,62118	55,32765	82,64706
	Máx	504,26	6,62	91,29	56,98	89
	DP	11,50111	0,196012	12,46537	1,03288	4,405093
$P_2$	Mín	487,7	5,97	45,17	52,96	17
	Média	534,8556	<b>6,113125</b>	63,54938	54,38188	33,25
	Máx	632,86	6,55	85,14	56,06	79
	DP	42,01694	0,214205	11,6744	1,218463	19,11642
$P_3$	Mín	536	6,59	40,66	54,58	15
	Média	546,6467	6,777778	<b>43,28889</b>	54,72	21,44444
	Máx	557,69	7	48,3	55,05	35
	DP	7,955898	0,179492	2,765716	0,121929	7,41037
$P_6$	Mín	533,31	6,59	53,25	54,69	3
	Média	548,3385	6,682308	53,58154	54,69	<b>3</b>
	Máx	564,45	6,94	57,56	54,69	3
	DP	10,4632	0,110673	1,148483	0	0
$P_7$	Mín	544,49	6,59	47,33	54,69	5
	Média	552,85	6,735833	48,57167	54,69	<b>5</b>
	Máx	560,97	6,94	50,55	54,69	5
	DP	6,189751	0,144998	0,967246	0	0
$P_8$	Mín	543,05	6,59	44,45	54,69	7
	Média	551,365	6,73	46,74667	54,69	<b>7</b>
	Máx	561,97	6,95	49,78	54,69	7
	DP	7,63525	0,153569	1,372834	0	0
$P_9$	Mín	538,38	6,09	42,77	52,97	9
	Média	546,9831	6,716923	45,75769	54,55769	<b>9</b>
	Máx	559,79	6,98	48,3	54,69	9
	DP	6,323152	0,239435	1,762512	0,458327	0
$P_{10}$	Mín	535,43	6,59	42,41	54,69	11
	Média	546,7325	6,751667	44,67083	54,69	<b>11</b>
	Máx	556,35	7	48,3	54,69	11
	DP	7,650023	0,16955	2,048343	0	0
$P_{11}$	Mín	527,91	6,09	42,41	53,05	13
	Média	546,0491	6,704545	44,13909	54,54091	<b>13</b>
	Máx	556,28	6,98	48,3	54,69	13
	DP	9,460755	0,253031	2,229474	0,471467	0

Considerando o principal objetivo como sendo minimizar o número de manobras (atendendo ao máximo de consumidores afetados possível), a tabela de 1 par de manobras, ou seja, a população  $P_6$  é a que apresenta o melhor resultado para o problema em questão. Considere, por exemplo, a tabela de menor queda de tensão,  $P_2$ , que apresenta um valor mínimo de 5,97% de queda de tensão, que é um valor baixo para um problema de restabelecimento, porém necessitando de 17 manobras para isso. Ao olhar para a tabela  $P_6$ , encontra-se um valor mínimo de queda de tensão encontrado de 6,59% sendo atingido, entretanto, com apenas 3 manobras. Sendo assim, a melhor solução encontrada pelo MEAN para o problema de reconfiguração de redes para restabelecer energia para o setor 606 do alimentador 1, necessitou de 3 manobras apenas, com um tempo médio de processamento computacional de 35,7s.

### **5.3.2 Falta única no alimentador 3**

Consideremos agora uma falta permanente no setor 43, localizado no início do alimentador 3. O alimentador 3 é composto por 61 setores, sendo que, devido à falta no setor 43, 59 setores ficariam fora de serviço. A figura 5.6 ilustra parte da RNP do alimentador 3 (até os setores com profundidade 8), dando destaque para falta que ocorre no setor 43. Pode-se notar que ele é o segundo setor do alimentador, tendo à montante apenas o setor raiz 1757.

Abaixo, a RNP representada na figura 5.6 (exceto os setores de profundidade 9, que não foram representados):

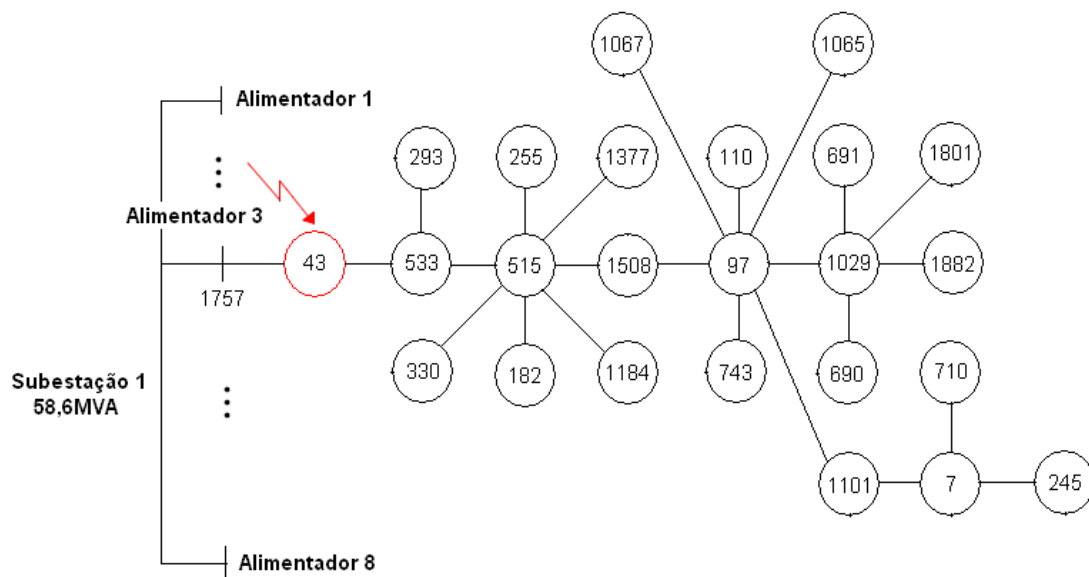


Figura 5.6. Destaque de parte da RNP do alimentador 3 (com falta no setor 43)

A figura 5.6, também retirada do REDE após manobra de abertura do trecho em falta, mostra o setor que fica fora de serviço devido à uma contingência no setor 43. Pode-se comparar as figuras 5.3 e 5.6 para notar a extensão do problema e como o restabelecimento rápido e adequado é necessário.




Figura 5.7. Trecho fora de serviço (em rosa claro) devido a contingência no setor 43

No estudo das soluções encontradas para restabelecimento de energia para o setor 43, foi feito o mesmo procedimento do setor 606. Serão apresentadas três tabelas de soluções, a fim de se comparar os resultados entre elas e com o caso anterior.

A tabela 5.4 apresenta os valores médio e desvio padrão para cada objetivo e restrições do problema. Para compor esta tabela foram consideradas todas soluções geradas após 20 simulações do MEAN, inclusive aquelas que ultrapassam os valores das restrições operacionais (soluções inactivíveis).

Tabela 5.4. Valores médios dos objetivos e restrições para todas as soluções encontradas para cada tabela de indivíduos

		<b>Perdas</b>	<b>QT</b>	<b>CarRede</b>	<b>CarSE</b>	<b>Man</b>
$P_0$	Média	502,6531	6,3168	54,2205	56,1172	18,72
	DP	8,660418	0,247325	3,295615	1,399781	3,441163
$P_1$	Média	<b>483,9234</b>	6,334	54,1485	55,5296	79,58
	DP	6,529685	0,263408	3,28163	0,963505	13,66249
$P_2$	Média	526,7071	<b>6,1047</b>	63,7208	55,0171	51,34
	DP	22,38265	0,204389	15,37948	1,693008	28,40008
$P_3$	Média	552,8962	<u>7,0209</u>	<b>43,2857</b>	54,5246	29,22
	DP	18,66354	0,731657	2,07833	0,96359	10,13862
$P_4$	Média	4622,416	<u>27,322</u>	<u>661,2472</u>	<b>44,1934</b>	102,38
	DP	2819,193	13,03789	398,5388	2,87235	15,72436
$P_5$	Média	579,9738	<u>7,31</u>	79,1862	54,69	<b>3</b>
	DP	26,64538	0	28,23792	0	0
$P_6$	Média	567,6838	<u>7,4033</u>	59,6544	54,69	<b>5</b>
	DP	11,90688	0,189209	3,371957	0	0
$P_7$	Média	560,1178	<u>7,1582</u>	50,7609	54,6951	<b>7</b>
	DP	9,711378	0,378165	2,706636	0,040037	0
$P_8$	Média	557,0923	6,93	47,9532	54,69	<b>9</b>
	DP	13,85074	0,400522	0,957963	0	0
$P_9$	Média	552,9273	6,8729	46,7425	54,5324	<b>11</b>
	DP	12,50482	0,500416	1,403318	0,499402	0
$P_{10}$	Média	550,1017	6,7495	45,4207	54,4543	<b>13</b>
	DP	11,40786	0,462297	1,717986	0,595551	0
$P_{11}$	Média	547,2499	6,6839	44,7809	54,4824	<b>15</b>
	DP	10,44134	0,419206	1,80848	0,643899	0

Pode-se notar, como no caso anterior, que para as tabelas de carregamento da rede, carregamento da subestação e de 1 a 3 pares de manobras, os valores médios ultrapassaram os limites de algumas restrições operacionais do sistema, especialmente queda de tensão e carregamento da rede (ver valores grifados).

A tabela 5.5 apresenta os valores médio e desvio padrão para cada objetivo e restrição operacional do sistema. Novamente foram selecionados apenas os melhores



indivíduos de cada tabela (indivíduos com melhor *fitness*). Na escolha dos melhores indivíduos das tabelas de pares de manobras, foram considerados como melhores aqueles que apresentam a menor soma, em porcentagem, da queda de tensão mais o carregamento da rede. Para compor esta tabela foram consideradas as mesmas 20 simulações do MEAN da tabela 5.4.

Tabela 5. Valores médios dos objetivos e restrições das melhores soluções encontradas para cada tabela de indivíduos

		<b>Perdas</b>	<b>QT</b>	<b>CarRede</b>	<b>CarSE</b>	<b>Man</b>
$P_0$	Média	502,4765	6,318	53,8755	56,0875	18,4
	DP	8,444161	0,246366	2,81791	1,408201	3,746999
$P_1$	Média	<b>483,6735</b>	6,32	54,3525	55,514	79,8
	DP	6,438269	0,223025	3,257605	0,961413	13,96281
$P_2$	Média	523,794	<b>6,0765</b>	67,616	54,4825	51,3
	DP	22,25197	0,16737	20,7384	1,81845	28,59563
$P_3$	Média	553,096	<u>7,1355</u>	<b>43,2405</b>	54,536	28,5
	DP	18,92276	0,787512	2,056474	0,964388	10,21518
$P_4$	Média	4627,751	<u>27,4435</u>	<u>663,0515</u>	<b>44,171</b>	102,8
	DP	2822,642	12,95775	397,1897	2,854988	15,64481
$P_5$	Média	566,5555	<u>7,31</u>	68,89	54,69	<b>1</b>
	DP	11,81247	0	0	0	0
$P_6$	Média	563,1225	<u>7,3625</u>	58,0075	54,69	<b>3</b>
	DP	9,946135	0,105018	3,681449	0	0
$P_7$	Média	560,522	<u>7,2365</u>	50,2965	54,708	<b>5</b>
	DP	8,782006	0,41099	2,73352	0,07846	0
$P_8$	Média	554,8885	6,883	47,7695	54,69	<b>7</b>
	DP	14,32158	0,380737	1,033162	0	0
$P_9$	Média	552,417	6,867	46,5945	54,362	<b>9</b>
	DP	14,36887	0,587589	1,404263	0,656	0
$P_{10}$	Média	550,804	6,7985	45,288	54,444	<b>11</b>
	DP	12,27254	0,545768	1,737304	0,585597	0
$P_{11}$	Média	546,33	6,6385	44,7035	54,417	<b>13</b>
	DP	10,51233	0,418847	1,819149	0,704898	0

Pode-se notar que os valores encontrados foram, em média, melhores que os valores encontrados quando se considerou todas as soluções, afinal foram escolhidos apenas os melhores indivíduos de cada população. Entretanto, é possível notar que ainda há vários valores que ultrapassam as restrições operacionais do sistema.

A fim de chegar-se a valores finais e soluções factíveis, ou seja, soluções que podem ser colocadas em prática sem desrespeitar nenhuma restrição operacional, para compor a tabela 5.3 foram escolhidas apenas as soluções factíveis de cada tabela. Nesta tabela estão apresentados não somente os valores médio e desvio padrão, mas

também o pior e o melhor indivíduo selecionado de cada população. Pode-se notar a ausência de algumas tabelas como, por exemplo, de carregamento da subestação e de 0 e 1 pares de manobras, isto devido ao fato de nenhuma destas tabelas apresentarem soluções factíveis para o restabelecimento de energia no setor 43 em falta.

Tabela 5.6. Valores mínimo, médio e máximo dos objetivos e restrições para as melhores soluções encontradas para cada tabela de indivíduos

		<b>Perdas</b>	<b>QT</b>	<b>CarRede</b>	<b>CarSE</b>	<b>Man</b>
$P_0$	Mín	483,85	6,09	50,05	53,05	11
	Média	502,1447	6,303684	54,00211	56,02105	18,47368
	Máx	515,99	6,59	59,36	57,7	25
	DP	8,535535	0,244523	2,83513	1,413893	3,830191
$P_1$	Mín	468,49	6,09	49,11	52,71	31
	Média	<b>483,6735</b>	6,32	54,3525	55,514	79,8
	Máx	493,54	6,66	64,33	56,74	95
	DP	6,438269	0,223025	3,257605	0,961413	14,01999
$P_2$	Mín	484,18	5,96	42,43	52,97	17
	Média	523,5865	<b>6,1015</b>	61,3775	55,133	51,4
	Máx	564,21	6,59	84,17	57,35	93
	DP	21,33727	0,216363	11,0393	1,29808	28,37323
$P_3$	Mín	518	6,09	40,8	53,07	13
	Média	545,5138	6,571538	<b>43,66692</b>	54,71	29,92308
	Máx	575,38	6,69	48,3	55,6	55
	DP	16,59077	0,141902	2,474222	0,565495	11,67813
$P_7$	Mín	544,17	6,59	48,1	54,69	5
	Média	552,9833	6,69	50,6	54,69	<b>5</b>
	Máx	571,72	6,94	53,87	54,69	5
	DP	9,318755	0,135401	2,247047	0	0
$P_8$	Mín	532,47	6,59	47,25	54,69	7
	Média	549,312	6,644667	47,922	54,69	<b>7</b>
	Máx	571,47	6,95	48,77	54,69	7
	DP	13,02525	0,088308	0,457066	0	0
$P_9$	Mín	521,09	6,09	44,82	53,05	9
	Média	544,4927	6,494	47,11867	54,25267	<b>9</b>
	Máx	572,6	6,95	48,32	54,69	9
	DP	12,39984	0,258374	1,262103	0,725235	0
$P_{10}$	Mín	531,77	6	43,28	53,05	11
	Média	544,9213	6,518667	45,73467	54,362	<b>11</b>
	Máx	565,89	6,95	48,3	54,69	11
	DP	9,80514	0,25974	1,721189	0,656	0
$P_{11}$	Mín	529,13	5,99	42,54	53,05	13
	Média	544,3118	6,498824	44,90294	54,32588	<b>13</b>
	Máx	564,76	6,95	48,3	55,06	13
	DP	10,14113	0,277465	1,814432	0,712964	0

Considerando o principal objetivo como sendo minimizar o número de manobras (atendendo ao máximo de consumidores afetados possível), a tabela de 2 pares de manobras, ou seja, a população  $P_7$  é a que apresenta o melhor resultado para o problema em questão. Considere, por exemplo, a tabela de menor carregamento da rede,  $P_3$ , que apresenta um valor mínimo de 40,8% de carregamento da rede, que é um valor baixo para um problema de restabelecimento, porém necessitando de 13 manobras para isso. Ao olhar para a tabela  $P_7$ , encontra-se um valor mínimo de encontrado de 6,59% sendo atingido, entretanto, com apenas 5 manobras. Sendo assim, a melhor solução encontrada pelo MEAN para o problema de reconfiguração de redes para restabelecer energia para o setor 43 do alimentador 3, necessitou de 5 manobras apenas, com um tempo médio de processamento computacional de 33,9s.



## 6 Conclusão

Este capítulo sintetiza as principais conclusões obtidas e apresenta algumas considerações sobre perspectivas de pesquisas futuras relativas à área de estudo deste trabalho.

O restabelecimento de energia em SDRs geralmente envolve reconfiguração de redes. Um AEMO associado a uma estrutura de dados eficiente, o MEAN, foi estudado neste trabalho. Existem várias aplicações para o MEAN, sendo algumas abordadas nas perspectivas de pesquisas futuras. Este trabalho explorou essa técnica para tratamento do problema de restabelecimento de energia em um SDR real, no qual se busca o restabelecimento de energia ao maior número possível de consumidores após as faltas terem sido identificadas e isoladas, sem violar os limites operacionais estabelecidos em normas técnicas como sobrecarga nas linhas e subestações e queda de tensão.

Os SDRs do mundo real possuem uma grande quantidade de barras e chaves. Assim, técnicas que conseguem lidar com modelagens complexas, envolvendo a maior quantidade possível de componentes de um SDR, podem ser interessantes para obtenção de planos de restabelecimento de melhor qualidade. O uso da estrutura de dados RNP é base de desenvolvimento do MEAN, uma vez que essa codificação garante a rápida geração de novas configurações de rede, sempre radiais e conexas. Com isso, evitam-se rotinas para identificar e corrigir essas infactibilidades, que aumentam consideravelmente e estão presentes em várias abordagens encontradas na literatura.

O MEAN foi avaliado utilizando uma rede de um SDR real com 15.708 barras e 2.240 chaves, sem simplificações em relação à rede real, ou seja, foram consideradas todas as linhas, barras e chaves da mesma, exceto os bancos reguladores de tensão que foram desligados do sistema por restrições do programa. O SDR alimenta a cidade de Marília com, aproximadamente, 220 mil habitantes e 94.103 unidades consumidoras.

Quanto maior o tamanho da rede, maior o número de configurações possíveis. Isso pode ser constatado ao se comparar os resultados apresentados neste trabalho de conclusão de curso, com os resultados obtidos para o SDR real da cidade de São Carlos apresentados em Santos et al. (2010). Nesse artigo foi estudado o SDR real de São Carlos, em operação no ano de 1994, que continha 3.860 barras e, em seguida, suas versões duplicado, quadruplicado e octuplicado. Apesar de o MEAN responder

bem à expansão do sistema naquele caso, inclusive obtendo ótimo tempo de processamento (na ordem dos segundos), constatou-se neste trabalho que para um SDR real de grande porte, como o de Marília, sua eficiência computacional não foi a mesma. Importa destacar, entretanto, que em termos de aplicação prática, os tempos de processamento obtidos nas simulações com o sistema de Marília foram muito bons, na ordem de dezenas (30, em média) de segundos, mas não na ordem dos segundos como os obtidos em Santos et al (2010). Neste aspecto deve-se lembrar que na literatura especializada não se encontra metodologia alguma que possibilite o tratamento do problema de restabelecimento de energia em SDRs de grande porte com tamanha eficiência computacional. Quanto ao número de chaveamentos pode-se constatar que os resultados obtidos para o sistema de Marília foram tão bons, ou até melhores, que os resultados obtidos naquele caso para o SDR de São Carlos. Reconfigurações com 5 chaveamentos como as apresentadas aqui, são reconfigurações ótimas para serem aplicadas na prática, aumentando a eficiência do processo de restabelecimento de energia às áreas afetadas.

É importante salientar que neste trabalho o MEAN foi aplicado a um sistema real de larga-escala atualizado (SDR Marília 2012). Em virtude disto, vários desafios foram encontrados no ajuste da base de dados exigindo bastante trabalho. Alguns pontos que carecem ser desenvolvidos já foram citados durante este trabalho, dentre eles merecem destaque: incorporar no código do programa a capacidade de trabalhar com bancos reguladores de tensão, a fim de processar uma base real e completa de dados; possibilidade de utilização de diferentes modelos de cargas e métodos de cálculo de fluxo de carga, a fim de refinar ainda mais os cálculos, quando for necessária exatidão nos valores de corrente e queda de tensão, por exemplo.

Vários trabalhos já vêm sendo desenvolvidos nesta área para aprimorar o MEAN. O uso de técnicas variadas que possibilitam melhorar os resultados encontrados (Sanches et al., 2012), assim como o tempo de processamento; dar prioridade na manobra de chaves automáticas, diminuindo o tempo efetivo do restabelecimento na prática; dar prioridade a cargas especiais como, por exemplo, hospitais; todas estas são pesquisas que já vêm sendo feitas.

Tendo em vista estas perspectivas de pesquisas futuras, a utilização de AE Multi-Objetivos em Tabelas, com estrutura de dados RNP, se apresenta como uma ferramenta promissora na área de distribuição de energia elétrica. Os benefícios de um restabelecimento, em caso de contingências, rápido e eficiente não alcançariam apenas os consumidores, mas também as próprias concessionárias, que teriam os custos com deslocamento de equipe no campo, além de custos com ressarcimento por causa dos indicadores de qualidade de energia, ambos diminuídos substancialmente.

## Referências Bibliográficas

Amabis, J.M. & Martho, G.R., 1985. *Curso básico de biologia* 3rd ed. E. M. Ltda, ed., São Paulo.

Benayoun, R. et al., 1971. *Linear programming with multiple objective functions: Step method (stem)*. *Mathematical Programming*, 1(1), pp.366-375.

Camillo, M. H. M, 2011. *Otimização de processo de restabelecimento de energia em tempo real utilizando técnicas de redes inteligentes (smart grids) e apoio à decisão dos operadores dos centros de operação da distribuição*. Qualificação de mestrado – USP.

Castro, R.E., 2001. *Otimização de Estruturas com Multi-objetivos via Algoritmos Genéticos de Pareto*. Tese de Doutorado UFRJ.

Castro, L. N., 2006. *Fundamentals of natural computing: Basic concepts, algorithms and applications*. CRC Press LLC.

CPFL, 2011. *Planejamento de Redes de Distribuição*. Orientação técnica CPFL.

Das, D., Nagi, H.S. & Kothari, D.P., 1994. *Novel method for solving radial distribution networks*. *Generation, Transmission and Distribution*, IEE Proceedings-, 141(4), pp.291-298.

Deb, K., 2001. *Multi-objective optimization using evolutionary algorithms*.

Deb, K. et al., 2002. *A fast and elitist multiobjective genetic algorithm: NSGA-II*. *Evolutionary Computation*, IEEE Transactions on, 6(2), pp.182-197.

Delbem, A. et al., 2004. *Node-Depth Encoding for Evolutionary Algorithms Applied to Network Design*. In Kalyanmoy Deb, ed. Springer Berlin / Heidelberg, pp. 678-687.

Delbem, A.C.B., de Carvalho, A.C.P.L.F. & Bretas, N.G., 2005. *Main chain representation for evolutionary algorithms applied to distribution system reconfiguration*. *Power Systems*, IEEE Transactions on, 20(1), pp.425-436.

Gabriel, P.H. & Delbem, A.C.B., 2008. *Fundamentos de Algoritmos Evolutivos*. USP.

Goldberg, D., 1989. *Genetic Algorithms in Search, Optimization, and Machine Learning* 1st ed., Boston, MA.

Gradshteyn, I.S. & Ryzhik, I.M., 2000. *Table of Integrals, Series, and Products* 6th ed., San Diego, CA.

De Jong, K.A., 2006. *Evolutionary computation: A unified approach*, Cambridge, MA: MIT Press.

Koza, J.R., 1989. *Genetic programming: On the programming of computers by means of natural selection*, Cambridge, MA: MIT Press.

Mansour, M. R., 2009. *Algoritmo para obtenção de planos de restabelecimento para sistemas de distribuição de grande porte*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

Mansour, M.R. et al., 2009. *Energy restoration in distribution systems using multi-objective evolutionary algorithm and an efficient data structure*. In PowerTech, 2009 IEEE Bucharest. pp. 1-7.

Marquez, R.A.C, 2012. *Restabelecimento de Energia em Sistemas de Distribuição de Energia Elétrica Através de Algoritmos Evolutivo e da Representação Nó-Profundidade*. Qualificação Mestrado-USP.

Penteado, J. B., 2011. *Análise do desempenho de subestações de energia elétrica a partir de critérios de confiabilidade*. Trabalho de Conclusão de Curso – EESC/USP.

Pigatin, V. N.; London, J. B. A., 2009. *Análise da Eficiência Computacional de Métodos para Cálculo de Fluxo de Carga*. Anais do Seminário Internacional de Iniciação Científica da USP.

PRODIST, 2012. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional*. Módulo 8 – Qualidade da Energia Elétrica. ANEEL.

Ridley, M., 1996. *Evolution*. 2 ed. Cambridge, MA: Blackwell Science, Inc.

Sanches, D.S., 2012. *Algoritmo Evolutivo MultiObjetivo para Reconfiguração de Redes Sistemas de Distribuição de Energia Elétrica*. Qualificação Doutorado-USP.

Sanches, D.S. et al., 2011. *Integrating relevant aspects of moeas to solve loss reduction problem in large-scale Distribution Systems*. In PowerTech, 2011 IEEE Trondheim. pp. 1-6.

Santos, A.C., 2009. *Algoritmo Evolutivo Computacionalmente Eficente para Reconfiguração de Sistemas de Distribuição*. Tese Doutorado-USP.

Santos, A.C., Delbem, A. & Bretas, N.G., 2008. *Energy restoration for large-scale distribution system using EA and a new data structure*. In Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE. pp. 1-8.

Santos, A.C. et al., 2010. *Node-Depth Encoding and Multiobjective Evolutionary Algorithm Applied to Large-Scale Distribution System Reconfiguration*. Power Systems, IEEE Transactions on, 25(3), pp.1254-1265.



Shirmohammadi, D. et al., 1988. *A compensation-based power flow method for weakly meshed distribution and transmission networks*. Power Systems, IEEE Transactions on, 3(2), pp.753-762.

Shirmohammadi, D., 1992. *Service restoration in distribution networks via network reconfiguration*. Power Delivery, IEEE Transactions on, 7(2), pp.952-958.

Souza, B.A., 1995. *Fluxo de potência em sistemas de distribuição*. Dissertação de Mestrado – UFPB.

Srinivas, M.S., 2000. *Distribution load flows: a brief review*. In Power Engineering Society Winter Meeting, 2000. IEEE. pp. 942-945 vol.2.

Ticona, W.G.C. & Delbem, A.C.B., 2008. *Algoritmos evolutivos para otimização multi-objetivo*. Relatório Técnico ICMC-USP.

Zitzler, E.; Thiele, L.; 1999. *An Evolutionary Algorithm for Multiobjective Optimization: The Strength Pareto Approach*. Relatório Técnico 43, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH), Zurich, Switzerland.



## **Apêndice A – Introdução aos Algoritmos Evolutivos**

Os Algoritmos Evolutivos (AEs) são métodos de otimização e busca inspirados nos princípios da Teoria de Darwin, isto é, são baseados em princípios que são encontrados na evolução dos sistemas biológicos. Esta apêndice introduz os principais conceitos sobre AEs os quais receberam maior atenção após a proposta dos Algoritmos Genéticos (AGs) por John Holland e a popularização dos mesmos por meio dos trabalhos de David Goldberg (Goldberg, 1989). Na seção A.1 são apresentados os fundamentos básicos de Algoritmos Evolutivos, sendo que A.1.1 apresenta a base biológica dos AEs, A.1.2 descreve os AEs, bem como as subáreas que merecem destaque e A.1.3 descreve os operadores genéticos. A seção A.2 introduz os principais aspectos da otimização multi-objetivo e algumas das técnicas de Algoritmos Evolutivos Multi-Objetivo (AEMO).

Para escrita deste apêndice utilizou-se (Mansour, 2009), (Gabriel e Delbem, 2008) e (Ticona e Delbem, 2008) como referências principais.

### **A.1 Fundamento de Algoritmos Evolutivos**

#### **A.1.1 Base biológica**

Os AEs podem ser vistos como técnicas de Computação Bioinspirada ou Computação Natural. Tais áreas de pesquisa abordam uma série de técnicas computacionais fundamentadas em conceitos Biológicos. As técnicas evolutivas apresentam conceitos cuja origem está em diversos campos da Biologia, em especial em idéias evolucionistas e na Genética. Esta seção foca nesses conceitos e resume a terminologia empregada na definição de AEs.

##### **A.1.1.2 O processo evolutivo**

Os AEs são fortemente inspirados em processos evolutivos que ocorrem na natureza. Segundo De Jong (2006), os principais componentes dos sistemas evolutivos são:

- Populações de indivíduos: uma ou mais populações concorrem por recursos limitados;
- Aptidão, que reflete a habilidade do indivíduo para sobreviver e reproduzir-se;
- A noção de mudanças dinâmicas nas populações devido ao nascimento e morte dos indivíduos;
- Os conceitos de variabilidade e hereditariedade, ou seja, os novos indivíduos possuem muitas das características de seus pais, embora não sejam idênticos.

Tais conceitos foram inspirados na chamada Teoria Sintética da Evolução, também conhecida como *neodarwinismo* (Ridley, 1996). O neodarwinismo admite que os principais fatores evolutivos são a *mutação*, a *recombinação gênica* e a *seleção natural*, os quais são resumidos a seguir:

- **Mutação gênica**

A origem da variabilidade é a mutação, processo pelo qual o gene (segmento de DNA que contém uma informação codificada para determinada característica ou processo que a célula tem ou executa) sofre alterações em sua estrutura. Tais alterações são modificações na sequência de bases do DNA. Essa molécula, quando duplicada, produz cópias idênticas de si, ou seja, diferentes da original (sem mutação), transmitindo hereditariamente a mudança. Isso pode acarretar a alteração da sequência de aminoácidos da proteína, modificando o metabolismo celular, podendo favorecer o organismo ou mesmo ser letal.

- **Recombinação gênica**

O processo evolutivo seria relativamente lento se não fosse possível colocar juntas, em um mesmo indivíduo, mutações ocorridas em indivíduos da geração anterior. O fenômeno que possibilita esse evento é a reprodução sexuada. É importante considerar que a seleção natural não atua aceitando ou rejeitando mudanças individuais, mas sim escolhendo as melhores combinações gênicas entre todas as variações presentes na população.

- **Seleção Natural**

A seleção natural é consequência de dois fatores:

1. Os membros de uma espécie diferem entre si;
2. A espécie produz descendência em maior número de indivíduos que de fato podem sobreviver.

Os indivíduos mais aptos a sobreviver são aqueles que, graças à variabilidade genética, herdaram a combinação gênica mais adaptada para determinadas condições naturais.

### A.1.1.2 Terminologia Básica

Apresenta-se, a seguir, a terminologia necessária para o estudo de AEs.

#### **Cromossomos, genes e alelos**

A estrutura que codifica como os organismos são construídos é chamada **cromossomo**. Os cromossomos associam-se de modo a formar um organismo e seu número varia de uma espécie para outra (Amabis e Martho, 1985). O conjunto completo de cromossomos de um ser vivo é chamado **genótipo** e as características do organismo gerado com base no genótipo constituem o **fenótipo**. De forma similar, a representação de soluções de um problema podem ser codificadas em uma estrutura de dados chamada cromossomo. Os cromossomos são codificados em um conjunto de símbolos chamados **genes**. Os diferentes valores de um gene são chamados **alelos**. A posição de um gene em um cromossomo é denominada locus.

A representação das soluções candidatas (ou seja, os indivíduos) é o primeiro estágio da elaboração de um AE e é crucial para o desempenho do algoritmo. Essa etapa consiste em definir o genótipo e a forma como este é mapeado no fenótipo. A codificação mais simples é a **codificação binária**: o genótipo é definido como um arranjo de 0s e 1s. É necessário definir o tamanho do arranjo, bem como o mapeamento genótipo-fenótipo. Entretanto, em muitas aplicações do mundo real, a representação binária pode apresentar fraco poder de expressão (Deb, 2001), não sendo eficiente na representação das possíveis soluções. Uma alternativa empregada é a **representação em ponto-flutuante ou representação real**, segundo a qual as soluções são arranjos de números reais. Essa representação é usualmente empregada quando os genes são distribuídos em um intervalo contínuo, em vez de um conjunto discreto de valores discretos.

#### ***Fitness***

O valor de *fitness* de um indivíduo (seja um genótipo ou um cromossomo) é um número positivo que mede o quanto adequado é o indivíduo, que representa uma solução. Em problemas de otimização, o *fitness* pode ser o custo da solução. Se o problema for de minimização, as soluções de maior *fitness* são as de menor custo.

#### **Pais, Operadores de Reprodução e Descendentes**

Os AEs trabalham sobre um ou mais cromossomos a fim de gerar novas soluções, chamadas **descendentes**. Os operadores que trabalham sobre cromossomos, chamados operadores de reprodução, são a **recombinação** (também conhecido como **crossover**) e a **mutação**. Esses operadores fazem analogia aos principais mecanismos da evolução natural, ou seja, a recombinação e a mutação gênica. A recombinação é aplicada, em geral, a um par de cromossomos. Os indivíduos selecionados para o

processo de recombinação são chamados **pais**. A mutação é aplicada a um simples cromossomo, modificando-o aleatoriamente.

### Geração e seleção

A **geração** é uma iteração do AE, na qual os indivíduos da população atual são selecionados e recombinados e/ou mutados, gerando descendentes. Devido à criação de novos descendentes, o tamanho da população cresce; deste modo um mecanismo de **seleção** controla esse tamanho. A idéia básica da seleção é a seguinte: seja uma população de tamanho  $M$  e seja  $N_d$  o número de descendentes, então, para a próxima geração, são selecionados  $M$  novos indivíduos ( $N_d$  pode ser maior que  $M$ ). Cada AE desenvolve, com base nesse princípio, uma estratégia de seleção.

### A.1.2 Algoritmos Evolutivos

Os AEs funcionam basicamente da seguinte maneira:

1. Primeiramente é criada uma população inicial com soluções aleatórias;
2. A partir da população atual, é gerada uma nova população. Os novos indivíduos desta nova população, são criados através do uso dos operadores genéticos. Esta tarefa é realizada aplicando-se o operador de cruzamento de indivíduos nos indivíduos com melhor *fitness*, que são escolhidos através de um processo chamado de seleção;
3. Retorna-se para o item 2 até atendimento do critério de parada.

O algoritmo 6 mostra o pseudocódigo de um AE.

---

**Algoritmo 6:** Pseudocódigo de um AE (Marquez, 2012).

---

#### ALGORITMO EVOLUTIVO

```

1: // Inicia o contador de tempo
2:
3: Inicia População ( )
4: // Avalia o fitness dos indivíduos
5: Avalia
6: // Verifica o critério de parada
7: ENQUANTO critério de parada não é atingido FAÇA
8:     // Incrementa a geração
9:
10:    // Seleciona os indivíduos para a geração dos descendentes
11:
12:    // Realiza o cruzamento dos pais selecionados
13:    Cruzamento
14:    // Realiza a mutação sobre a nova população
15:    Muta
16:    // Avalia o fitness dos indivíduos

```

---

---

17: Avalia (  
18:**FIM**

---

Os AEs são utilizados para problemas de otimização em decorrência de ser o método preferencialmente utilizado pela natureza, que é considerada por muitos como o sistema mais perfeito. Além disso, resolvem problemas com modelos matemáticos complexos de modo simples, sendo de fácil acoplamento com outras técnicas (hibridação) (dos Santos, 2004).

Existem várias subáreas na Computação Evolutiva, das quais destacam-se:

### **Algoritmos Genéticos (AG)**

Tais algoritmos foram propostos por Holland na década de 1970 e trabalham com populações de indivíduos (cromossomos), que durante o processo de evolução são submetidos aos procedimentos de seleção e reprodução. Deste modo o algoritmo consegue aproveitar das melhores soluções e ao mesmo tempo explorar o espaço de busca.

### **Programação Evolutiva (PE)**

Foi proposta por Lawrence J. Fogel na década de 1960, originalmente como uma estratégia de otimização estocástica similar aos AGs. No entanto, enfatiza o relacionamento entre os progenitores e seus descendentes ao invés de tentar emular operadores genéticos específicos observados na natureza (Castro, 2001). A PE também opera com populações, mas apenas diferentes níveis de mutação são efetuados sobre os progenitores na criação de novas soluções. O tamanho da população não necessita ser mantido constante, como também não é necessário um número fixo de descendentes por progenitor. A PE trabalha com representações mais flexíveis que as empregadas pelos AGs por não efetuarem recombinações.

### **Programação Genética (PG)**

A Programação Genética (PG) foi proposta em (Koza, 1989) e pode ser vista como uma extensão dos AGs. A PG difere dos AEs devido à sua representação, seus operadores de reprodução e seus métodos de avaliação de fitness. Introduzida para solucionar os problemas de aprendizado de máquina, a PG busca a construção automática de programas de computadores. Os indivíduos são codificados na forma de árvores, onde cada nó folha contém constantes, variáveis ou parâmetros para a execução de procedimentos e funções. Os nós internos contém operações primárias. Os operadores de reprodução utilizados são operadores de recombinação e mutação específicos para representação por árvores. Na recombinação, partes das árvores são trocadas, o ponto de corte na árvore é escolhido de forma a evitar a criação de operações inválidas. Na mutação, o valor de um nó ou subárvore é alterado. Se o nó

escolhido para a mutação for um nó interno, este será alterado para ter uma nova operação ou função. No caso de mutação da subárvore, a subárvore selecionada é substituída por uma nova subárvore gerada aleatoriamente.

O processo de avaliação ocorre por meio da execução do programa representado pela árvore do indivíduo. Se este resolver o problema proposto ou se aproximar da resposta correta, terá um valor de *fitness* elevado; caso contrário, seu *fitness* será baixo. Geralmente, os algoritmos de PG utilizam somente o operador de recombinação no processo de busca de melhores soluções.

### **Estratégias Evolutivas (EE)**

Propostas originalmente para tratarem problemas técnicos de otimização como alternativa aos métodos convencionais. Operam com cromossomos na forma de vetores de números reais e originalmente na proporção  $(1 + 1)$ , isto é, cada progenitor gera um herdeiro por geração, normalmente por mutações distribuídas. Caso esse descendente seja melhor que seu progenitor, ele lhe toma o lugar. Essas estratégias foram estendidas para as proporções  $(m + 1)$ , isto é,  $m$  progenitores geram um herdeiro por geração, e  $(m + n)$ , isto é,  $m$  progenitores geram  $n$  herdeiros por geração. As EE tiveram estratégias de recombinações introduzidas no seu processo evolutivo (Castro, 2006).

### **A.1.3 Operadores Genéticos**

Nesta seção são abordados os principais aspectos dos operadores genéticos utilizados nos AEs.

#### **A.1.3.1 Seleção**

O objetivo deste operador é escolher um ou mais indivíduos para gerar um ou mais descendentes para a próxima população do processo evolutivo. Os indivíduos com o melhor grau de *fitness* têm uma maior probabilidade de serem escolhidos nesta etapa.

Existe na literatura, uma grande variedade de estratégias de seleção. Porém, as mais utilizadas são a **seleção por torneio**, **roda da roleta** e **ranking**.

Na **seleção por torneio**, são realizadas várias competições entre duas ou mais soluções, e a melhor solução é a escolhida. Na **roda da roleta**, geralmente, os pais são selecionados com probabilidade proporcional ao *fitness*. Para tal seleção usa-se a expressão abaixo:

---



onde  $F_i$  é o fitness da solução  $i$  e  $N$  é o tamanho da população. Logo, é gerado um valor aleatório  $k$ , no intervalo de 0 a PTOTAL (soma de todos os valores de *fitness*). Finalmente, o indivíduo selecionado é o primeiro que possui uma probabilidade de seleção maior que  $k$ . Na **seleção por ranking**, são ordenadas as soluções de acordo com o seu valor de *fitness* (sendo *ranking* 1 pertencente a pior solução e o *ranking*  $N$  pertencente a melhor solução, sendo  $N$  o número de soluções). Com isso, determina-se a probabilidade de seleção de para cada solução. Logo, a escolha das soluções progenitoras é referente ao valor de *ranking*.

### A.1.3.2 Cruzamento

O operador de cruzamento gera as soluções descendentes das soluções progenitoras. Basicamente, para cada duas soluções progenitoras selecionadas corta-se o seu vetor de símbolos em uma posição aleatória, produzindo duas cabeças e duas caudas. Em seguida, as caudas são trocadas, gerando dois novos indivíduos (figura A.1).

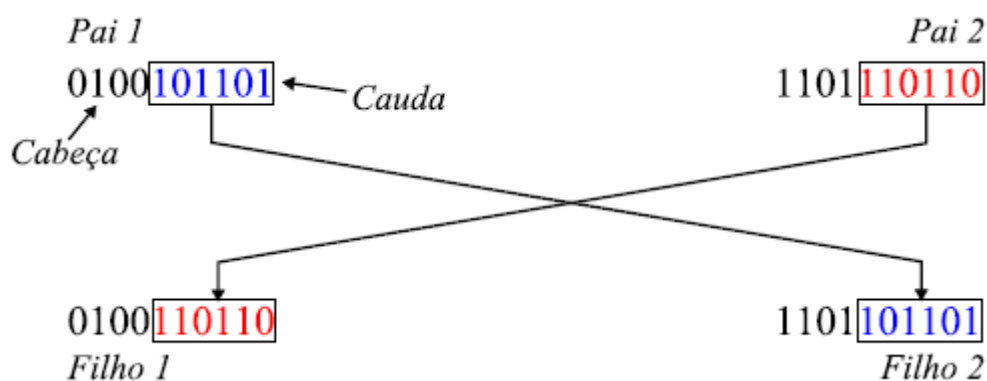


Figura A.1. Exemplo de aplicação do operador de cruzamento em um ponto

Existem diversas variações desse operador, vários deles são específicos para determinado problema (Goldberg, 1989).

### A.1.3.3 Mutação

Esse operador gera uma determinada taxa de “perturbação” em um determinado número de soluções, isto é, gera pequenas alterações em um determinado número de soluções, com o objetivo de explorar o espaço de busca (figura A.2) e manter a diversidade das soluções. Desta forma, o AE tende a não ter uma convergência rápida,

evitando sua estabilização em regiões chamadas de mínimos locais, nos quais os AEs sempre estão sujeitos a cair.

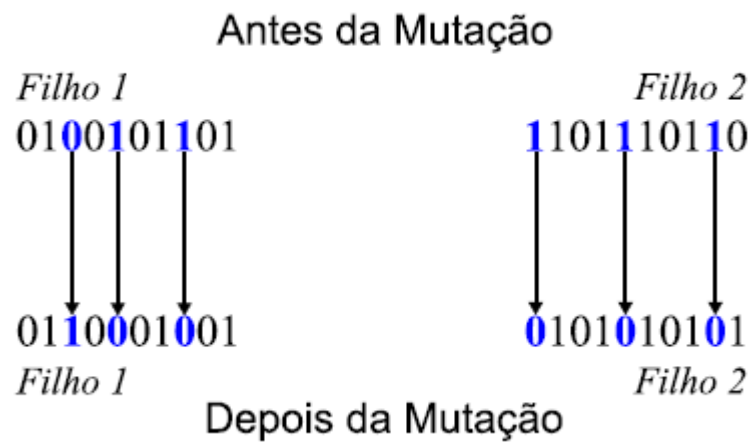


Figura A.2. Exemplo de aplicaç o do operador de mutaç o

#### A.1.3.4 Elitismo

Existe um grande risco de perder os melhores indiv duos na transiç o de uma geraç o para outra, isto devido   aplicaç o dos operadores de mutaç o e cruzamento. Desse modo, o objetivo do operador de elitismo   preservar os melhores indiv duos para as pr ximas geraç es que possam surgir, sem que esses sofram alguma alteraç o. Assim, as melhores soluç es n o se deterioram.

## A.2 Problemas de Otimizaç o Multi-Objetivo

Problemas que envolvem a otimizaç o de v rios objetivos simultaneamente, que, em geral, s o conflitantes, s o chamados de problemas de otimizaç o multi-objetivo (MOOP, do ingl s *Multi-Objective Optimization Problem*). Um MOOP possui um conjunto de funç es objetivo a serem otimizadas (maximizar ou minimizar). Al m disso, possui restriç es que devem ser satisfeitas para que uma soluç o seja fact vel ao problema. O enunciado geral de um MOOP   o seguinte (Deb, 2001):

Maximizar/minimizar  
sujeito a:

}  
}

onde  $x$  é um vetor de  $N_{var}$  variáveis de decisão,  $x = (x_1, x_2, \dots, x_{N_{var}})^T$ , também denominado de solução. Os valores  $x_{min}$  e  $x_{max}$  representam os limites inferior e superior, respectivamente, para a variável  $x_i$ . Esses limites definem o espaço de variáveis de decisão ou espaço de decisão  $S_{dec}$ . As desigualdades ( ) e as igualdades ( ) são chamadas de funções de restrição. Uma solução  $x$  factível satisfaz as  $m$  +  $n$  funções de restrição e os 2 limites. Caso contrário, a solução não será factível. O conjunto de todas as soluções factíveis formam a região factível ou espaço de busca  $S_{fact}$ .

Cada função  $f_i$  pode ser maximizada ou minimizada. Porém, para trabalhar com os algoritmos de otimização, é necessário converter todas as funções para serem apenas de maximização ou minimização. O vetor de funções objetivo  $f = (f_1, f_2, \dots, f_m)^T$  compõe um espaço multidimensional chamado espaço de objetivos  $S_{obj}$ . Para cada solução  $x$ , no espaço de decisão, existe um  $f(x)$  em  $S_{obj}$ . Esta é uma diferença fundamental em relação à otimização de objetivos simples, cujo espaço de objetivos é unidimensional. O mapeamento ocorre então entre um vetor  $x$  (de dimensão  $N_{var}$ ) e um vetor  $f(x)$  (de dimensão  $m$ ). Por exemplo, se cada elemento de  $x$  e  $f(x)$  são números reais, então  $f(x)$  estaria mapeada como  $f(x) = (f_1(x), f_2(x), \dots, f_m(x))^T$ .

### A.2.1 Soluções Pareto-Ótimas

As funções objetivo empregadas nos MOOPs são em geral conflitantes entre si, ou seja, quando não é possível melhorar o valor de  $f_i$  sem piorar o valor da função  $f_j$ . Em (Deb, 2001) encontramos um exemplo prático de objetivos conflitantes que é a tomada de decisão a partir de dois critérios (custo e conforto) para compra de um automóvel. Quanto mais confortável o automóvel, maior será o custo. Na Figura A.3 são ilustradas algumas alternativas de escolha.

Portanto temos como objetivo uma minimização do custo e uma maximização do conforto. Pela Figura A.3 tem-se 6 opções de compra, e por intuição a opção 5 é descartada, pois possui o mesmo conforto que opção 3 com maior custo. Ao analisar as opções 2 e 6, observa-se que a solução 6 também deve ser descartada, pois possui menor conforto e maior custo em relação à solução 3. Então, após eliminar-se as soluções ruins, tem-se 4 opções (1, 2, 3 e 4) como boas alternativas para compra. Dentre essas soluções, não se pode afirmar qual é a melhor, pois quando uma tem maior conforto, também tem maior custo, e vice versa. Assim, pode-se afirmar que uma solução domina outra solução, quando é melhor que a outra em pelo menos 1 objetivo e não pior em todos os demais objetivos. Da Figura A.3 tem-se que a solução 3 domina a

solução 5 e a solução 2 domina a solução 6. Portanto, as soluções 5 e 6 são dominadas e as soluções 1, 2, 3 e 4 não são dominadas por nenhuma outra. Tem-se então o conjunto das soluções não-dominadas (1, 2, 3 e 4) e o conjunto das soluções dominadas (5 e 6).




Figura A.3. Curva Conforto x Custo

Em um MOOP, emprega-se o conceito de Dominância de Pareto para comparar duas soluções factíveis de um problema. Dadas duas soluções  $x$  e  $y$ , diz-se que  $x$  domina  $y$ , denotado como  $x \leq y$ , se as seguintes condições forem satisfeitas:

1. A solução  $x$  é pelo menos igual a  $y$  em todas as funções objetivo;
2. A solução  $x$  é superior a  $y$  em pelo menos uma função objetivo.

Observe que existe um conjunto de alternativas ótimas que são não-dominadas entre si nos objetivos de custo e desempenho. Em um MOOP, o conjunto de soluções não-dominadas é chamado de conjunto **Pareto-ótimo**, que representa as soluções ótimas do problema. A **fronteira de Pareto** é o conjunto dos valores das funções objetivo das soluções do conjunto Pareto ótimo.

### A.2.2 Metas em Otimização Multi-Objetivo

Em (Deb, 2001) são destacadas três importantes metas em otimização multi-objetivo:

1. Encontrar um conjunto de soluções que esteja o mais próximo possível da fronteira de Pareto;
2. Encontrar um conjunto de soluções com a maior diversidade possível;
3. Realizar as duas metas anteriores com a maior eficiência computacional possível.

A primeira meta é comum a qualquer processo de otimização. Soluções muito distantes da fronteira de Pareto não são desejáveis. Por outro lado, encontrar a maior

diversidade dentro das soluções é a meta específica para otimização multi-objetivo. A figura A.4a ilustra uma distribuição quase uniforme das soluções na fronteira de Pareto. A figura A.4b ilustra a fronteira com soluções apenas em algumas regiões, isto é, com baixa diversidade. É necessário assegurar a maior cobertura possível da fronteira.




Figura A.4. Diferentes distribuições na fronteira de Pareto

Com MOOP trabalha-se com o espaço de decisões e o espaço de objetivos, é também desejável que as soluções estejam adequadamente distribuídas em ambos os espaços. Em geral, a diversidade em um desses espaços garante também a diversidade no outro. Entretanto, para alguns problemas isso não acontece. Tendo em vista que encontrar um conjunto de soluções uniformemente distribuído é uma tarefa que pode consumir consideráveis recursos computacionais, é necessário que tais soluções sejam obtidas eficientemente.

### A.2.3 Diferenças entre Otimização Multi-Objetivo e a Otimização Mono-Objetivo

Em Deb (2001) identificam-se três importantes aspectos que diferenciam a otimização multi-objetivo da otimização mono-objetivo, sendo eles:

1. Em problemas de otimização mono-objetivo, a meta é encontrar uma solução ótima global. Se a função objetivo desses problemas for multimodal, poderia existir mais de um ótimo global. Neste caso, todos os ótimos são equivalentes. Por outro lado, em MOOP, determinar um conjunto de soluções da fronteira de Pareto é tão importante quanto preservar a diversidade deste conjunto. Um algoritmo eficiente para otimização multi-objetivo deve considerar ambos aspectos;

2. Nos problemas de otimização multi-objetivo trabalha-se com os espaços das variáveis e dos objetivos, enquanto que os problemas com um objetivo trabalham unicamente no espaço das variáveis, já que procura-se apenas uma solução no espaço dos objetivos. Desta forma, manter a diversidade nos espaços das variáveis e dos objetivos torna a solução dos problemas multi-objetivo mais complicada, pois a proximidade de duas soluções no espaço das variáveis não implica proximidade no espaço dos objetivos;
3. Os métodos tradicionais de otimização multi-objetivo reduzem o conjunto de funções objetivo a uma função simples que pondera cada objetivo. Estes métodos podem também tratar cada objetivo separadamente, utilizando os demais objetivos como restrições. Portanto, um MOOP pode ser convertido, por meio de algumas técnicas, em um problema de otimização simples.

#### A.2.4 Algoritmos Evolutivos para Otimização Multi-Objetivo

Os AEs são promissores para serem empregados em MOOP, em razão de apresentarem as seguintes características: trabalham com mais de uma função simultaneamente, não precisam de informações adicionais e são capazes de escapar de ótimos locais. Neste contexto, nas próximas subseções serão apresentados alguns AEMO disponíveis na literatura.

Para escrita desta seção tomou-se como referência principal (Sanches, 2012).

##### A.2.4.1 NGS-II: *Elitist Non-Dominated Sorting Genetic Algorithm*

Proposto por Deb et al. (2002), o algoritmo *Elitist Non-Dominated Sorting Genetic Algorithm* (NGSA-II) baseia-se na ordenação elitista por dominância chamado de **Pareto ranking**. Esse procedimento consiste em classificar as soluções de um conjunto  $M$  em diversas fronteiras ( , onde  $k$  é o número de fronteiras) conforme o grau de dominância de cada solução. Deste modo, a fronteira  $k$  contém as soluções não dominadas de todo o conjunto de soluções  $M$ ,  $k+1$  contém as soluções não dominadas de  $M - F_k$ ,  $k+2$  contém as soluções não dominadas de  $M - F_k - F_{k+1}$  e assim sucessivamente.

O procedimento de ordenação por não dominância proposto por Deb et al. (2002) é descrito no Algoritmo 7. Para cada solução  $i$ , contida em  $P$ , são calculados dois valores:

- $n_i$ , o número de soluções que dominam a solução  $i$ ;

- $\mathcal{D}_i$ , o conjunto de soluções que são dominadas pela solução  $i$ .

As linhas 1-15 do Algoritmo 7 calculam tais valores para as soluções em  $M$ . Além disso, as soluções com  $\mathcal{D}_i = \emptyset$  estão contidas na fronteira  $\mathcal{F}_1$ . Em seguida, as linhas 17-29 percorrem o conjunto de soluções dominadas  $\mathcal{D}_i$ , para solução  $i$  em  $\mathcal{F}_1$ . O contador  $n_i$ , de cada solução  $i$  em  $\mathcal{D}_i$ , é decrementado em 1. Se  $n_i = 0$ , então a solução  $i$  pertence à próxima fronteira, neste caso,  $\mathcal{F}_2$ . Essa iteração é repetida até que todas as soluções estejam classificadas em uma fronteira. A Figura A.5 ilustra este procedimento aplicado às soluções que minimizam  $f_1$  e  $f_2$ .




Figura A.5. Ordenação por não dominância (Deb, 2001)

O NSGA-II trabalha com duas populações denotadas por  $P$  e  $Q$ , ambas de tamanho  $N$ . As populações  $P$  e  $Q$  em cada iteração são denotadas por  $P_t$  e  $Q_t$  respectivamente. Na primeira geração, os indivíduos iniciais da população  $P$  geram as soluções  $P_1$ , através da aplicação dos operadores genéticos. Após esta etapa, se inicia um processo competitivo para preencher  $N$  vagas para a solução  $P_{t+1}$ , entre  $N$  indivíduos contidos em  $P_t \cup Q_t$ . Esta operação é realizada utilizando a ordenação não dominância em  $P_t \cup Q_t$ , encaminhando as soluções não dominadas contidas nas fronteiras diretamente para a próxima geração (elitismo).

Para garantir a diversidade na fronteira o NSGA-II emprega uma estimativa de densidade das soluções que rodeiam cada indivíduo da população. Assim, calcula-se a média da distância das duas soluções adjacentes a cada indivíduo para todos os objetivos, onde este valor é denominado distância de multidão. O algoritmo 8 descreve os passos para calcular tal valor, onde  $d_i$  é o valor da distância da multidão do indivíduo  $i$ .

ésimo indivíduo do conjunto (denotado como  $x_i$ ) e  $f(x_i)$  é o valor da  $i$ -ésima função objetivo para o  $i$ -ésimo indivíduo.

---

**Algoritmo 7:** Ordenação por não-dominância (Sanches, 2012)

---

```
1: for  $i = 1$  to  $n$  do
2:
3:
4:   for  $j = 1$  to  $n$  do
5:     if  $f(x_i) \leq f(x_j)$  then
6:
7:       end if
8:     if  $f(x_j) \leq f(x_i)$  then
9:
10:      end if
11:   end for
12:   if  $f(x_i) \leq f(x_j)$  then
13:
14:   end if
15: end for
16:
17: while  $n > 1$  do
18:
19:   for  $i = 1$  to  $n$  do
20:     for  $j = i + 1$  to  $n$  do
21:
22:       if  $f(x_i) \leq f(x_j)$  then
23:
24:       end if
25:     end for
26:   end for
27:
28:
29: end while
```

---



---

**Algoritmo 8:** Calculo de distância de multidão (Sanches, 2012)
 

---

```

1: for  $p \in P$  do
2:
3: end for
4: for  $p \in P$  do
5:   Classificar  $p$  por  $f(p)$ , em ordem decrescente
6:
7:   for  $q \in P$  do
8:     Classificar  $q$  por  $f(q)$ , em ordem decrescente
9:
10:   end for
11: end for

```

---

O *fitness* de cada solução é determinado pelos seguintes valores:

1.  $r(p)$ , o valor de *ranking* é igual ao número da fronteira à qual pertence;
2.  $d(p)$ , é o valor da distância de multidão.

O NSGA-II emprega um processo de seleção por torneio, que é guiado por um novo operador denominado crowded-comparison operator. Em tal abordagem, duas soluções são comparadas para escolher qual delas vai gerar descendentes na nova população. Uma solução é escolhida sobre uma solução se:

1. possui um *ranking* menor que  $r(q)$ , ou seja,  $r(p) < r(q)$ ;
2. Se ambas as soluções possuem o mesmo *ranking* e  $p$  possui um maior valor de distância de multidão, ou seja,  $d(p) > d(q)$ .

O cálculo da distância de multidão permite que as soluções melhores espalhadas passem a ocupar as últimas vagas disponíveis de  $N$ , garantindo a diversidade das soluções. A população é gerada utilizando os operadores de seleção por torneio, recombinação e mutação em  $N$ . O NSGA-II continua por  $T$  iterações e as soluções finais encontram-se em  $P$ . A sequência de passos do NSGA-II é descrita no Algoritmo 9. A Figura A.6 ilustra o esquema para uma iteração do NSGA-II.

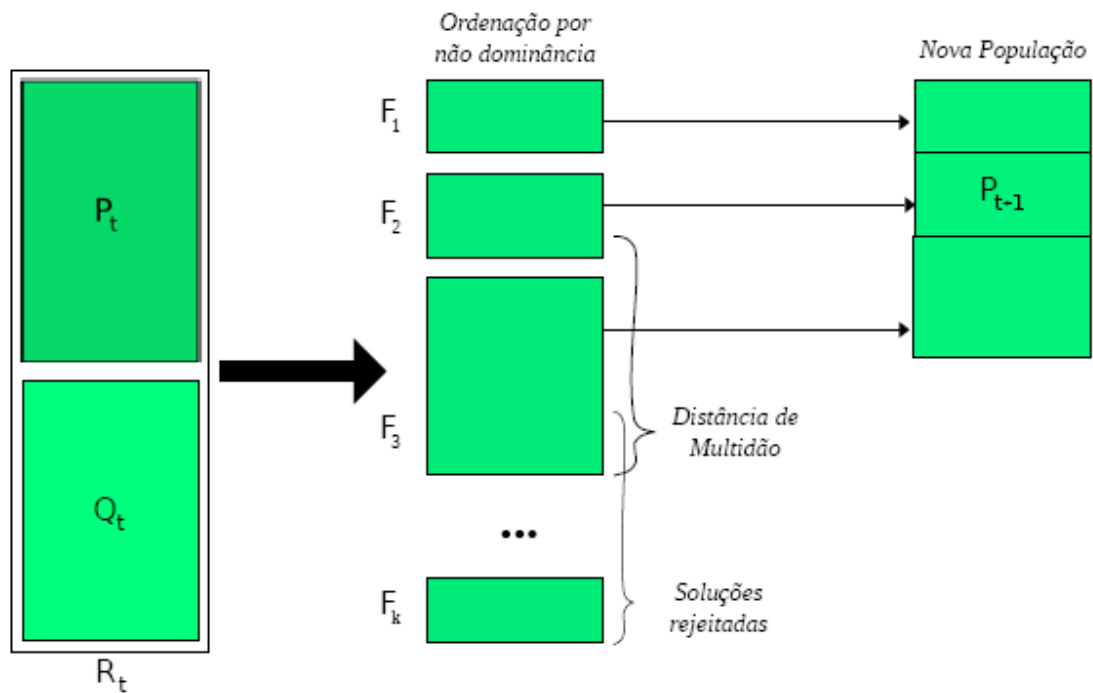


Figura A.6. Esquema do modelo NSGA-II (Deb, 2001).

---

**Algoritmo 9:** NSGA-II (Sanches, 2012).

---

- 1: Cria uma população de soluções aleatórias e de indivíduos
  - 2: Ordenar utilizando o algoritmo 2
  - 3: Gerar a população de tamanho , aplicando os operadores genéticos em .
  - 4: **for** geração **do**
  - 5:     Aplicar algoritmo 2 em
  - 6:
  - 7:     **while** **do**
  - 8:         Aplicar algoritmo 3 em
  - 9:
  - 10:
  - 11:     **end while**
  - 12:     Aplicar o algoritmo 3 em
  - 13:     Classificar a fronteira pelo e a distância usando operador
  - 14:     Copiar as primeiras soluções de para
  - 15:     Gerar a nova população aplicando os operadores genéticos em
  - 16: **end for**
  - 17:
  - 18:
-

#### A.2.4.2. SPEA 2: Strength Pareto Evolutionary Algorithm

O SPEA 2, proposto por (Zitzler & Thiele 1999), também utiliza duas populações e . Na população , chamada de população externa, são armazenadas apenas as soluções não dominadas encontradas pelo algoritmo. O tamanho da população , denotado como é fornecido como parâmetro. As populações e em cada iteração são representadas por e , respectivamente.

No SPEA 2 cria-se, inicialmente, uma população aleatória e uma população externa inicialmente vazia. Em cada iteração, a função aptidão é calculada para cada solução  $i$  em  $R_t = P_t \cup Q_t$ . Para isso são utilizados os conceitos de dominância e densidade, que será definida a seguir. O objetivo é minimizar o valor da função de aptidão. Quanto menor o valor da função de aptidão de um indivíduo, melhor é adaptação do indivíduo. A força de cada indivíduo é dada pelo número de soluções que ele domina:

Este valor de representa o número de soluções em dominadas pela solução . Portanto, soluções com seu valor de igual a zero são soluções que não-dominam nenhuma outra. O valor de aptidão bruto do indivíduo, denotado por  $raw_i$ , que é a soma das forças de todos os indivíduos, é calculado como segue:

Conforme a equação acima, que apresenta o somatório dos valores de , assim as soluções não dominadas tem um valor igual a zero, enquanto as soluções com um alto são dominadas por muitas soluções em .

A densidade do indivíduo é uma função decrescente em relação ao -ésimo vizinho mais próximo. A inclusão de um fator de densidade se deve ao fato de que, nos casos em que existem muitas soluções não dominadas, se aproxima de zero para todas as soluções. Nesse caso, é necessário haver um mecanismo para privilegiar soluções dentre as não dominadas.

Para cada indivíduo , as distâncias (no espaço dos objetivos) entre e todos os indivíduos da população e da população externa são calculadas pela equação abaixo e armazenadas em uma lista. Depois de ordenada a lista em ordem crescente, o -ésimo elemento representa o termo . Sugere-se para o valor de \_\_\_\_\_.

Finalmente, a aptidão final para cada solução em  $P$ , denotada por  $f$ , é dada por:

### Algoritmo de Corte

O algoritmo de corte do SPEA 2 tem como objetivo restringir o tamanho de  $P$  a  $n$  soluções. Durante cada iteração remove-se a solução cuja distância, para seu vizinho mais próximo, seja a menor dentre as distâncias, e assim sucessivamente. Formalmente, uma solução  $p$  é eliminada de  $P$  se as seguintes condições forem satisfeitas:

, ou;

Onde,  $d_1$ ,  $d_2$  e  $d_3$ , representam as distâncias de  $p$  em relação a seu primeiro,  $k$ -ésimo e  $(k+1)$ -ésimo vizinho mais próximo, chamado de  $p_1$ . Com isso, são eliminadas soluções em  $P$  até reduzir o seu tamanho para  $n$ .

A Figura A.7 nos mostra um conjunto de soluções que pertence à população externa  $P$ . Depois de aplicar o algoritmo de corte, algumas soluções são eliminadas, conforme ilustrado na figura. Além disso, o algoritmo de corte garante que as soluções extremas para cada objetivo sejam mantidas.




Figura A.7. Algoritmo de Corte no modelo SPEA 2 (Zitzler & Thiele 1999).

#### A.2.4.3 Algoritmo Evolutivo Multi-Objetivo em Tabelas

O AE Multi-objetivo em Tabelas, denominado MEAN, segundo (Santos et al. 2010 E Benayoun et al. 1971), trabalha com várias subpopulações em paralelo armazenadas em tabelas, onde os melhores indivíduos para cada característica do problema são armazenados em sua respectiva subpopulação (cada subpopulação é representada por

uma tabela). Uma importante característica do MEAN é o uso de uma subpopulação para armazenar indivíduos avaliados por uma função agregação, também conhecida como soma ponderada (Deb, 2001). O indivíduo selecionado para reprodução pode ser proveniente de qualquer subpopulação (ou tabela). Essa estratégia de seleção aumenta a diversidade entre os indivíduos que se reproduzem, pois as características de um indivíduo de uma subpopulação podem migrar para as demais subpopulações. Em consequência, aumenta-se a possibilidade de o algoritmo escapar de ótimos locais, aproximando-se de soluções com avaliações próximas de um ótimo global na fronteira de Pareto-ótima.

Conforme (Santos et al 2010), alguns parâmetros são importantes para o MEAN:

O tamanho de cada subpopulação  $n_i$ , que indica o número máximo de indivíduos que podem permanecer na subpopulação  $P_i$  de uma geração para outra;

O número máximo de gerações ( $G$ ).

Soluções (ou indivíduos) geradas pelo MEAN podem ser armazenadas ou descartadas, dependendo do grau de adaptação do indivíduo a cada objetivo do problema (características do problema em uma subpopulação  $P_i$ ).

Durante o processo de seleção de sobreviventes, um novo indivíduo é acrescentado a uma subpopulação  $P_i$  se sua adequação ao objetivo de  $f_i$  for melhor que pelo menos um indivíduo da mesma. É importante destacar que o mesmo indivíduo pode ser incluído em mais de uma tabela de acordo com esse critério de seleção. Como a população é estacionária, os novos indivíduos substituem os piores.