

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ENGENHARIA ELÉTRICA
CURSO DE ENGENHARIA ELÉTRICA

LUCIANA MENEZES XAVIER DE SOUZA

**ANÁLISE COMPARATIVA DE ALGORITMOS EVOLUTIVOS
MULTIOBJETIVO APLICADOS NO PROBLEMA DE
RESTABELECIMENTO DE ENERGIA ELÉTRICA**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO

2015

LUCIANA MENEZES XAVIER DE SOUZA

**ANÁLISE COMPARATIVA DE ALGORITMOS EVOLUTIVOS
MULTIOBJETIVO APLICADOS NO PROBLEMA DE
RESTABELECIMENTO DE ENERGIA ELÉTRICA**

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do título de Engenheira Eletricista pela Universidade Tecnológica Federal do Paraná – Campus Cornélio Procópio.

Orientador: Prof. Dr. Marcelo Favoretto Castoldi.

Coorientador: Prof. Dr. Danilo Sipoli Sanches.

CORNÉLIO PROCÓPIO

2015



**Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento de Engenharia Elétrica
Curso de Engenharia Elétrica**



FOLHA DE APROVAÇÃO

Luciana Menezes Xavier de Souza

Análise comparativa de algoritmos evolutivos multiobjetivo aplicados no problema de restabelecimento de energia elétrica

Trabalho de conclusão de curso apresentado às 14:00hs do dia 02/06/2015 como requisito parcial para a obtenção do título de Engenheira Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). Marcelo Favoretto Castoldi - Presidente (Orientador)

Prof(a). Dr(a). Danilo Sipoli Sanches - (Coorientador)

Prof(a). Dr(a). Murilo da Silva - (Membro)

Prof(a). Me(a). Marco Antonio Ferreira Finocchio - (Membro)

Prof(a). Dr(a). André Luís Shiguemoto - (Membro)

A folha de aprovação assinada encontra-se na coordenação do curso.

À minha família.

AGRADECIMENTOS

A Deus, por estar sempre presente na minha vida, me dando força e iluminando meu caminho.

Aos meus pais Elizabethe e Marcio, a meus irmãos Mariana e Tiago pelos conselhos, apoio e estímulo que me deram durante toda a minha vida.

Ao meu orientador professor Dr. Marcelo Favoretto Castoldi pela oportunidade de ser sua orientanda, pela paciência, empenho e grande ajuda durante toda essa caminhada.

Ao meu coorientador professor Dr. Danilo Sipoli Sanches por toda sua ajuda, dedicação, seus inúmeros ensinamentos e por todo tempo que dispôs em me auxiliar.

A todos meus amigos da graduação pelo companheirismo e amizade durante toda essa jornada de estudos.

Aos professores André Luís Shiguemoto, Marco Antonio Ferreira Finocchio e Murilo da Silva por aceitarem participar da minha banca, pela atenção e contribuição dedicadas a este estudo.

Ao departamento Acadêmico de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, campus Cornélio Procópio, pela oportunidade a mim concedida.

A todos os demais professores e colegas que fizeram parte da construção do meu aprendizado.

RESUMO

SOUZA, Luciana. M. X. de. Análise comparativa de algoritmos evolutivos multiobjetivo aplicados no problema de restabelecimento de energia. 2015. 88f. Trabalho de conclusão de curso – Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

Encontrar uma configuração que reduz o número de manobras operacionais necessárias para se restabelecer a energia elétrica após a ocorrência de uma falta, é considerada como sendo um problema de natureza combinatorial, e que normalmente possui características que dificultam a utilização de técnicas de programação matemática. Algoritmos evolutivos têm sido cada vez mais empregados, pois apresentam resultados satisfatórios para o restabelecimento de energia elétrica no sistema de distribuição. Neste trabalho, é realizada a análise aprofundada dos conjuntos de soluções dos algoritmos evolutivos multiobjetivo que tratam problemas de restabelecimento de energia elétrica. Portanto, esta análise detalhada tem o objetivo de verificar a qualidade das soluções multiobjetivo e observar se há diferença ou não nas soluções encontradas em relação ao número de operações de chaveamento obtido para o processo de reconfiguração do sistema. Para o desenvolvimento desta análise emprega-se algumas abordagens clássicas da literatura sobre algoritmos evolutivos multiobjetivo, bem como, os algoritmos AEMT, AEMT-SP e o NSGA-II, sendo que esta avaliação foi realizada através de métricas comparativas como o Hipervolume, Epsilon, R2 e R3 e também por meio do teste de Wilcoxon. Estes métodos foram implementados no *software* R com o intuito de encontrar o algoritmo que possui o melhor desempenho e agregar uma maior precisão da escolha da solução pelo operador do sistema elétrico. A principal vantagem da análise proposta é conhecer qual algoritmo melhor representa o sistema de distribuição.

Palavras-chave: Sistema elétrico de distribuição. Algoritmo Evolutivo. Métricas comparativas.

ABSTRACT

SOUZA, Luciana. M. X. De. Comparative analysis of applied multi-objective evolutionary algorithms in energy recovery problem. 2015. 88f. Trabalho de conclusão de curso – Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2015.

Finding a configuration that reduces the number of necessary operational switch to restore the power after the occurrence of a fault it is considered to be a problem combinatorial nature, and usually has characteristics that make the use of mathematical programming techniques. Evolutionary algorithms have been increasingly used because they present satisfactory results for the restoration of electricity in the distribution system. This work is carried out in-depth analysis of the solution sets of multi-objective evolutionary algorithms that address issues of power restoration. So this detailed analysis is intended to check the quality of multi-objective solutions and see if there is a difference or not the solutions found in the number of switching operations obtained for the system reconfiguration process. To develop this analysis is employed some classic approaches of the literature on multi-objective evolutionary algorithms and the algorithms AEMT, AEMT-SP and the NSGA-II, and this evaluation was carried out through comparative metrics like hypervolume, Epsilon, R2 and R3 and also through the Wilcoxon test. These methods are implemented in *software* R in order to find the algorithm which has better performance and greater accuracy adding the solution of choice by the electric system operator. The main advantage of the proposed analysis is to know which one best algorithm is the distribution system.

Keywords: Electric distribution system. Evolutionary algorithm. Comparative metrics.

LISTA DE FIGURAS

Figura 1 – Representação do Sistema Elétrico de Potência	19
Figura 2 – Representação do Sistema de Distribuição Estável.....	21
Figura 3 – Representação do Sistema de Distribuição em Falta no Setor 2	21
Figura 4 – Representação do SD Isolando o Setor 2 em Falta	22
Figura 5 – Representação do SD Reconfigurado Após uma Falta.....	23
Figura 6 – Representação do passo <i>backward</i>	30
Figura 7 – Exemplo de um (a) Grafo e (b) RNP	34
Figura 8 – Diagrama de Funcionamento de um Algoritmo Genético Simples	37
Figura 9 – Representação da Fronteira de Pareto Ótima.....	38
Figura 10 – Curva Conforto Versus Custo	39
Figura 11 – Esquema Representativo da Fronteira de Pareto (a) Conjunto A; (b) Conjunto B.....	41
Figura 12 – Esquema Comparativo de Dois Conjuntos de Soluções	41
Figura 13 – Ordenação por Não Dominância	48
Figura 14 – Esquema do Modelo NSGA-II	49
Figura 15 – Distribuição Normal	53
Figura 16 – Curva de Distribuição Assimétrica.....	53
Figura 17 – Hipervolume Construído Através das Soluções da Fronteira A	58
Figura 18 – Representação da Métrica Epsilon.....	59
Figura 19 – Eficiência	65
Figura 20 - Comparação entre os AEMOs	67
Figura 21 – Fronteira de Pareto comparativa com os algoritmos AEMOs AEMT, AEMT-SP e NSGA-II	68
Figura 22 – Comparação dos AEMOs em relação ao HV com dominância	69
Figura 23 – Comparação dos AEMOs em relação ao HV indicador.....	70
Figura 24 – Comparação dos AEMOs em relação à qualidade obtida pela métrica epsilon.....	71
Figura 25 – Comparação dos AEMOs em relação à qualidade obtida pela métrica R2	72
Figura 26 – Comparação dos AEMOs em relação à qualidade obtida pela métrica R3	72
Figura 27 – Comparação da solução da métrica HV com dominância para os AEMOs	73
Figura 28 – Comparação da solução da métrica HV indicadora para os AEMOs	74
Figura 29 – Comparação da solução da métrica epsilon para os AEMOs	75
Figura 30 – Comparação da solução da métrica R2 para os AEMOs.....	76
Figura 31 – Comparação da solução da métrica R3 para os AEMOs.....	76
Figura 32 – EAF comparativo dos algoritmos AEMT x AEMT-SP	78
Figura 33 – EAF comparativo dos algoritmos AEMT x NSGA-II.....	78
Figura 34 – EAF comparativo dos algoritmos AEMT-SP x NSGA-II.....	79

LISTA DE SIGLAS

AE	Algoritmo Evolutivo
AEMO	Algoritmo Evolutivo Multiobjetivo
AEMT	Algoritmo Evolutivo Multiobjetivo em Tabelas
AEMT – SND	Algoritmo Evolutivo Multiobjetivo em Tabelas com Soluções Não Dominadas
AEMT – SP	Algoritmo Evolutivo Multiobjetivo em Tabelas com Soluções Não Dominadas e Strength Pareto
CAO	<i>Change Ancestor Operator</i>
DM	Dispositivo de Manobra
EAF	<i>Empirical Attainment Function</i>
EDMT	Evolução Diferencial Multiobjetivo em Tabelas
EMO	Evolutivo Multiobjetivo
GNU	Licença Pública Geral
HV	Hipervolume
MPF	Modelo Pais-Filhos
NA	Normalmente Aberto
NF	Normalmente Fechado
NSGA	<i>Non-dominated Sorting Genetic Algorithms</i>
NSGA – II	<i>Elitist Non-Dominated Sorting Genetic Algorithm</i>
PAO	<i>Preserve Ancestor Operator</i>
PM	Programação Matemática
RNP	Representação Nó-Profundidade
RS	Restauração do Serviço
SD	Sistema de Distribuição
SDR	Sistema de Distribuição Radial
SEP	Sistema Elétrico de Potência
SPEA2	<i>Strength Pareto Evolutionary Algorithm</i>
TR	Transformador
kW	Quilowatt

SUMÁRIO

1. INTRODUÇÃO	12
1.1. OBJETIVOS	16
1.1.1. Objetivo geral	16
1.1.2. Objetivos específicos.....	16
1.2. ESTRUTURA.....	17
2. O SISTEMA ELÉTRICO DE POTÊNCIA	18
2.1. FALTAS ASSIMÉTRICAS	19
2.2. RECONFIGURAÇÃO DO SISTEMA DE DISTRIBUIÇÃO.....	20
2.3. PLANO DE RESTABELECIMENTO DE ENERGIA EM SISTEMAS RADIAIS ...	23
2.4. FORMULAÇÃO MATEMÁTICA.....	24
2.5. FLUXO DE CARGA PARA SDRs.....	28
2.5.1. Método Soma das Correntes.....	29
2.5.2. Método Soma das Potências.....	31
2.6. REPRESENTAÇÃO NÓ-PROFUNDIDADE	33
2.6.1. Operadores da RNP	35
3. ALGORITMO EVOLUTIVO PARA OTIMIZAÇÃO MULTIOBJETIVO	36
3.1. ALGORITMO EVOLUTIVO	36
3.2. OTIMIZAÇÃO MULTIOBJETIVO.....	37
3.2.1. Estrutura geral de um AE multiobjetivo	38
4. ALGORITMOS EVOLUTIVOS CLÁSSICOS DA LITERATURA	42
4.1. AEMT: ALGORITMO EVOLUTIVO MULTIOBJETIVO EM TABELAS.....	42
4.2. AEMT-SP: AEMT COM SOLUÇÕES NÃO DOMINADAS E <i>STRENGTH</i> PARETO	44
4.3. NSGA-II: <i>ELITIST NON-DOMINATED SORTING GENETIC ALGORITHM</i>	47
5. ESTATÍSTICA APLICADA	51
5.1. DISTRIBUIÇÃO NORMAL.....	52
5.2. TESTE NÃO PARAMÉTRICO.....	53
5.3. TESTE DE WILCOXON	54
5.4. MÉTRICAS DE COMPARAÇÃO DE AEMO.....	56
5.4.1. Métrica hipervolume	57
5.4.2. Métrica epsilon	58
5.4.3. Métricas R2 e R3	59
5.5. EAF - <i>Empirical Attainment Function</i>	61

6. RESULTADOS.....	63
6.1. SIMULAÇÕES PARA O PROBLEMA DE RESTABELECIMENTO DE ENERGIA	64
6.2. SIMULAÇÕES COM O TESTE DE WILCOXON.....	65
6.3. FRONTEIRA DE PARETO.....	67
6.4. SIMULAÇÕES COM AS MÉTRICAS COMPARATIVAS MULTIOBJETIVO.....	68
6.4.1. Gráfico <i>BoxPlot</i> para Métrica Hipervolume.....	68
6.4.2. Gráfico <i>BoxPlot</i> para Métrica Epsilon.....	70
6.4.3. Gráfico <i>BoxPlot</i> para Métrica R2 e R3.....	71
6.5. SIMULAÇÃO DA SOLUÇÃO DAS MÉTRICAS COMPARATIVAS MULTIOBJETIVO PELO TESTE DE WILCOXON.....	73
6.6. SIMULAÇÃO DA EAF.....	76
6.7. RANKING COM RESULTADO COMPARATIVO ENTRE OS AEMOS.....	79
7. CONCLUSÕES E TRABALHOS FUTUROS.....	81
7.1. CONCLUSÕES.....	81
7.2. TRABALHOS FUTUROS.....	82
REFERÊNCIAS.....	84

1. INTRODUÇÃO

O sistema elétrico no Brasil e em vários países do mundo vem sofrendo constantes modificações em sua regulamentação com o intuito de melhorar a qualidade do abastecimento de energia elétrica para os consumidores, por conseguinte o modelo do setor de energia tem como objetivo garantir a segurança e fornecimento de energia elétrica. Por outro lado, percebe-se que as empresas estão cada vez mais atreladas ao setor energético, pois a sua capacidade de investimento depende da eficiência do setor. Mediante esta análise, observa-se que os setores que atuam no segmento de distribuição de energia elétrica necessitam utilizar sistemas computacionais que restaurem e façam o planejamento das operações da rede elétrica. Assim, é fundamental que as ferramentas computacionais utilizadas tenham confiabilidade e garantam a agilidade na operação da rede elétrica (FERREIRA, 2010).

O restabelecimento de energia elétrica para o sistema de distribuição (SD) envolve a reconfiguração da rede elétrica e tem como objetivo isolar as áreas em falta e minimizar o número de manobras operacionais (SANCHES, 2013).

O processo de reconfiguração da rede para a restauração do serviço é complexo e exige bastante dos *softwares*, pois existe um número grande de elementos de chaveamento, as equações que regem o sistema elétrico normalmente não são lineares, as equações também não são diferenciáveis, ou seja, pode haver uma mudança no estado de alguma chave alterando assim as restrições e o objetivo do sistema. As restrições estão limitadas aos parâmetros elétricos e operacionais do sistema elétrico, já o objetivo ele se torna multiobjetivo, pois o plano de restauração do serviço deve maximizar o número de consumidores atendidos, minimizar o número manobras operacionais e ainda minimizar as perdas de energia (SANCHES et al., 2013).

Um plano de reconfiguração de redes de distribuição envolve algumas necessidades práticas, ou seja, deve se analisar como restaurar o sistema em um curto intervalo de tempo e ainda diminuir as perdas de potência e as quedas de tensão no sistema. De acordo com as restrições e os objetivos expostos, pode se constatar que a reconfiguração da rede de distribuição de energia elétrica é um problema com múltiplas restrições e múltiplos objetivos (SANTOS, 2009).

Encontrar uma configuração que tenha mínimas perdas ou que gere um plano adequado de restabelecimento é tido como um problema de natureza combinatória, onde o principal problema desse tipo de abordagem consiste no esforço do cálculo exigido (SANTOS, 2009).

Ante os fatos apontados, diversos métodos vêm sendo utilizados para resolver problemas de reconfiguração de redes de distribuição. O estudo destes métodos acaba sendo dividido em dois grupos: o primeiro baseado em programação matemática (PM) e o segundo em heurística (SANTOS, 2009).

Para os métodos com PM, fica em evidência a programação não linear (EL-KHATTAM et al., 2005), a dinâmica (BOULAXIS et al., 2002; DIAZ-DORADO et al., 2004) e a linear (FARRAG et al., 1999). Nestes métodos matemáticos são explicitadas algumas restrições como a queda de tensão, a capacidade dos cabos, entre outros. No entanto, a PM é limitada a problemas de pequeno porte, pois os modelos matemáticos acabam utilizando uma grande quantidade de variáveis na reconfiguração de redes de distribuição. O número de variáveis necessárias para a determinação de uma solução pode atingir níveis inviáveis, fazendo com que muitas vezes o problema se torne intratável computacionalmente em aplicações práticas, desta forma, essa metodologia se torna inexecutável para redes de distribuição de energia elétrica de médio e grande porte, onde a solução deve ser encontrada o mais rápido possível (BONA, 2005). É importante destacar que esse problema é combinatorial no número de chaves do sistema, isso quer dizer que o número de possíveis soluções aumenta de forma exponencial com o número de chaves. Através do exposto, o método de PM é deixado de lado e se passa a utilizar os métodos heurísticos.

Os algoritmos fundamentados em heurísticas conseguem em tempo real encontrar uma nova reconfiguração do SD, por este motivo são sugeridos como alternativa a resolver o problema da reconfiguração da rede de distribuição. Esse tipo de algoritmo não garante que se possa encontrar a melhor solução, ou a solução ótima, mas assegura a determinação de soluções que são adequadas para o problema (SANTOS, 2004).

Um método passa a ser chamado de heurístico quando não se tem o conhecimento matemático completo sobre o comportamento dessa metodologia ou quando se utiliza conhecimento e experiência de especialistas na criação do algoritmo. O objetivo deste método é solucionar problemas complexos utilizando

pouca quantidade de recursos, e onde não são conhecidos métodos eficientes que busquem uma solução ótima (SANTOS, 2009).

No decorrer dos anos muitas pesquisas surgiram com o intuito de aumentar o desempenho de métodos heurísticos para problemas combinatoriais, desta forma surgiram métodos conhecidos como metaheurísticas. A diferença entre as duas metodologias é que a metaheurística tem a capacidade de escapar dos ótimos locais, isso ocorre por meio de estratégias que ajudam a explorar o espaço de busca encontrando soluções com ótima qualidade. A metaheurística se inicia de uma solução factível ou não, e utilizando estratégias de transição passam de uma solução para outra até que o critério de parada que foi estabelecido seja alcançado (BIRATTARI et al., 2002). Existem Muitos métodos utilizando metaheurística como, por exemplo: o *branch exchange*, busca tabu, sistemas especialistas, Algoritmo Evolutivo (AE), entre outros. O algoritmo mais usado para a aplicação em problemas de reconfiguração de sistemas de distribuição são os AEs. Além do informado, esse algoritmo é fortemente relevante na literatura para problemas onde existem vários objetivos e restrições (MENDOZA et al., 2006; DEB, 2001; DEB et al., 2000).

Algoritmos evolutivos representam metaheurísticas que são inspiradas na evolução natural de populações e na estimativa de que os indivíduos mais aptos sobreviverão. Os métodos baseados em AEs usualmente utilizam mecanismos inspirados na biologia, tais como a seleção, recombinação e mutação. Os AEs cada vez mais ganham popularidade no meio científico principalmente porque conseguem realizar a otimização de tarefas complexas (GOLDBERG, 1989; KNOWLES; CORNE, 1999). Assim, começou a se destacar a otimização evolucionária multiobjetivo, a qual tem o propósito de utilizar os AEs para solucionar problemas com múltiplos critérios.

Para tratar o problema de restauração do sistema de distribuição existem inúmeras abordagens como os algoritmos NSGA (*Non-dominated Sorting Genetic Algorithms*), EDMT (Evolução Diferencial Multiobjetivo em Tabelas), SPEA2 (*Strength Pareto Evolutionary Algorithm*), entre outros. Porém, os métodos abordados neste trabalho foram escolhidos por apresentar melhor desempenho, são eles: o algoritmo evolutivo multiobjetivo em tabelas (AEMT) (DELBEM et al., 2005), o algoritmo evolutivo multiobjetivo em tabelas com soluções não dominadas e *strength Pareto* (AEMT-SP) (SANTOS et al., 2010) e o *Elitist Non-Dominated Sorting Genetic Algorithm* (NSGA-II) (DEB et al., 2002). Os métodos empregados têm como objetivo

atender o maior número de clientes, minimizar o número de manobras no sistema, e garantir que as soluções não violem as restrições operacionais impostas pelo sistema de distribuição (BATISTA, 2011).

Os algoritmos AEMT, AEMT-SP e o NSGA-II, foram desenvolvidos para o restabelecimento de energia em sistemas de distribuição radial (SDR). O SDR é composto por uma linha principal instalada da subestação até as cargas, onde pode haver derivações ou não, com recursos de manobras ou chaves seccionadoras.

O AEMT é baseado em uma estrutura conhecida como representação Nó-Profundidade (RNP), e aloca os dados organizados em tabelas, que utilizando a RNP produz configurações radiais em que todos os consumidores são atendidos após a área em falta ter sido isolada do sistema. Já o método AEMT- SP apresenta uma nova estrutura de tabela onde cada indivíduo está associado a um valor de força, isto é, a força da dominância de um indivíduo em relação aos outros indivíduos. Os indivíduos com um maior valor de força são preservados e mantidos na tabela para melhorar a capacidade de investigação do espaço de objetivos. Por fim, tem-se o NSGA-II que possibilita o tratamento do problema com múltiplos objetivos para a obtenção de planos de restabelecimento de forma direta. Para tanto, o NSGA-II faz uso da ordenação elitista por dominância que é conhecida como Pareto ranking, esta estrutura possibilita um melhor desempenho computacional, e a fim de sempre encontrar soluções factíveis o NSGA-II também faz uso da RNP (DELBEM et al., 2004).

O sistema de distribuição real utilizado para o estudo foi o da cidade de São Carlos/SP. Assim, foi realizada a simulação computacional dos algoritmos AEMT, AEMT-SP e o NSGA-II para a reconfiguração deste sistema, após essa simulação os algoritmos retornaram conjuntos de dados, esses dados são as possíveis soluções obtidas por cada método. É através destes dados que será realizada a análise estatística detalhada do problema de restabelecimento de energia elétrica.

A análise detalhada dos métodos estatísticos tem a intenção de verificar a qualidade das soluções multiobjetivo, além de também tentar observar se há diferença ou não nas soluções encontradas em relação ao número de operações de chaveamento obtidas para o processo de restabelecimento. Neste sentido, uma análise estatística é importante para definir com maior segurança qual abordagem de AEMO possui o melhor desempenho.

O trabalho propõe a análise dos dados de saída dos algoritmos de estudo por meio de programação feita no *software* R. Os dados serão tratados através de um teste de hipótese, no caso, o teste de Wilcoxon, o qual é utilizado para comparar se as medidas de posição de duas amostras são iguais, casos em que as amostras são dependentes. Também será abordada a utilização de métricas comparativas multiobjetivo com a finalidade de verificar a convergência e a diversidade das soluções. Portanto, para avaliar os algoritmos empregam-se as métricas Hipervolume, Epsilon, R2 e R3 que tem como objetivo realizar a comparação das soluções. A análise estatística é de fundamental importância porque dissemina a informação de forma a mostrar qual algoritmo possui de fato o melhor desempenho, desta forma, encontrar o algoritmo que possui melhor conjunto de soluções factíveis é obter a melhor solução para o operador do sistema elétrico.

1.1. OBJETIVOS

Nesta seção são apresentados os objetivos gerais e específicos deste trabalho.

1.1.1 Objetivo geral

O objetivo deste trabalho é avaliar de forma estatística a qualidade dos resultados obtidos por várias abordagens clássicas de algoritmos evolutivos multiobjetivo para o problema de restabelecimento de energia elétrica em sistemas de distribuição. Assim, este projeto tem como objetivo geral, fazer uma análise detalhada utilizando métricas de avaliação de algoritmos evolutivos multiobjetivo e teste de hipótese estatístico, com o propósito de definir qual algoritmo evolutivo possui melhor desempenho.

1.1.2. Objetivos específicos

Como objetivo específico, este projeto busca a solução mais eficiente para recompor o sistema de distribuição de energia elétrica rapidamente, garantindo assim o fornecimento de energia elétrica aos seus clientes. Desta forma propõe-se:

1. Analisar as características e o comportamento dos métodos AEMT, AEMT-SP e o NSGA-II;
2. Investigar os métodos estatísticos, no caso, as métricas para avaliar os algoritmos evolutivos multiobjetivo e o teste de hipótese a fim de encontrar a solução para o restabelecimento.
3. Aplicar as métricas levantadas usando o *software* estatístico R.
4. Observar o comportamento dos algoritmos AEMT, AEMT-SP e o NSGA-II em relação ao restabelecimento do sistema e apontar qual a melhor metodologia para o sistema de distribuição.

1.2. ESTRUTURA

Os capítulos deste trabalho foram divididos da seguinte maneira:

O Capítulo 2 revisa trabalhos e conceitos sobre o sistema elétrico de potência, tratamento da reconfiguração do sistema elétrico de distribuição e introduz a estrutura de dados conhecida como Representação Nó-Profundidade (RNP).

O Capítulo 3 apresenta fundamentos do AEs e demonstra conceitos de otimização multiobjetivo.

O Capítulo 4 apresenta os algoritmos clássicos AEMT, AEMT-SP e o NSGA-II.

O Capítulo 5 introduz a análise estatística utilizada, aborda os conceitos sobre métricas de comparação multiobjetivo, bem como as métricas hipervolume, epsilon, R2, R3 e a função EAF.

O Capítulo 6 apresenta os testes realizados para demonstrar a eficiência das metodologias utilizadas, juntamente com uma análise comparativa dos resultados.

O Capítulo 7 apresenta as conclusões alcançadas e as perspectivas futuras.

2. O SISTEMA ELÉTRICO DE POTÊNCIA

A função básica do sistema elétrico de potência (SEP) é fornecer energia elétrica aos consumidores com qualidade e continuidade adequada no momento em que é solicitado. Além disso, o sistema deve ser confiável. O SEP é subdividido em três partes: geração, transmissão e distribuição da energia elétrica (SANTOS, 2009). Abaixo são descritas as características que diferenciam as partes de um SEP.

- **Geração:** É composta das usinas de geração de energia elétrica. Tem como objetivo final converter energia mecânica em energia elétrica, ou seja, converte a energia de alguma fonte primária como a água ou outras fontes bem como a solar e a eólica, por exemplo, em energia elétrica. As usinas geradoras apresentam normalmente uma tensão em torno de 13,8 kV.
- **Transmissão:** São formadas pelas linhas de transmissão, sendo responsáveis por levar a energia elétrica da geração até o consumo. É comum dentro da sua composição a utilização de transformadores reguladores de tensão. A tensão normalmente utilizada nestas linhas de transmissão pode variar entre 69 kV chegando até 750 kV.
- **Distribuição:** É formada basicamente pelas subestações abaixadoras de tensão e as linhas de distribuição de energia elétrica. As linhas de transmissão levam a energia elétrica até as linhas de distribuição, e estas ficam responsáveis por levar a energia elétrica até o centro consumidor, ou seja, para a indústria, residências e áreas rurais. Normalmente, utiliza-se uma tensão de 13,8 kV.

Na Figura 1, tem-se a representação do sistema elétrico de potência, onde é possível visualizar os processos de geração, transmissão e distribuição da energia elétrica. A Figura 1 apresenta por meio do símbolo G a geração de energia, já o símbolo TR é relacionado a transformadores, nesta configuração, analisando da geração até a distribuição, tem-se um TR elevador de tensão, que eleva a tensão até as linhas de transmissão. Na transmissão de energia elétrica, além das próprias linhas de transmissão encontram-se os dispositivos de manobra, representados simbolicamente por DM, estes por sua vez, servem para abrir e fechar estas linhas. Por final, tem-se um TR abaixador que diminuirá a tensão vinda da transmissão e a

levará para a distribuição, assim observa-se que são as linhas de distribuição que levam a energia elétrica até o consumidor final (SANTOS, 2009).

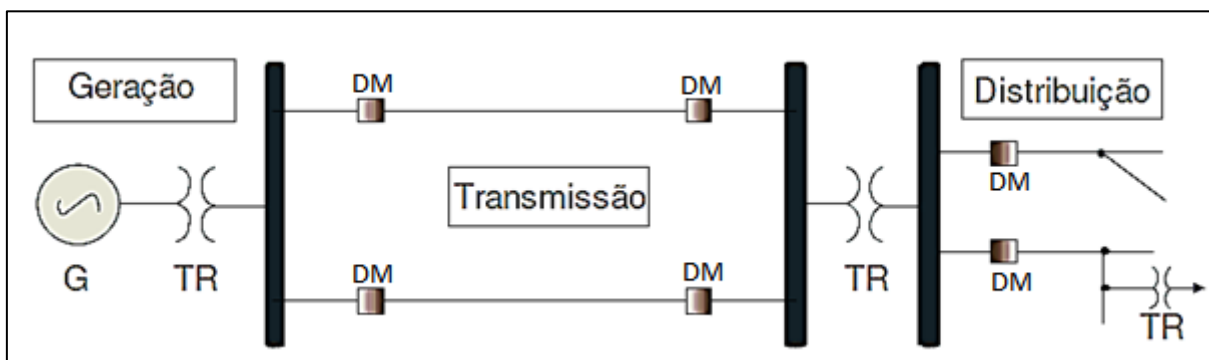


Figura 1- Representação do Sistema Elétrico de Potência

Fonte: Adaptado de Santos (2009).

O sistema de distribuição, o qual será foco deste trabalho, é dividido em duas classes: o sistema de distribuição primário e o secundário.

- Sistema de distribuição primário: É a distribuição de média tensão, normalmente operam em redes aéreas com a tensão de 13,8 kV. O sistema deste tipo é projetado para que se possa transferir carga para outras localidades, ou seja, para outros circuitos, garantindo assim o atendimento ao consumidor mesmo em condições de contingência ou para a manutenção do sistema.
- Sistema de distribuição secundário: É a distribuição de baixa tensão, normalmente encontra-se a tensão em torno de 127/220 V e 220/380 V.

Neste trabalho o foco principal está voltado para o sistema de distribuição primário, porque é neste sistema que ocorrem os processos de contingência.

2.1. FALTAS ASSIMÉTRICAS

A grande maioria das faltas (transgressão do sistema elétrico) são falhas assimétricas, porém podem ocorrer faltas trifásicas em circuitos simétricos. As faltas assimétricas podem ser formadas a partir de curto – circuito, da abertura de condutores e através de falhas assimétricas nas impedâncias (GRAINGER; STEVENSON, 1994).

As faltas assimétricas podem ocorrer da seguinte forma:

- Falta fase-terra simples;
- Falta linha-linha;
- Falta fase-terra dupla.

O caminho que a corrente de falta faz entre as linhas ou entre a linha e o terra pode ter uma impedância associada. A junção de um ou dois condutores em aberto resulta em uma falta assimétrica, seja pelo rompimento destes condutores, por outros dispositivos que não abrem as três fases simultaneamente ou até mesmo pela ação de fusíveis. Qualquer falta assimétrica pode gerar um fluxo de corrente desequilibrado no sistema (GRAINGER; STEVENSON, 1994).

2.2. RECONFIGURAÇÃO DO SISTEMA DE DISTRIBUIÇÃO

Quando o sistema de distribuição sofre uma falta é imprescindível que seja restabelecido a distribuição de energia elétrica rapidamente. Para que a reconfiguração do sistema ocorra de modo que se restabeleça o fornecimento de energia elétrica, é executado um fluxo de carga e o cálculo do número de manobras que serão necessárias para gerar essa nova configuração, apenas mediante estas etapas é que será possível restabelecer o sistema de forma adequada (MORELATO; MONTICELLI, 1989).

Neste capítulo, será feito um passo a passo do processo para a obtenção do restabelecimento de energia elétrica. A rede estudada é fictícia e apresenta apenas uma subestação e 11 barras de carga.

As Figuras 2, 3, 4 e 5 ilustram respectivamente o sistema de distribuição de energia elétrica em cada momento, ou seja, em estabilidade, em falta, a falta sendo isolada e no momento da sua nova reconfiguração para a restauração do sistema. Nestas figuras, há a representação de uma subestação que alimenta o sistema de distribuição, e que é referida pelo símbolo SB. Ainda, são ilustrados os blocos de carga, comumente conhecidos como setores, e reproduzidos nas figuras como sendo barras verticais com suas respectivas numerações. Por fim, têm-se as chaves seccionadoras, estas não estão em evidência nas figuras, porém admite-se a existência de pelo menos uma em cada linha. As linhas de distribuição tracejadas na

cor azul representam as chaves normalmente abertas (NA), já as linhas contínuas na cor preta mostram as chaves normalmente fechadas (NF).

A Figura 2 representa o sistema em pleno funcionamento, ou seja, estável e fornecendo energia elétrica para seus consumidores.




Figura 2 – Representação do Sistema de Distribuição Estável

Fonte: Autoria própria.

A Figura 3 ilustra o sistema elétrico de distribuição sofrendo uma falta no setor 2. Com o sistema em falta, é necessário que se isole a carga desequilibrada, e depois se adquira uma nova configuração com o objetivo de restabelecer rapidamente a energia elétrica para todos os consumidores.

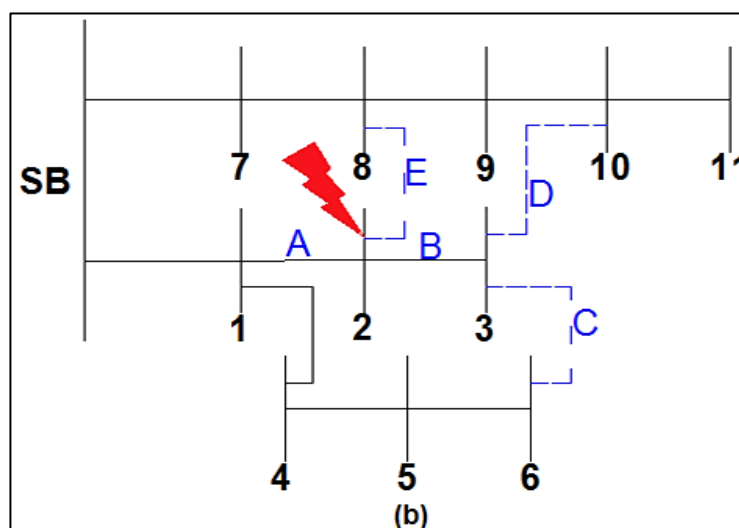


Figura 3 – Representação do Sistema de Distribuição em Falta no Setor

2

Fonte: Autoria própria.

Inicialmente isola-se o setor em falta, e conecta-se o mesmo ao sistema mais próximo que supra essa distribuição de energia elétrica. Assim, o sistema de restabelecimento de distribuição de energia elétrica exige que haja manobras de chaves seccionadoras, ou seja, manobras operacionais.

Para se isolar um setor é necessário que chaves seccionadoras sejam abertas, como pode ser visto na Figura 4. Por conseguinte, neste caso, abrem-se as chaves A e B, fazendo duas manobras no sistema. Nota-se que com este procedimento o setor 3 não estará mais interligado, ou seja, ficará desconectado do sistema de distribuição de energia elétrica, visto que as outras linhas de distribuição conectadas a este setor estão com chaves seccionadoras NA.




Figura 4 – Representação do SD Isolando o Setor 2 em Falta

Fonte: Autoria própria.

O setor 3 não pode ficar sem energia, pois isso interrompe a distribuição de energia elétrica para os consumidores ali alocados. Desta forma, para restaurar o funcionamento do setor será necessário fechar uma chave. De forma que, cada alteração no estado das chaves é computada como sendo mais uma manobra operacional. Mediante a ilustração da Figura 4, é possível perceber que se têm algumas opções para a realimentação do sistema, ou seja, pode se escolher as chaves que melhor se adequam ao problema, isto ocorre neste exemplo, pois, não conhecemos as restrições operacionais do sistema em estudo. Assim, para o setor 3 pode-se fechar a chave C ou D, gerando mais uma manobra para manter a conectividade do sistema. A partir daqui, cada chave alterada ocorrerá em par, ou seja, para que uma chave seja aberta outra deverá ser fechada. É através da

manipulação do chaveamento da rede que se consegue estimar quantas manobras são necessárias para restabelecer um sistema em falta.

A Figura 5 exhibe que a manobra escolhida foi o fechamento da chave D, agora o sistema está estável e atendendo novamente seus consumidores.

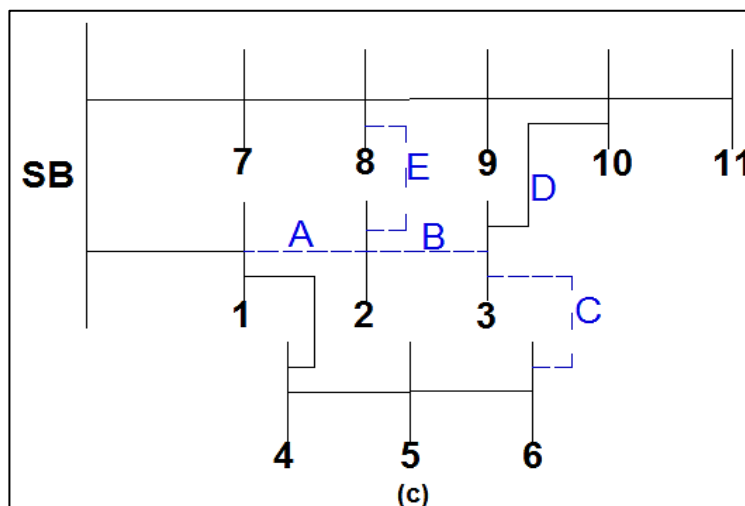


Figura 5 – Representação do SD Reconfigurado Após uma Falta
Fonte: Autoria própria.

É importante entender como o sistema de reconfiguração da distribuição de energia elétrica funciona, pois os dados que serão utilizados são provenientes das manobras operacionais do sistema elétrico, ou seja, da abertura e do fechamento de chaves seccionadoras.

2.3. PLANO DE RESTABELECIMENTO DE ENERGIA EM SISTEMAS RADIAIS

Face ao exposto no tópico 2.2 para a reconfiguração do sistema de distribuição de energia elétrica, é importante desenvolver um plano de restabelecimento de energia para o setor, após ser identificado em falta e isolado do sistema, pois se deve restabelecer a energia elétrica para os setores que ficaram sem, devido à atuação da proteção. O plano de restabelecimento deve conter as seguintes características:

- Ser ágil. Em tempo real deve ser encontrado em um curto intervalo de tempo;
- Possuir o menor número de manobras operacionais possível;

- Reduzir o número de consumidores sem fornecimento de energia elétrica;
- Nenhum dos componentes deve ficar sobrecarregado;
- Reduzir as quedas de tensão.

Pelo exposto anteriormente, pode se dizer que o restabelecimento de energia elétrica é um problema com múltiplos objetivos e muitas vezes alguns destes objetivos acabam sendo conflitantes, assim as restrições e os objetivos devem ser considerados na formulação matemática do problema. Desta maneira, o tópico 2.4 tem o propósito de explicar como é feita a formulação do problema.

2.4. FORMULAÇÃO MATEMÁTICA

Para tratar o restabelecimento de energia elétrica o primeiro passo é formular o problema de forma geral. O equacionamento deve servir para o tratamento da reconfiguração da rede elétrica e também para a redução das perdas ôhmicas. Assim a formulação matemática deve considerar todos os objetivos e as restrições do problema.

A fim de minimizar as perdas o problema deve encontrar uma configuração que não viole nenhuma das restrições operacionais do sistema elétrico de potência, como a queda de tensão, os limites de tensão das subestações e o carregamento da rede. Já para a obtenção de uma nova configuração da rede elétrica, devem-se minimizar as áreas sem serviço e o número de chaveamentos necessários para a implantação do novo modelo reconfigurado (DELBEM et al., 2005).

O modelo matemático encontrado por Delbem et al. (2005) para a reconfiguração de redes em sistemas de distribuição radial foi o seguinte:

$$\begin{aligned}
 & \text{Min.} && E(F) \\
 & \text{sujeito a.:} && H(F) = 0 \\
 & && I(F) \leq 0 \\
 & && F \text{ é uma floresta}
 \end{aligned} \tag{1}$$

A equação 1, representa a função de minimização para o sistema e está sujeita a restrições. Onde cada termo é apresentado abaixo:

- $E(F)$ – Função objetivo;
- $H(F)$ – Restrições de igualdade representando as equações de fluxo de carga;
- $I(F)$ – Restrições de desigualdade representando as restrições operacionais do sistema;
- F – Floresta que corresponde a uma configuração do sistema, onde cada árvore, por analogia corresponde a um alimentador ligado a uma subestação.

A função $E(F)$ normalmente possui os seguintes elementos:

- $\phi(F)$ – Quantidade de cargas fora de serviço para uma configuração radial da rede para uma floresta F ;
- $\varphi(F)$ – Perdas resistivas no sistema para a floresta F ;
- $\psi(F, F^0)$ – Número de operações de chaveamento para obter uma dada configuração F , a partir da configuração original F^0 ;

Restrições de igualdade $H(F)$ normalmente representam as equações de fluxo de carga. Assim, um sistema simples e linear como $Ax = b$ pode representá-las, como segue abaixo (SANCHES, 2013):

- A – Representa a matriz de incidência de F ;
- X – Vetor de correntes de linha;
- b – Vetor com as injeções de correntes nas barras de carga ($b_i \leq 0$) ou correntes nas subestações ($b_i > 0$).

Geralmente as restrições operacionais de $I(F)$ para problemas de reconfiguração de redes em sistemas de distribuição radial contém as seguintes características (SANCHES, 2013):

- \bar{x}_j é o limite superior de corrente para cada corrente de linha x_j . Onde $X(F)$ é representada pela maior taxa x_j/\bar{x}_j que é o carregamento da rede para a configuração F ;
- \bar{b}_i é a máxima injeção de corrente possível para cada subestação i , onde $B(F)$ é representada pela maior taxa b_i/\bar{b}_i denominada como carregamento da subestação para a configuração F ;
- Limite inferior para a tensão nó \underline{v} . Se v_i é a tensão na barra i e v_b a tensão na base do sistema, a menor taxa v_i/v_b é a maior queda de tensão da rede na configuração F , representada por $V(F)$.

Normalmente são empregados AEs para resolução destes problemas, pois a função objetivo de sistemas envolvendo reconfiguração de sistemas de distribuição radial é não linear, com ótimos locais e descontínua, o que dificulta a empregabilidade de programação matemática. Assim, quando AEs são utilizados nestes problemas são feitas algumas modificações na formulação, como pode ser visto na equação 2 se comparada com a equação 1. Desta forma, são inseridas medidas corretivas, com o objetivo de penalizar as configurações da rede que infringirem as restrições operacionais impostas $I(F)$ (SANCHES, 2013). Assim, na sequência é apresentada a nova formulação para o problema:

$$\begin{aligned}
 & \text{Min.} && E(F) + |\Omega I(F)| \\
 & \text{sujeito a.:} && H(F) = 0 \\
 & && F \text{ é uma floresta}
 \end{aligned} \tag{2}$$

Onde Ω é uma matriz diagonal que possui os seguintes elementos:

$$W_{11} = \begin{cases} w_x, & \text{se houver pelo menos um } j, x_j > \bar{x}_j \\ 0, & \text{caso contrário} \end{cases} \tag{3}$$

$$W_{22} = \begin{cases} w_s, & \text{se houver pelo menos um } i, b_i > \bar{b}_i \\ 0, & \text{caso contrário} \end{cases} \tag{4}$$

$$W_{33} = \begin{cases} w_v, & \text{se houver pelo menos um } j, v_i > \underline{v} \\ 0, & \text{caso contrário} \end{cases} \tag{5}$$

Os pesos w_x , w_S e w_v são valores positivos que estão respectivamente relacionados com o limite superior de corrente, a máxima injeção de corrente e o limite inferior de tensão no nó (SANCHES, 2013).

A execução do fluxo de carga é imprescindível para verificar se uma configuração obedece às restrições operacionais impostas para o problema (I(F)), assim, o fluxo de carga deve ser computacionalmente eficiente, visto que será processada e analisada uma grande quantidade de configurações, visando sempre à configuração ótima para o problema.

É extremamente importante a utilização de estruturas de dados eficientes computacionalmente, para que se consiga dimensionar da melhor forma possível às topologias elétricas dos SDRs e também eficientes algoritmos para calcular o fluxo de carga (SANCHES, 2013). É importante destacar que para facilitar o cálculo do fluxo de potência nos problemas de reconfiguração de redes de energia elétrica, podem-se modelar as cargas como corrente constante e utilizar métodos para o cálculo do fluxo de potência monofásico de varredura. Neste contexto, o método de varredura que se destaca na literatura, como pode ser observado nos trabalhos propostos por Mansour (2009), Santos (2009) e Sanches (2013), é a utilização do método soma de correntes, pois possui menor complexidade.

O método de soma de correntes para poder ser aplicado as barras da rede elétrica deve estar ordenado segundo o modelo Pai-Filho (MPF). Neste modelo, pode-se calcular o fluxo de corrente partindo dos nós terminais (nó folhas) em direção à subestação (nó raiz), e as tensões podem ser obtidas de forma encadeada partindo da subestação até as barras terminais (SANCHES, 2013).

Para facilitar a formulação de problemas de reconfiguração de redes de sistema de distribuição através da utilização de algoritmos evolutivos, autores como Mansour (2009) e Santos (2009), propuseram a utilização da RNP e de seus operadores (representação aprofundada na seção 2.6). A utilização da RNP é justificada, pois quando os operadores são empregados geram se configurações exclusivamente factíveis (MANSOUR, 2009; SANCHES, 2013; SANTOS, 2009).

Através da RNP e de seus operadores foi possível escrever uma nova formulação matemática, a qual esta representada na equação 6.

$$\begin{aligned}
 & \text{Min.} \quad E(F) + |\Omega I(F)| \\
 & \text{sujeito a.: } H(F) = 0 \\
 & \quad \quad \quad F \text{ ser dado pelos operadores da RNP}
 \end{aligned} \tag{6}$$

O fluxo de carga de varredura com RNP é mais eficiente quando comparado com os fluxos de carga convencionais para o tratamento SDRs (SANCHES, 2013). A utilização do MPF proporciona que realmente as restrições de igualdade ($H(F)$) sejam satisfeitas. Ao se fazer uso das propriedades e características da RNP, e concordando com o armazenamento dos nós de acordo com o MPF, se encontra uma nova formulação matemática, representada na equação 7.

$$\begin{aligned}
 & \text{Min.} \quad E(F) + |\Omega I(F)| \\
 & \text{sujeito a.: Utilizar MPF com RNP} \\
 & \quad \quad \quad F \text{ ser dado pelos operadores da RNP}
 \end{aligned} \tag{7}$$

Essa nova formulação matemática torna possível configurações exclusivamente factíveis. Através da utilização da RNP juntamente com o fluxo de carga, é possível conseguir um equacionamento simplificado, o que pode ser observado comparando a equação 7 com a 1. Desta forma, fazendo uso da equação 7, é necessário se preocupar apenas com as restrições de queda de tensão, com o carregamento na rede elétrica e os transformadores que estão sendo utilizados (SANCHES, 2013).

2.5. FLUXO DE CARGA PARA SDRs

O fluxo de carga consiste no estudo para a obtenção das condições de operação da rede de energia elétrica, bem como, o fluxo de potência nas linhas, nos transformadores e as tensões complexas nas barras, tudo em função da topologia e dos níveis de demanda que a rede se encontra.

Existem alguns métodos para o cálculo do fluxo de carga como o Newton-Raphson, o Desacoplado Rápido e outras versões que apresentam variações e modificações dos mesmos (MONTICELLI, 1983). Os modelos apresentados possuem desempenho considerado ineficiente quando aplicados em sistemas de

distribuição. Principalmente para redes radiais com um elevado número de barras (SANCHES, 2013), isso ocorre, pois os SDRs apresentam características que levam ao mau desempenho destas metodologias como:

- Baixa relação reatância/resistência (X/R) dos parâmetros dos alimentadores;
- Impedâncias em alguns trechos com valores altos e em outros muito baixos;
- Grande número de barras de carga distribuídas.

As matrizes associadas ao sistema de distribuição radial se tornam mal condicionadas em razão das características já apresentadas, o que dificulta o cálculo de fluxo de carga através das metodologias tradicionais, pois podem afetar a convergência do método e até mesmo levar a divergência do processo (SANCHES, 2013).

Os dois métodos capazes de resolver o problema de fluxo de potência para SDRs são:

- Método de soma de correntes proposto por Shirmohammadi et al. (1988);
- Método de soma de potências de Baran e Wu (1989).

2.5.1. Método Soma das Correntes

O método soma de correntes proposto por Shirmohammadi et al. (1988) foi desenvolvido para sistemas de distribuição radial. O método é tido como simples e apresenta desempenho eficiente. Para o cálculo do fluxo de carga de um sistema de distribuição radial são considerados n nós, b ramos, tensão do nó raiz igual a 1 p.u., e ângulo de 0 (zero) graus para as demais barras do SDR, assim devem-se seguir os passos descritos abaixo para a resolução do método:

1. Calcular a corrente nodal – A injeção de corrente nodal $\hat{I}^{(k)}$ é calculada para cada iteração k , através da equação 8:

$$i^{(k)} = (\dot{S}_i / \dot{V}_i^{(k-1)})^* - \dot{Y}_i^{sh} \dot{V}_i^{(k-1)}, \quad i = 1, 2, \dots, n. \quad (8)$$

Onde

$\dot{V}_i^{(k-1)}$ é a tensão na barra i , calculada durante $(k - 1)$ iterações;

\dot{S}_i é a injeção de potência complexa especifica para cada barra i ;

\dot{Y}_i^{sh} é a soma dos elementos shunt da barra i ;

n é o número de barras da representação radial do sistema;

$()^*$ o símbolo indica o conjugado complexo do valor que esta dentro do parênteses.

2. *Backward* – Na iteração k , as linhas conectadas as barras extremas, que são barras com maior profundidade e que se movem até as linhas conectadas a barra raiz, que tem profundidade zero, calcula-se a corrente \dot{F}_L na linha L , que liga a barra L_1 a próxima barra, no caso L_2 , como representado na equação 9 abaixo e ilustrado na Figura 6.

$$\dot{F}_L^{(k)} = -\dot{i}_{L_2}^{(k)} + \sum(\text{Correntes nas linhas que saem do nó } L_2) \quad (9)$$

Onde

$L = p, p - 1, \dots, 1$, $\dot{i}_{L_2}^{(k)}$ é a injeção de corrente no nó L_2 ;

p é o número de linhas que o sistema possui.




Figura 6 - Representação do passo *backward*

Fonte: Autoria própria.

3. *Forward* – As tensões complexas das barras são sempre atualizadas, inicia-se pelas barras que estão conectadas a barra raiz que é à subestação, e segue-se até as barras externas. A linha L liga a barra $L2$ a sua barra anterior $L1$, a tensão calculada para $L2$ é fruto da atualização da tensão na iteração k de $L1$. O fluxo de corrente na linha é calculado no passo 3. A equação 10 mostra a formulação para as tensões complexas.

$$\dot{V}_{L2}^{(k)} = \dot{V}_{L1}^{(k)} - \dot{Z}_L \dot{I}_L^{(k)}, L = 1, 2, \dots, p \quad (10)$$

Onde

\dot{Z}_L é a impedância série da linha L ;

4. Os passos 2, 3 e 4 são repetidos inúmeras vezes até que se alcance o critério de convergência.

Usualmente, o critério de convergência adotado é o maior erro de potência ativa (P) e reativa (Q) nas barras do sistema, de forma que, o erro seja sempre menor que ϵ . De acordo com o mencionado nos passos anteriores, em cada iteração se calcula a injeção de corrente, e logo em seguida as tensões das barras do sistema. A potência complexa injetada na barra i na iteração k , $\dot{S}_i^{(k)}$ é calculada através da equação 11.

$$\dot{S}_i^{(k)} = \dot{V}_i^{(k)} \dot{I}_i^{(k)*} - \dot{Y}_i \left| \dot{V}_i^{(k)} \right|^2, i = 1, 2, \dots, n. \quad (11)$$

O erro da potência ativa e reativa pode ser encontrado na barra i , por meio das equações 12 e 13.

$$\Delta P_i^{(k)} = Re \left[\dot{S}_i^{(k)} - \dot{S}_i \right], i = 1, 2, \dots, n. \quad (12)$$

$$\Delta Q_i^{(k)} = Im \left[\dot{S}_i^{(k)} - \dot{S}_i \right] \quad (13)$$

2.5.2 Método Soma das Potências

O método soma das potências foi desenvolvido por Baran e Wu (1989) e é considerado o mais utilizado e difundido na literatura, pois é relativamente simples

do ponto de vista conceitual, além disso, o método apresenta um eficiente desempenho para a resolução de problemas de carga radial (BRANDINI, 2000).

Assim como apresentado no método de soma de correntes o método soma das potências pode ser obtido a partir do cálculo do fluxo de carga. O método pode ser desenvolvido seguindo os passos descritos abaixo.

1. Pressupor que as tensões iniciais de todas as barras são iguais à tensão da subestação;
2. *Backward* – Calcular o fluxo de potência ativa e reativa para cada linha utilizando as equações 14 e 15 a seguir.

$$P_{i-1} = P_i + r_i \frac{P_i'^2 + Q_i'^2}{V_i^2} + P_{Li} \quad (14)$$

$$Q_{i-1} = Q_i + x_i \frac{P_i'^2 + Q_i'^2}{V_i^2} + Q_{Li} \quad (15)$$

Onde

P_i é o fluxo de potência ativa no ramo i ;

Q_i é o fluxo de potência reativa no ramo i ;

P_{Li} é a injeção de potência ativa líquida na barra i ;

Q_{Li} é a injeção de potência reativa líquida na barra i ;

$P_i' = P_i + P_{Li}$;

$Q_i' = Q_i + Q_{Li}$.

3. *Forward* – Calcular a tensão e o ângulo de cada barra, isso pode ser feito utilizando as equações 16 e 17 abaixo.

$$V_{i+1}^2 = V_i^2 - (r_i P_i + x_i Q_i) + (r_i^2 + x_i^2) \frac{P_i^2 + Q_i^2}{V_i^2} \quad (16)$$

$$\delta_{i+1}^2 = \delta_i^2 - \tan^{-1} \left(\frac{k_1}{k_2} \right) \quad (17)$$

Onde

V_i é a tensão na barra i ;

δ_i é o ângulo na barra i ;

r_i é a resistência em série na linha que conecta a barra i ;

x_i é a reatância em série na linha que conecta i ;

$$k_1 = \frac{P_i x_i - Q_i r_i}{V_i};$$

$$k_2 = V_i - \frac{P_i x_i - Q_i r_i}{V_i}.$$

4. O critério de convergência faz a verificação da tensão e do ângulo, de forma que, a iteração atual seja comparada com a anterior. Assim, se a diferença encontrada for igual ou superior a uma tolerância estipulada, neste caso, a tolerância sempre deve estar próximo de zero, deve-se repetir o processo, iniciando-se do passo 2, caso contrário encerra-se o cálculo.

Esta seção abordou os métodos de solução através do fluxo de carga, contudo, são utilizados nos AEMOs descritos no capítulo 5 o método soma de correntes, pois o mesmo apresenta menor complexidade. Ainda, em relação aos AEMOs, os mesmos utilizam a Representação Nó-Profundidade (RNP), com o objetivo de reproduzir um sistema de distribuição radial real, desta maneira, o fluxo de carga utilizado sofre ajustes para adequar a RNP a metodologia. A seção 2.6 descreve o funcionamento da RNP.

2.6. REPRESENTAÇÃO NÓ-PROFUNDIDADE

Os algoritmos analisados neste trabalho utilizam a representação Nó-Profundidade (RNP). A RNP representará para os algoritmos a topologia elétrica do sistema de distribuição radial (SDR). É possível observar nos trabalhos propostos por Mansour (2009), Sanches (2013) e Santos (2009), que a RNP garante a eficiência computacional. Assim, é fundamental conhecer a estrutura RNP e os seus operadores.

A representação nó-profundidade proposta por Delbem et al. (2004), fundamenta-se na definição de nó e profundidade de nó em uma árvore, onde árvore é um grafo simples acíclico e conexo, como se pode observar na Figura 7 (a). A estrutura da RNP é composta por uma lista linear contendo os nós da árvore e as suas profundidades. A lista mencionada é gerada por pares (n_x, p_x) , assim, p_x é a profundidade do nó e n_x o nó da árvore (SANCHES, 2013).

Para fazer essa lista computacionalmente é necessário construir uma matriz de dimensão $2 \times n$, onde n é o número de nós da árvore que está sendo utilizada. Cada par (n_x, p_x) é alocado em uma coluna da matriz, onde p_x e n_x são armazenados respectivamente na primeira e na segunda linha, como pode ser observado na Figura 7 (b). É utilizado um algoritmo de busca em profundidade para armazenar um nó e a sua respectiva profundidade na RNP. Desta forma, iniciando a busca a partir do nó raiz da árvore, é gerada uma lista de pares (n_x, p_x) em uma determinada sequência, esta sequência é produzida a partir da visita do nó n_x , ou seja, inicia-se a busca em um determinado local e toda vez que tocar um ponto pré-estabelecido, no caso, n_x os dados serão alocados em uma lista (SANCHES, 2013).

A Figura 7 ilustra um exemplo de como uma árvore é armazenada na RNP. Já a Figura 7 (b) mostra a RNP para a árvore geradora, esta por sua vez é representada por linhas espessas no grafo, como é possível ver na Figura 7 (a). De início, é armazenado o nó da raiz da árvore, no caso deste exemplo o nó 1, com profundidade igual a zero, como pode ser examinado na Figura 7 (b). Na sequência é feita uma busca em profundidade na árvore, através dos ramos conectados ao nó raiz, é esta busca que conecta os demais nós a suas específicas profundidades, as quais serão calculadas sempre em relação ao nó raiz (SANCHES, 2013).

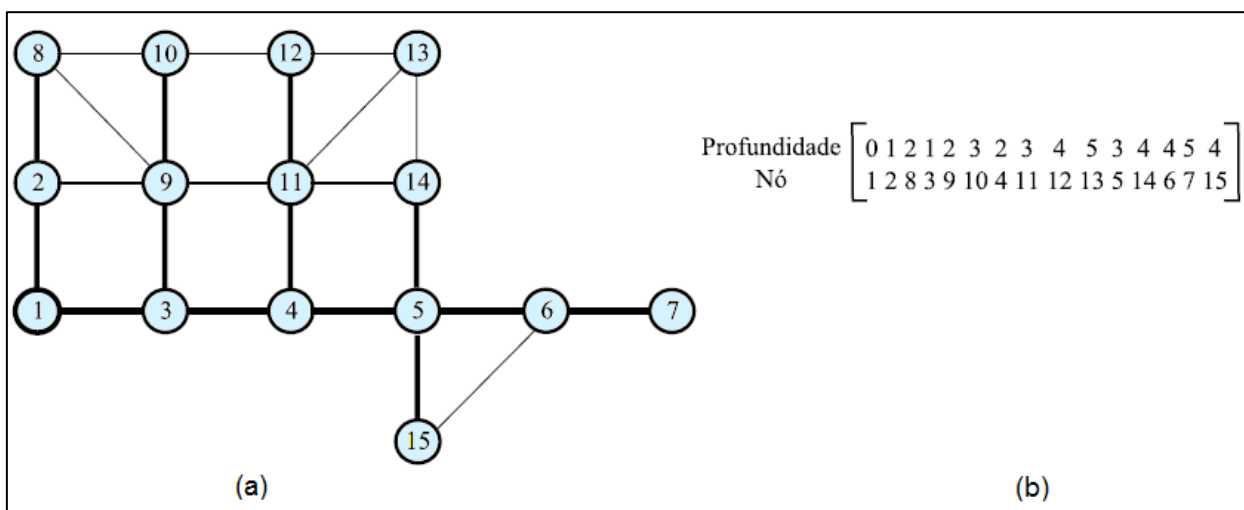


Figura 7 - Exemplo de um (a) Grafo e (b) RNP

Fonte: Adaptado de Sanches (2013).

Assim, a Figura 7 (b) ilustra a representação da árvore, onde inicialmente tem-se o nó raiz, representado pelo número 1 (um) e sua respectiva profundidade, no caso, 0 (zero). Partindo para o próximo nó, o nó 2 (dois) possui profundidade 1 (um) em relação ao nó raiz, continuando tem-se o nó 8 (oito) com profundidade 2

(dois) em relação ao nó raiz, o próximo nó é o 3 (três) que detém profundidade 1 (um), e assim sucessivamente, nota-se que sempre se fixa o nó raiz, e a partir dele vai se caminhando, de forma que, o próximo nó esteja nas proximidades do nó raiz e que o mesmo apresente a menor profundidade possível. A reunião dos nós reproduz uma árvore.

A junção das codificações de todas as árvores compõe a codificação que gera uma floresta. Desta forma, os dados da floresta são capazes de serem implementados utilizando uma lista de ponteiros, esses ponteiros podem indicar a RNP de uma árvore da floresta (SANCHES, 2013).

2.6.1. Operadores da RNP

Foram criados dois operadores para ajudar no manuseio da floresta armazenada em RNP. O primeiro é conhecido como PAO – *Preserve Ancestor Operator* (operador que preserva o ancestral), já o segundo chamado de CAO – *Change Ancestor Operator* (operador que muda o seu ancestral). Esses operadores podem gerar uma floresta F' de um grafo G quando são impostas a outra floresta F de G . Por experimentação, autores como Sanches (2013) e Santos (2009) dizem que os resultados encontrados utilizando qualquer um dos operadores são similares. Assim, por exemplo, se uma floresta com duas ou mais árvores trabalhar com um desses operadores, o que ocorre pode-se dizer que corresponde a transferir uma subárvore, que é considerada como a parte podada da árvore de origem A_{de} para uma árvore de destino A_{para} . Porém, no operador PAO a raiz da subárvore podada vem a ser a raiz dessa subárvore em A_{para} . O operador CAO procede de outra forma, um nó diferente da raiz é escolhido, ou seja, um novo nó será a raiz da subárvore A_{para} (SANCHES, 2013).

Os operadores da RNP modificam a floresta gerando configurações factíveis. De forma que, estas configurações aumentem significativamente a eficiência da busca por melhores configurações de AE. Vale ressaltar, que a utilização da RNP para problemas de restabelecimento de energia elétrica torna a execução do fluxo de carga extremamente rápido e por este motivo atualmente é bem utilizado.

No próximo capítulo será abordado os algoritmos evolutivos, bem como a estrutura geral de algoritmos evolutivos com múltiplos objetivos.

3. ALGORITMO EVOLUTIVO PARA OTIMIZAÇÃO MULTIOBJETIVO

A otimização combinatória multiobjetivo consiste na resolução de problemas. Assim, um problema de otimização multiobjetivo tenta minimizar ou maximizar um conjunto de objetivos de modo a satisfazer as restrições impostas pelo problema. Estes problemas não apresentam apenas uma única solução e sim um conjunto de soluções não dominadas, que é chamado de conjunto de Pareto Ótimo ou de Fronteira de Pareto Ótimo (DEB, 2001). Antecipando, pode-se dizer que uma solução A domina a solução B, quando A é melhor que B em pelo menos em um objetivo e não pior em todos os outros objetivos.

Neste capítulo será abordado a definição de algoritmos evolutivos, em seguida é apresentado a otimização multiobjetivo e como é construída a sua estrutura geral.

3.1. ALGORITMO EVOLUTIVO

Entre os anos de 1950 e 1960 vários cientistas da computação iniciaram estudos sobre sistemas evolutivos com a idéia de que o sistema de evolução poderia ser usado como uma ferramenta de otimização para problemas de engenharia. A idéia inicial em todos esses sistemas era evoluir uma população de soluções candidatas para um determinado problema, usando algum operador, sendo este operador inspirado na variação genética natural e seleção natural da natureza (MITCHELL, 1998). Pelo exposto, pode-se dizer que os algoritmos evolutivos (AE) são algoritmos de otimização que tentam simular um processo da evolução natural, para tanto, existem três possibilidades de formulação, utilizando algoritmos genéticos, estratégias evolutivas e através de programação evolutiva.

Como os algoritmos são comparados aos processos evolutivos, por analogia denomina-se que as soluções candidatas, são os indivíduos, e o conjunto destas soluções recebem o nome de população (DEB, 2001).

Nos AEs cada iteração realizada tenta melhorar a capacidade dos indivíduos desta população, sendo assim, eles são avaliados e as soluções com melhor aptidão são selecionadas para a reprodução formando novas gerações. Após muitas comparações o sistema acaba aumentando a qualidade das soluções por que as soluções mais adequadas acabam dominando a população de indivíduos

(SANCHES, 2013). A seguir, são apresentadas algumas características da evolução natural, são elas: Indivíduos, seleção, recombinação e mutação.

A Figura 8 mostra de forma simplificada o funcionamento de um algoritmo genético simples. Os indivíduos ou população representam os organismos genéticos que farão o processo evolutivo. Já a seleção, mostra que os indivíduos mais adaptados sobreviverão e provavelmente se perpetuarão. A recombinação é o meio pelo qual o material genético dos ancestrais é transferido para os descendentes. Por final, ocorre à mutação que é a modificação aleatória do material genético dos indivíduos, ocorrendo desta forma a alteração nos cromossomos. Por conseguinte, a mutação pode aumentar a diversidade da população, isso acaba evitando que o algoritmo convirja rapidamente (MITCHELL, 1998; SANCHES, 2013).




Figura 8 - Diagrama de Funcionamento de um Algoritmo Genético Simples
 Fonte: Adaptado de Lureg (2014).

3.2. OTIMIZAÇÃO MULTIOBJETIVO

O modelo matemático de um problema é construído a partir de um sistema real e é de fundamental importância em otimização, pois é este modelo que deve identificar as funções objetivo, as restrições e as variáveis de controle.

A próxima seção explica os conceitos sobre a estrutura geral de AE multiobjetivo e também analisa a fronteira de Pareto.

3.2.1. Estrutura geral de um AE multiobjetivo

Otimidade de Pareto ou eficiência Pareto é um conceito muito utilizado em economia e com larga aplicação em engenharia (BATISTA, 2011). O termo otimalidade de Pareto surgiu após os estudos do economista italiano Vilfredo Pareto (1848-1923).

Por definição tem-se que a fronteira de Pareto é um conjunto factível (Ω) de soluções, em que, não há relação de dominância, da forma que, qualquer vetor y_i pertencente à fronteira Y_j não pode ser pior que os demais vetores desta fronteira em todos os objetivos.

Dado um conjunto de soluções $\{y_1 = f(x_1), y_2 = f(x_2), \dots, y_i = f(x_i), \dots, y_n = f(x_n)\} \in f(\Omega)$, estas soluções podem ser ordenadas, no domínio dos objetivos através de fronteiras $y = \{y_1, y_2, \dots, y_j, \dots, y_M\}$, sendo cada fronteira composta por soluções que não podem ser comparadas entre si (BATISTA, 2011).

A Figura 9 exhibe a fronteira de Pareto ótima (F), que tem o objetivo de minimizar f_1 e f_2 . De acordo com Pareto, os vetores da primeira fronteira y_1 são ditos incomparáveis entre si e melhores do que os da segunda fronteira y_2 , de maneira que, os vetores da segunda fronteira y_2 também são incomparáveis entre si e melhores que a próxima fronteira, desta forma, este processo se repete sucessivamente até que se chegue à última fronteira (BATISTA, 2011).




Figura 9 – Representação da Fronteira de Pareto Ótima
Fonte: Adaptado de Batista (2011).

A importância de se estudar as características de dominância dos conjuntos de solução encontrados a partir dos algoritmos evolutivos multiobjetivo é que se pode verificar qual conjunto possui a melhor solução para múltiplos objetivos.

Um conceito básico é que as funções objetivo empregadas em AEMOs são geralmente conflitantes entre si (DEB, 2001). A função objetivo f_1 é conflitante com outra função objetivo f_2 quando não se pode melhorar o valor da função f_1 sem acabar piorando o valor da função f_2 . Para ficar mais simples a compreensão é utilizado um exemplo abordado por Sanches (2013) e comumente encontrado na literatura, que é a tomada de decisão a partir de dois critérios, o conforto versus o custo para a compra de um automóvel. Como se pode perceber através da Figura 10, quanto maior o conforto, maior será o custo do automóvel (SANCHES, 2013).

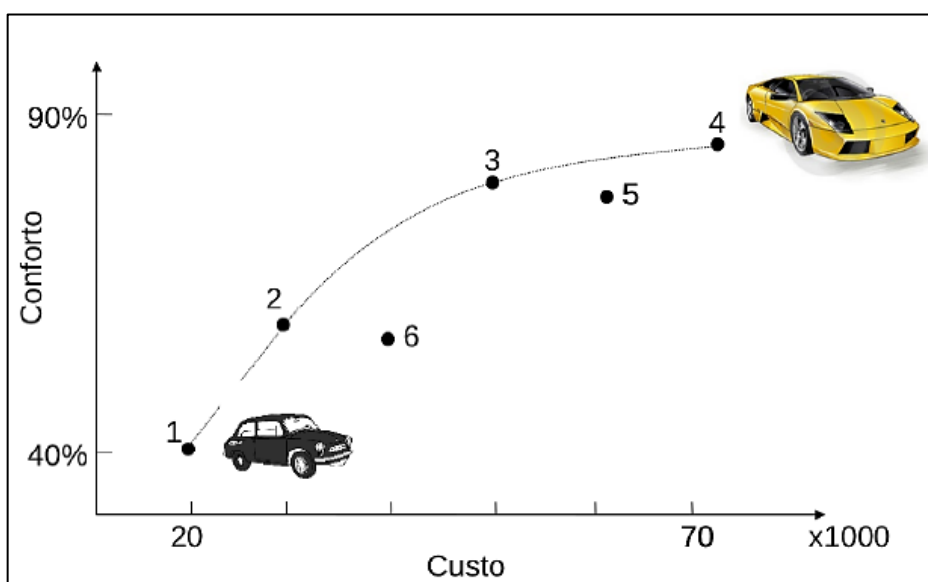


Figura 10 – Curva Conforto Versus Custo

Fonte: Adaptado de Sanches (2013).

O objetivo deste caso é maximizar o conforto e minimizar o custo. Analisando a Figura 10, por intuição pode-se descartar a opção 5 quando comparada com a 3, pois esta apresenta um maior custo e o conforto oferecido é menor. Já quando a solução 2 é confrontada com a 6, observa-se que a solução 6 também deve ser descartada, visto que, a opção 6 possui um custo elevado e conforto menor em relação a solução 2.

Em uma visão geral, não se pode comparar as soluções 1 e 4 por exemplo, pois não é possível afirmar qual das duas opções seria a melhor, já que 4 apresenta o maior conforto e 1 o menor custo. Conseguem-se então 4 boas alternativas para a

compra, que são as opções 1, 2, 3 e 4. Porém, dentre essas soluções não é admissível afirmar qual é a melhor, visto que, quando uma tem o maior conforto também possui o maior custo. Assim, parte-se do princípio de que uma solução domina a outra solução quando é melhor que a outra em pelo menos 1 objetivo e não em todos os outros objetivos.

Mediante a Figura 10 consegue-se retirar as soluções dominantes e as dominadas. Pelo exposto, tem-se que a solução 3 domina a solução 5 e a solução 2 domina a 6, logo as soluções 5 e 6 fazem parte do conjunto de soluções dominadas, enquanto que as soluções 1, 2, 3, e 4 estão no conjunto não dominado por nenhuma outra solução.

Para os AEMOs emprega-se o conceito de dominância de Pareto, como já vimos no tópico 3.2.1. São por meio destes conceitos que é possível comparar duas soluções factíveis de um problema. O conjunto de soluções não dominadas é chamado de conjunto Pareto-ótimo e representa as soluções ótimas do problema. Já a fronteira de Pareto é o conjunto dos valores da função objetivo das soluções do conjunto Pareto-ótimo (SANCHES, 2013).

Os dados que são discutidos neste trabalho são provenientes de algoritmos evolutivos multiobjetivo que estão explicitados na próxima seção. O importante neste momento é entender o problema deste trabalho, que é identificar qual conjunto de soluções apresenta o melhor resultado, visto que, os dados normalmente estão camuflados pela sobreposição das respostas.

Para entender esta proposição é fundamental analisar os dados encontrados na Figura 11 (a) e (b), que representam um conjunto de soluções para duas funções objetivo f_1 e f_2 . Aqui, comparando as Figuras 11 (a) e (b), depois do que foi exposto no tópico 3.2.1., fica evidente que o conjunto A (Figura 11 (a)) é melhor que B (Figura 11 (b)), por estar mais próximo da fronteira de Pareto. Assim, mesmo que os dados de A estejam dispostos nas extremidades da fronteira, os dados ainda se encontram sobre a fronteira e podem atender algum dos objetivos estipulados.

A análise desses conjuntos de soluções encontrados a partir dos AEMOs não é tão simples. Na Figura 12, encontram-se para as funções objetivo f_1 e f_2 dois conjuntos de soluções A e B. Ainda, na Figura 12 é possível ver o que normalmente ocorre com as soluções dos AEMOs, ou seja, os conjuntos de dados acabam se sobrepondo, dificultando a possibilidade de se encontrar a melhor solução ou até

mesmo determinar qual algoritmo possui o melhor desempenho para o objetivo imposto.

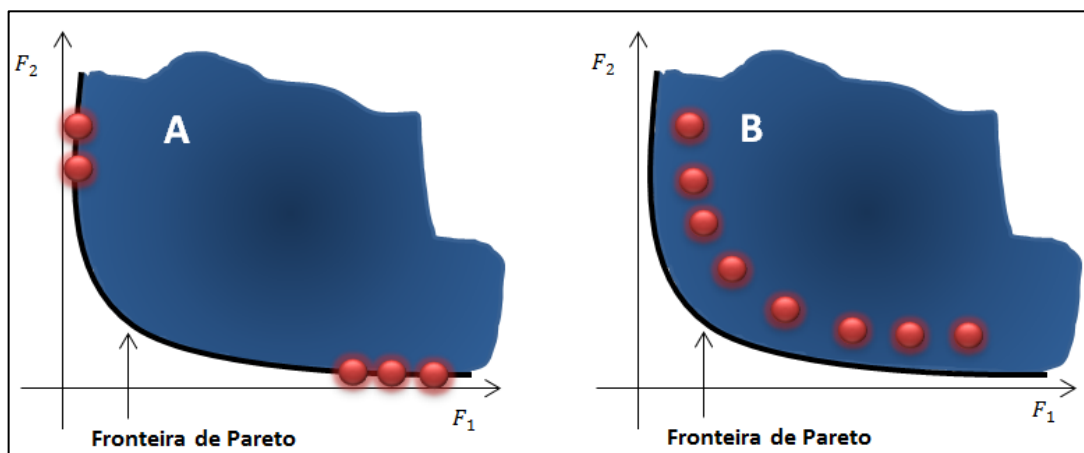


Figura 11 – Esquema Representativo da Fronteira de Pareto (a) Conjunto A; (b) Conjunto B
Fonte: Autoria própria.

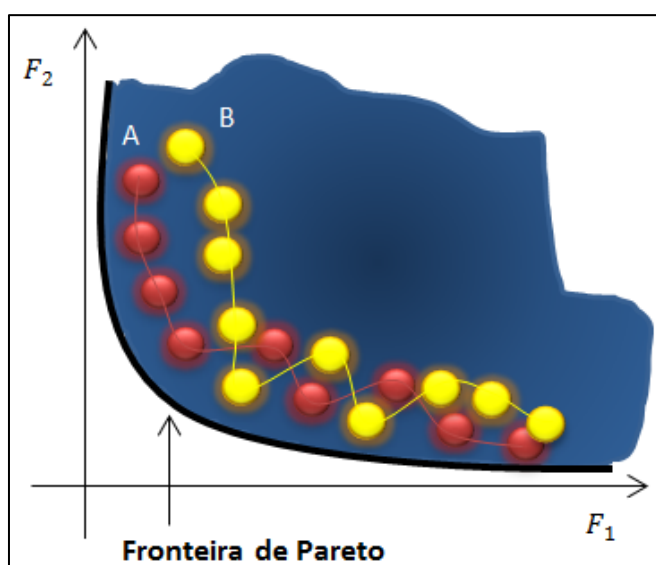


Figura 12 – Esquema Comparativo de Dois Conjuntos de Soluções
Fonte: Autoria própria.

Neste trabalho, será abordado um problema de minimização, onde a função objetivo traça um mapa de espaço para os parâmetros no qual serão seus objetivos. Além do que, o conjunto factível definirá o tamanho do espaço de busca que é delimitado pelo domínio das variáveis de otimização (BATISTA, 2011).

Após a análise da fronteira de Pareto e dos conjuntos de soluções, é possível continuar o estudo com a inserção dos algoritmos evolutivos clássicos que são utilizados neste projeto e abordados no capítulo 4.

4. ALGORITMOS EVOLUTIVOS CLÁSSICOS DA LITERATURA

Os algoritmos evolutivos são amplamente utilizados em problemas de otimização multiobjetivo por apresentarem algumas características relevantes como: trabalham com mais de uma função simultaneamente e são capazes de escapar de ótimos locais.

Neste capítulo são apresentados os três algoritmos utilizados para a aquisição dos conjuntos de dados. Os dados são referidos as manobras operacionais do sistema de distribuição radial real. Assim, são empregados os seguintes algoritmos evolutivos clássicos:

- AEMT- Algoritmo evolutivo multiobjetivo em tabelas;
- AEMT-SP - AEMT com soluções não dominadas baseado na função distância de multidão do NSGA-II e força de Pareto do SPEA2;
- NSGA-II - *Elitist non-dominated sorting genetic algorithm*.

Os três algoritmos citados foram escolhidos por possibilitarem o tratamento dos problemas de redução de perdas e restabelecimento de energia elétrica em sistemas de distribuição radiais de grande porte. A seguir são analisados cada AEMO proposto para a reconfiguração de redes.

4.1. AEMT: ALGORITMO EVOLUTIVO MULTI OBJETIVO EM TABELAS

O algoritmo evolutivo multiobjetivo em tabelas (AEMT), trabalha com várias subpopulações em paralelo armazenadas em tabela, como pode ser visto em Benayoun et al. (1971) e Delbem et al. (2005), onde os melhores indivíduos para cada característica do problema são alocados em uma respectiva subpopulação. O algoritmo AEMT é programado utilizando a RNP que é a representação nó-profundidade. Assim, a utilização da estrutura de dados RNP é base do desenvolvimento do AEMT, uma vez que esse tipo de codificação assegura a rápida geração de novas configurações da rede (SANCHES, 2013).

Uma subpopulação é criada para armazenar indivíduos avaliados por uma função agregação, esta função também é conhecida como método da soma ponderada. Cada subpopulação armazena indivíduos de forma que minimize

características como: a perda de potência; menor tensão na rede elétrica; carregamento das subestações; carregamento da rede; função agregação (SANTOS, 2009).

Indivíduos que foram selecionados para a reprodução podem ter vindo de qualquer subpopulação da tabela. Essa tática para a seleção tende a aumentar a diversidade entre os indivíduos que reproduzem, de forma que, as características de um indivíduo de uma subpopulação acabam por migrar para as demais subpopulações da tabela (SANTOS, 2009). Esse processo aumenta a possibilidade do algoritmo fugir de ótimos locais, aproximando-se de soluções com um ótimo global na fronteira de Pareto ótima.

Existem dois parâmetros que são importantes na avaliação de desempenho do algoritmo AEMT:

- S_{P_i} – Tamanho de uma subpopulação, este termo indica o número máximo de indivíduos que podem permanecer na subpopulação P_i de uma geração para outra. $S_{P_i} = 5$, para $i = 1, \dots, 5$ e 15000 iterações;
- $g_{máx}$ – Número máximo de gerações.

As soluções encontradas através do algoritmo AEMT estão relacionadas com o grau de adaptação do indivíduo para cada objetivo do problema. Assim, estas soluções podem ser utilizadas ou não, dependendo da característica do problema em uma subpopulação P_i . Na seleção de sobreviventes, um indivíduo só será acrescentado a uma subpopulação P_i se sua adequação ao objetivo de P_i for melhor que pelo menos um indivíduo que se encontre na mesma. Assim, pelo critério de seleção o mesmo indivíduo pode estar incluído em mais de uma tabela. No AEMT a população é tida como estacionária, desta forma, os novos indivíduos irão substituir os piores. A adequação do indivíduo será um vetor de valores relativos a cada objetivo ou restrição. Neste caso, para os objetivos o vetor poderia conter informações a respeito das perdas, do número de chaveamento e etc. Já para as restrições, as informações seriam sobre o carregamento nas linhas, a queda de tensão, entre outros (SANTOS, 2009).

O algoritmo AEMT trabalha com operadores, esses são selecionados para a reprodução segundo um ajunte dinâmico. Inicialmente, o algoritmo começa a

varredura utilizando a mesma taxa de probabilidade para todos os operadores, por exemplo, são selecionados dois operadores, com taxas de probabilidade idênticas $P_1 = P_2 = 0,50$. Considerando que o operador 1 foi o escolhido para gerar um novo indivíduo, se o indivíduo gerado obter sucesso, quer dizer, for adicionado a uma ou mais subpopulações, então aumenta-se o valor para $P_1 = 0,51$ e, por este acréscimo o valor de $P_2 = 0,49$ é reduzido, e assim sucessivamente. Como se pode observar em Sanches (2013) e Santos (2009), é este ajuste dinâmico do método da escolha dos operadores que aperfeiçoa o desempenho do algoritmo AEMT.

A análise dos indivíduos no AEMT é feita através da execução de um fluxo de carga específico para sistemas de distribuição radial. Assim, a cada novo indivíduo gerado, a rotina do fluxo de carga será executada para o par de alimentadores modificados do sistema (SANTOS, 2009).

O algoritmo AEMT gera apenas 1 indivíduo por iteração, ao contrário do algoritmo NSGA-II, que será analisado no tópico 4.3, que possibilita a criação de vários indivíduos em apenas uma iteração (SANTOS, 2009).

4.2. AEMT-SP: AEMT COM SOLUÇÕES NÃO DOMINADAS E *STRENGTH PARETO*

O algoritmo evolutivo multiobjetivo em tabelas com soluções não dominadas e *strength Pareto* é mais conhecido como AEMT-SP, e combina características de outros importantes algoritmos como o NSGA-II (tópico 4.3), o AEMT-SND (Algoritmo evolutivo multiobjetivo em tabelas com soluções não dominadas) (SANCHES et al., 2011) e o AEMT analisado anteriormente. Além desta composição, faz uso da RNP e de seus operadores que são baseados no SPEA2 (*Strength Pareto Evolutionary Algorithm*) (ZITZLER et al., 2001).

O objetivo de se construir essa metodologia foi o de corrigir o problema da falta de diversidade das soluções encontradas no AEMT. Essa dificuldade ocorre porque o AEMT não faz uso do conceito de classificação por camadas, do ranking, desta forma, acaba não separando as soluções entre dominadas e não dominadas, como o algoritmo NSGA-II faz (método abordado no tópico 4.3). Assim, uma fronteira de Pareto criada pelo AEMT gera poucas soluções concentradas nos extremos da fronteira (SANCHES, 2013).

O algoritmo AEMT-SP é baseado na ideia de tabelas de subpopulações, como o AEMT, porém o AEMT-SP utiliza novas tabelas de subpopulações, sendo estas definidas por novas tabelas de subpopulações não dominadas, para tanto, essa técnica usa a não dominância entre as soluções, pois tenta assegurar que haja diversidades entre as soluções encontradas. As novas tabelas encontradas classificam e armazenam os indivíduos de acordo com o grau de dominância entre as soluções.

O AEMT-SP possui outra característica que é conhecida como *strength* (força), que é a inclusão de uma tabela de força dos indivíduos. Deseja-se com a criação desta tabela assegurar a convergência e distribuição das soluções na fronteira de Pareto. O *raw* é o valor armazenado na tabela e é conhecido como valor de aptidão bruto de cada indivíduo, seu valor é obtido através da somatória do *strength*. Assim, define-se a melhor solução sendo aquela que não é dominada por outra solução contida na tabela, ou seja, a solução que tem o valor de aptidão bruto (*raw*) igual a zero (SANCHES, 2013).

Respeitando os objetivos e as restrições operacionais as tabelas de subpopulações são preenchidas. Assim, um novo indivíduo gerado I_{New} é inserido em uma tabela de subpopulação P_i , se esta tabela ainda não estiver totalmente preenchida ou se I_{New} for melhor do que a pior solução encontrada na subpopulação P_i (SANCHES, 2013).

As tabelas de subpopulações não dominadas são representadas respectivamente por F_1 , F_2 e F_3 . Desta maneira, as tabelas são preenchidas de forma a obedecer o grau de dominância da solução, assim, as soluções que não são dominadas por nenhuma outra solução são armazenadas na tabela F_1 ; já as soluções que são dominadas pelas soluções contidas em F_1 são armazenadas em uma nova tabela, ou seja, em F_2 ; A terceira tabela F_3 é formada pelas soluções dominadas que estão armazenadas em F_1 e F_2 .

A fim de garantir a diversidade entre as soluções contidas nas tabelas de subpopulação não dominada, o algoritmo AEMT-SP utiliza-se da função de distância de multidão proposta por Deb et al. (2001). A tabela *Strength* Pareto é representada por F_{str} e é preenchida com o valor de aptidão bruto de cada indivíduo, ao se atingir a capacidade máxima da tabela, a pior solução, ou seja, a que possui o maior valor de *raw* é automaticamente eliminada (SANCHES, 2013).

A seguir são explicitados alguns parâmetros de desempenho do AEMT-SP:

- G_{max} – É utilizado como critério de parada e também como o número máximo de indivíduos que são gerados no algoritmo AEMT-SP;
- S_{pi} – Representa o tamanho da tabela de subpopulação P_i , além disso, indica a quantidade de indivíduos que podem ser armazenados em P_i , assim se pode ter $i = 1, \dots, 5$. Desta forma, as subpopulações estão divididas em:
 - P_1 – Indivíduos com menor perda ôhmica;
 - P_2 – Indivíduos com menor queda de tensão;
 - P_3 – Indivíduos com menor carregamento da rede;
 - P_4 – Indivíduos com menor carregamento da subestação;
 - P_5 – Indivíduos com menor valor da função agregação.

Essa função é composta pelo número de operações de manobras e suas restrições operacionais, e também pelos valores das perdas ôhmicas (SANCHES, 2013).

- S_{fi} – Representa o tamanho da tabela de subpopulação com soluções não dominadas F_i , onde $i = 1, 2, 3$.
- S_{fstr} – Denomina o tamanho da tabela Strength Pareto.

O algoritmo AEMT-SP utiliza duas funções como critério de entrada para as tabelas de subpopulações não dominadas, a primeira é o número de operações de manobras e a segunda a própria função agregação (SANCHES, 2013). Assim, dada uma solução I_{New} , é necessário verificar se o valor da função poderção de I_{New} e o número de operações de manobras é menor ou igual a pelo menos uma solução presente na tabela de subpopulações não dominadas F_1 , ou seja, verifica-se se a solução encontrada por I_{New} domina alguma solução de F_1 . Caso a solução seja dominada por alguma solução de F_1 , então é refeita essa verificação, porém agora emprega-se a tabela de subpopulações não dominadas F_2 , esse processo vai se repetindo até chegar a última tabela de subpopulações (SANCHES, 2013).

O processo de armazenamento das soluções na tabela de *strength* Pareto é feito da seguinte maneira:

- 1º - Calcula-se o valor de aptidão bruto de I_{New} em relação a todas as soluções presentes na tabela;
- 2º - Verifica-se se o valor de aptidão bruto de I_{New} é inferior ao valor de aptidão bruto da pior solução encontrada na tabela. Caso isso seja verdadeiro, então é feita a troca da pior solução na tabela pelo valor de I_{New} , caso ocorra o contrário então a tabela não é alterada.

Face ao exposto, o AEMT-SP de modo similar ao AEMT pode ser empregado em problemas de redução de perdas e restabelecimento de energia elétrica em sistemas de distribuição de grande porte após a ocorrência de faltas elétricas.

Na próxima seção será analisado o último algoritmo empregado neste trabalho.

4.3. NSGA-II: *ELITIST NON-DOMINATED SORTING GENETIC ALGORITHM*

O algoritmo NSGA-II - *Elitist Non-Dominated Sorting Genetic Algorithm* (Algoritmo genético de classificação elitista não dominada) foi proposto por Deb et al. (2000). Esse algoritmo se baseia na ordenação elitista por dominância conhecido por Pareto ranking.

O procedimento de Pareto ranking tenta classificar as soluções de um conjunto M em várias fronteiras (F_1, F_2, \dots, F_k , onde k é o número de fronteiras) conforme o grau de dominância que cada solução apresenta. Desta forma, cada fronteira se sobressai sobre a próxima, ou seja, a fronteira F_1 possui as soluções não dominadas de todo conjunto de soluções M , já a fronteira F_2 contém as soluções não dominadas de $M - F_1$, a terceira fronteira F_3 têm as soluções não dominadas de $M - (F_1 \cup F_2)$ e desta maneira o processo ocorre sucessivamente até encontrar uma última fronteira (MANSOUR, 2009).

A ordenação por não dominância proposta por Deb et al. (2000) detém o seguinte procedimento: para cada solução i encontrada e contida em P , calcula-se

dois valores, nd_i que é o número de soluções que dominam a solução i e U_i que é o conjunto de soluções que são dominadas pela solução i . De forma que, quando as soluções são $nd_i = 0$, se diz que as soluções estão contidas na fronteira F_1 . Assim, o código para a implementação do NSGA-II percorre o conjunto de soluções dominadas U_i para cada solução i apresentada na fronteira F_1 . O contador nd_j , de cada solução j em U_i , é decrementado em 1. Isso ocorre para que se preencha o valor encontrado na fronteira a qual a solução pertence, de forma que, se $nd_j = 0$, então a solução j pertence à próxima fronteira, neste caso, F_2 . Esse processo vai se repetindo até que todas as soluções possíveis sejam classificadas na sua respectiva fronteira. A Figura 13 ilustra o preenchimento das fronteiras, aplicado às soluções que minimizam as funções objetivo f_1 e f_2 (MANSOUR, 2009).

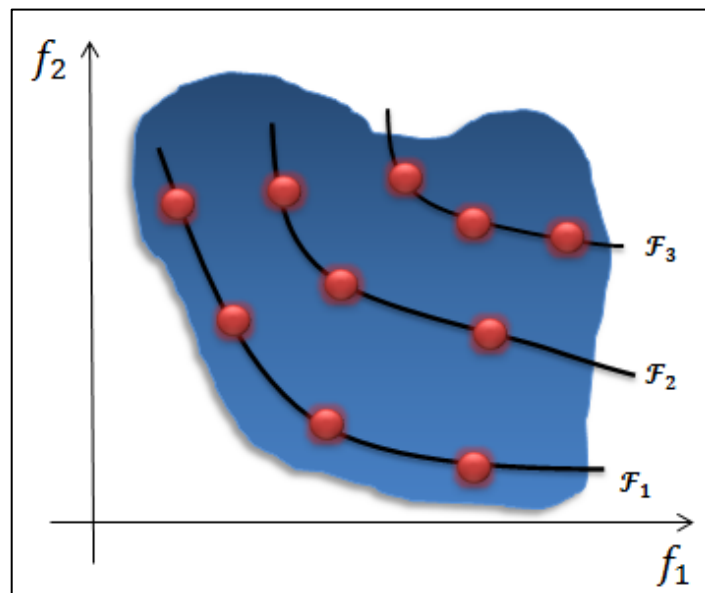


Figura 13 – Ordenação por Não Dominância

Fonte: Autoria própria.

O NSGA-II é um algoritmo que utiliza duas populações conhecidas como P e Q , ambas de tamanho N_{ind} . A cada iteração $t = 1, 2, 3, \dots, N_{iter}$ as populações P e Q passam a ser representadas respectivamente por P_t e Q_t . Inicialmente na primeira geração, os indivíduos iniciais da população P_1 geram suas soluções na população Q_1 , isso ocorre por meio da aplicação de operadores genéticos. Logo em seguida, inicia-se um processo competitivo para completar N_{ind} vagas para a próxima solução P_{t+1} , entre $2 * N_{ind}$ indivíduos contidos em R_t , onde $R_t = P_t \cup Q_t$. A operação descrita é realizada utilizando a ordenação por não dominância em R_t , esse

procedimento é conhecido como elitismo, pois encaminha as soluções não dominadas contidas nas fronteiras diretamente para a próxima geração.

O algoritmo NSGA-II busca manter a diversidade na fronteira e para que isso ocorra, calcula uma estimativa de densidade das soluções que ficam ao redor de cada indivíduo da população. Para este procedimento, é feito o cálculo da média das distâncias das duas soluções adjacentes a cada indivíduo para todos os objetivos. O valor encontrado recebe o nome de distância de multidão (MANSOUR, 2009).

O cálculo da distância de multidão faz com que as melhores soluções espalhadas passem a ocupar as últimas vagas disponíveis de P_{t+1} , isso garante a diversidade das soluções. A população formada por Q_{t+1} utiliza os operadores de seleção por torneio, recombinação e mutação em P_{t+1} . O algoritmo NSGA-II continua por mais N_{iter} iterações e as soluções finais encontram-se em $P_{N_{iter}} \cup Q_{N_{iter}}$ (MANSOUR, 2009). A Figura 14 ilustra o procedimento de funcionamento do algoritmo NSGA-II para ocorrer uma iteração.

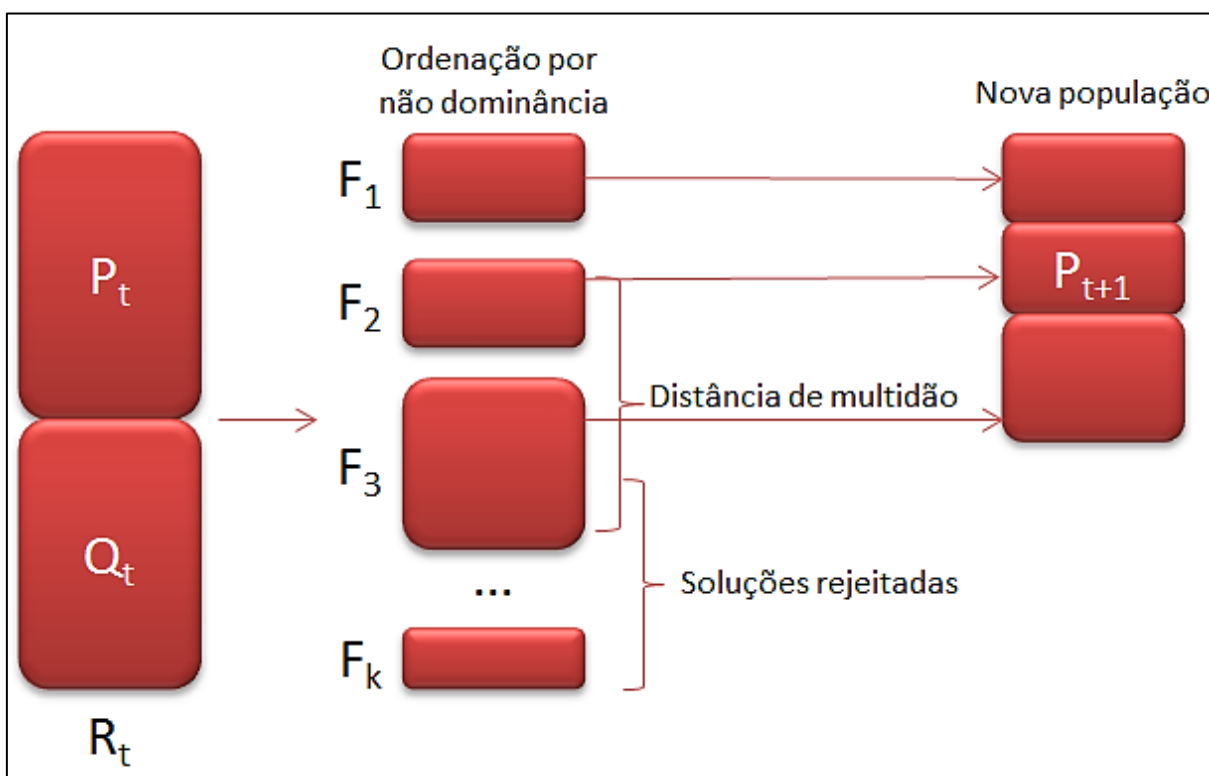


Figura 14 – Esquema do Modelo NSGA-II

Fonte: Adaptado de Mansour (2009).

Este capítulo apresentou as metodologias AEMT, AEMT-SP e a NSGA-II que serão utilizadas neste trabalho. No próximo capítulo se inicia a discussão da estatística empregada, com o objetivo de tratar os dados obtidos através da execução dos três AEMOs analisados.

5. ESTATÍSTICA APLICADA

Estatística é a ciência que nos ajuda a tomar decisões e tirar conclusões a cerca de algo na presença de variabilidade. Por variabilidade pode se entender como a observação sucessiva de um sistema ou fenômeno que não produz o mesmo resultado (MONTGOMERY; RUNGER, 2002).

O teste estatístico tem o propósito de verificar se os dados obtidos experimentalmente com uma ou mais amostras são equivalentes, e ainda tenta identificar as diferenças entre as amostras.

Este trabalho apresenta uma comparação estatística com base nas metodologias de AEMOs abordados no capítulo 4, onde se faz a comparação desses AEs sob alguns critérios. A análise de cada critério é baseada na construção progressiva de um ranking dos algoritmos, com a determinação de níveis de significância para a classificação dos mesmos.

A agregação de diferentes AEMOs para a formulação de um ranking é tida como uma análise não dominante e que indica os algoritmos que constituem o conjunto de maior eficiência.

A comparação entre os algoritmos de otimização que compõe métodos alternativos para lidar com problemas ou classes de problemas específicos, como a reconfiguração do sistema de distribuição de energia elétrica, geralmente envolve algum tipo de esforço computacional associado à execução do algoritmo e a qualidade da solução.

Algoritmos evolutivos que apresentam estruturas flexíveis facilitam a construção de novos AEMOs. De acordo com Carrano et al. (2010) cada variação do operador dentro de um algoritmo leva a uma nova versão do algoritmo com seu próprio desempenho associado. Este cenário combinatório de possíveis algoritmos que são originados a partir das variações de diversos operadores, levam à necessidade de métodos para a avaliação de tais grupos de algoritmos. Isso motiva o desenvolvimento de métodos para a avaliação e comparação de desempenho de AEs, como pode ser visto nos trabalhos de Dutta et al. (1996), Takahashi et al. (2003) e Shilane et al. (2006), onde os autores citados utilizam a estatística como principal abordagem.

Muitos estudos como os dos autores Sanches (2013) e Santos (2009) apresentam a fraqueza de realizar comparações com base apenas em valores

médios. Este tipo de comparação desconsidera as informações sobre a distribuição de dados (como os dados são espalhados ao redor da média), também não fornece qualquer informação sobre a incerteza associada com o uso de um conjunto de amostras, e não se faz uma estimativa do comportamento esperado do algoritmo. A fim de considerar tais fatores, o trabalho proposto utiliza técnicas de avaliação de algoritmo baseado na análise estatística.

Para a avaliação dos dados dos AEMOs do capítulo 4, o *software* utilizado para a comparação e resolução dos algoritmos de forma estatística é o R projetos para computação estatística (*R Project for Statistical Computing*). R é uma linguagem de programação estatística, que foi desenvolvida por Ross Ihaka e Robert Gentleman em 1993.

O R fornece uma ampla variedade de métodos estatísticos (linear e modelagem não linear, testes estatísticos clássicos, análise de séries temporais, além de pacotes de algoritmos multiobjetivo e etc.) e técnicas gráficas. O R está disponível como *software* livre sob os termos da GNU licença pública geral. O R foi escolhido para a implementação e análise dos dados, pois apresenta ferramentas computacionais confiáveis e também por ter licença pública.

Para se efetuar uma boa investigação devem-se conhecer os testes empregados. Assim, mediante ao exposto, aborda-se nas próximas seções o conceito de distribuição normal, de testes não paramétricos e do teste de Wilcoxon.

5.1. DISTRIBUIÇÃO NORMAL

Distribuição normal é a junção de dados que obedecem a uma disposição simétrica em torno da média (MONTGOMERY; RUNGER, 2002).

A distribuição normal, representada na Figura 15, possibilita fazer uma análise estatística com os dados da própria amostra. Porém, existem distribuições nas quais não ocorre simetria, como ilustra a Figura 16, sendo chamadas de assimétricas, pois podem sofrer desvios para a direita ou esquerda. Portanto, quando se compara dois grupos de variáveis dependentes e da sua análise resulta a assimetria, pode se dizer que nos testes paramétricos as soluções não são válidas, desta forma, quanto maior o desvio da distribuição, menor validade este método terá (MONTGOMERY; RUNGER, 2002).




Figura 15 – Distribuição Normal

Fonte: Adaptado PortalAction (2014).




Figura 16 – Curva de Distribuição Assimétrica

Fonte: Adaptado PortalAction (2014).

Por apresentar desvios na distribuição e ter dados assimétricos o teste de hipótese que se emprega deve ser não paramétrico.

Se os dados não satisfazem as suposições assumidas pelas técnicas tradicionais, métodos não paramétricos de inferência estatística devem ser usados, assim, justifica se conhecer melhor os testes não paramétricos.

5.2. TESTE NÃO PARAMÉTRICO

Testes não paramétricos baseiam-se em dados, estes por sua vez, podem ser ordinais ou nominais. Normalmente, este teste é empregado quando há a necessidade de soluções rápidas, pois os seus cálculos são bem dinâmicos (BUSSAB, 2013).

Os testes não paramétricos necessitam de menos cálculo para as distribuições quando comparados com os testes paramétricos. São mais utilizados quando há a necessidade da análise de grandes amostras em que pressupostos

paramétricos não estão presentes e em testes de hipótese (MONTGOMERY; RUNGER, 2002).

A partir dos anos de 1940, a ideia de testes de postos, ou seja, de *ranks* ganhou força na literatura estatística (MONTGOMERY; RUNGER, 2002). Desde então, tem-se testes não paramétricos para uma ou mais amostras. A chave para avaliar os dados em uma estrutura não paramétrica é comparar observações com base em seus postos no interior da amostra.

As técnicas não paramétricas assumem pouca ou nenhuma hipótese sobre a distribuição de probabilidade da população na qual se retira os dados, e por este motivo, é essencial utilizar um teste de hipótese para investigar a distribuição das amostras. Pelo proposto, será utilizado como teste de hipótese o teste de Wilcoxon, que é um método eficiente e é classificado como não paramétrico, atendendo assim o pré-requisito dos dados que serão analisados. Na próxima seção será possível entender o funcionamento do teste de Wilcoxon e notar todas as características até agora mencionadas.

5.3. TESTE DE WILCOXON

O teste de Wilcoxon, ou também conhecido como teste de Wilcoxon–Mann-Whitney, considera duas populações contínuas e independentes, neste caso, expressas por P_1 e P_2 . O teste também avalia as duas amostras independentes das duas populações X_1 e X_2 (BUSSAB, 2013).

O objetivo de utilizar o teste de Wilcoxon é testar se as distribuições das populações são iguais em localização, isto é, tem-se o interesse em saber se uma população tende a ter valores maiores do que a outra, ou se elas têm a mesma mediana.

O teste de Wilcoxon é baseado nos postos, ou seja, no *rank* dos valores obtidos combinando-se as duas amostras. Isso é feito ordenando-se esses valores, do menor para o maior, independentemente de qual população cada valor provém.

Seja uma população P_1 com uma amostra aleatória x_1, x_2, \dots, x_m e uma população P_2 com a seguinte amostra aleatória y_1, y_2, \dots, y_n , de modo que, os valores x_m e os y_n são independentes e identicamente distribuídos. Além disso, suponha que os valores de x_m e os valores de y_n são mutuamente independentes e

considere a amostra y como sendo aquela com o menor tamanho amostral, isto é, $n \leq m$ (FERREIRA, 2004).

Para aplicar o teste de Wilcoxon-Mann-Whitney, deve-se supor que F e G são as funções de distribuição correspondentes às populações P_1 e P_2 , respectivamente. Assim, considera-se como hipótese nula, que a distribuição da população P_1 é igual à de P_2 , ou seja, supõe-se que as funções de distribuição são idênticas em todo intervalo t .

$$H_0: F(t) = G(t), \text{ para todo } t \quad (18)$$

A hipótese alternativa considera que y tende a ser maior (ou menor) que x . Outra forma de se analisar é considerar que y tem a mesma distribuição de $x + \Delta$. Assim, neste caso, considerando que o valor médio esperado $E(x)$ da P_1 exista e utilizando que $E(y)$ seja o valor médio da população P_2 , espera-se que:

$$\Delta = E(y) - E(x) \quad (19)$$

Onde a hipótese nula (H_0) se reduz a:

$$H_0: \Delta = 0 \quad (20)$$

Lembrando que H_0 é uma amostra aleatória e H_1 uma amostra não aleatória. Assim, é possível estabelecermos uma das seguintes hipóteses em um teste de Wilcoxon.

Primeira hipótese

$$\begin{cases} H_0: \Delta = 0 \\ H_1: \Delta \neq 0 \end{cases} \quad (21)$$

Segunda hipótese

$$\begin{cases} H_0: \Delta = 0 \\ H_1: \Delta > 0 \end{cases} \quad (22)$$

Terceira hipótese

$$\begin{cases} H_0: \Delta = 0 \\ H_1: \Delta < 0 \end{cases} \quad (23)$$

Em seguida, ordenam-se todos os valores das duas amostras, em ordem crescente e coloca-se o respectivo posto associado.

A utilização do teste de Wilcoxon tem por finalidade comparar os conjuntos de soluções encontrados pelos AEMOs empregados, para o restabelecimento de energia elétrica em sistemas de distribuição. Estes dados que irão ser confrontados representam o número de manobras operacionais necessário para a reconfiguração do sistema. Desta forma, o teste confronta aos pares as soluções dos AEMOs, no sentido de verificar se existem diferenças significativas entre os seus resultados. A utilização do teste para os AEMOs acarreta na possibilidade de conhecer se os algoritmos tem a mesma solução para os mesmos objetivos impostos. Assim, tem-se a oportunidade de verificar se o conjunto de amostras é semelhante, porém não mostra qual AEMO é o melhor, para isso, empregam-se métricas comparativas multiobjetivo as quais são abordadas na próxima seção.

5.4. MÉTRICAS DE COMPARAÇÃO DE AEMO

Nesta seção serão descritos alguns métodos de comparação de AEMOS, os quais são usados normalmente para comparar os dados encontrados em relação ao seu desempenho.

O crescente aumento da utilização de algoritmos evolutivos multiobjetivo se deve ao interesse de resolver questões com multiobjetivo e a importância da comparação de desempenho dos mesmos. O resultado destes algoritmos são conjuntos de vetores não dominados. Assim, se existir dois vetores de um mesmo conjunto que se difere em alguns pontos em relação ao seu objetivo, é possível estimar que um vetor vá dominar o outro (KNOWLES; CORNE, 2002).

A tarefa de um algoritmo evolutivo de otimização multiobjetivo é gerar uma possível aproximação da solução, portanto estes algoritmos necessitam de uma comparação dos conjuntos não dominados. Contudo, não existe nenhuma maneira fácil de distinguir a qualidade dos diferentes conjuntos não dominados, desta forma, atualmente ainda se utiliza o plano gráfico como indicador de desempenho (VAN VELDHUIZEN; LAMONT, 2000).

Com o intuito de encontrar um ranking de algoritmos, as métricas de comparação de AEMO são empregadas para a busca do melhor desempenho.

Portanto, são utilizados neste trabalho algumas abordagens, como as métricas hipervolume, *epsilon*, *R2* e *R3*. As subseções a seguir abordam o funcionamento de cada métrica utilizada neste trabalho.

5.4.1. Métrica hipervolume

A métrica S ou hipervolume (HV) foi proposta por Zitzler e Thiele em 1999. Essa métrica é normalmente utilizada para comparar o resultado de algoritmos multiobjetivo e tem como objetivo avaliar a distribuição do conjunto de soluções em relação ao espaço de busca (ZITZLER et al., 1999).

Para se conseguir o hipervolume de um conjunto de soluções A se mede a área que o conjunto A cobre ou domina, ou seja, é calculado o volume da região coberta entre os pontos das soluções do conjunto A e um ponto de referência. Para cada solução encontrada i pertencente a A, é construído um hipercubo v_i com relação ao ponto de referência. Em problemas de maximização o ponto de referência usado é a origem (0; 0), já em problemas de minimização, o ponto de referência pode ser encontrado através da construção de um vetor com os piores valores da função objetivo, assim o ponto (x; y) é usado para limitar a área. A equação 24 representa a forma como o hipervolume pode ser calculado (REGO, 2013).

$$HV = \sum_{i \in A} v_i \quad (24)$$

Onde v_i representa o hipercubo da solução i encontrada.

Na Figura 17 é possível observar uma região sombreada, que define o hipervolume de um conjunto de soluções A para um problema com duas funções objetivo f_1 e f_2 , no qual o limite superior o ponto (x; y) é utilizado para limitar a área. Assim, pode-se denotar $H(A)$ como o hipervolume de conjunto de soluções A em função do ponto de referência (NÓBREGA, 2013).

Para uma boa resolução o valor do hipervolume deve ser o maior possível, pois quanto mais alto é esse valor tem-se um indicativo de que se obtém um elevado espalhamento das soluções de A. Ainda, acredita-se que o maior espalhamento das soluções indica uma melhor convergência (ZITZLER et al., 1999).




Figura 17 – Hipervolume Construído Através das Soluções da Fronteira A
Fonte: Adaptado de Zitzler (2003).

5.4.2. Métrica epsilon

Em 2003 a métrica epsilon multiplicativo foi proposta por Zitzler et al.. Essa métrica é totalmente baseada no conceito de ϵ -dominância.

Se diz que um vetor de objetivos $z^a = (z_1^a, z_2^a, \dots, z_n^a) \in Z$ ϵ -domina outro vetor de objetivos $z^b = (z_1^b, z_2^b, \dots, z_n^b) \in Z$, em um problema de minimização, se respeitar a equação 25 (ZITZLER et al., 2003).

$$\forall i \in \{1, \dots, n\}: z_i^a \leq \epsilon \cdot z_i^b \quad (25)$$

Em que i é um conjunto de soluções, n o número final de possibilidade e z_i^n é um vetor de objetivos.

A Figura 18, ilustra o funcionamento da ϵ -dominância para uma solução z^a em comparação com três valores diferentes de ϵ . Na Figura 18 (a), se considera um valor de ϵ menor que 1. Desta forma, é possível observar que a solução z^a ϵ -domina as soluções z^b , z^d e z^e . Já a Figura 18 (b) leva em consideração um ϵ igual a 1, neste caso, a solução z^a ϵ -domina as soluções z^d e z^e . Por último, na Figura 18 (c), ϵ recebe um valor maior que 1, assim a solução z^a ϵ -domina apenas z^d (ZITZLER et al., 2003).




Figura 18 – Representação da Métrica Epsilon

Fonte: Adaptado de Zitzler (2003).

Para dois conjuntos aproximados A e B , o valor encontrado da métrica *epsilon* multiplicativo (I_ϵ) representa o valor mínimo pelo qual cada ponto pertencente a B deve ser multiplicado para que o resultado encontrado seja fracamente dominado por A . O valor que ϵ deve possuir pode ser calculado através da equação 26 (ZITZLER et al., 2003).

$$I_\epsilon(A, B) = \max_{z^b \in B} \left\{ \min_{z^a \in A} \left\{ \max_{1 \leq i \leq r} \frac{z_i^a}{z_i^b} \right\} \right\} \quad (26)$$

É possível observar que o valor de ϵ precisaria ser calculado para todos os pares de soluções, pois, dessa forma se consegue comparar os algoritmos e observar o seu desempenho. Contudo, Zitzler et al. (2005) propôs uma nova versão do método, em que A é o conjunto de soluções não dominadas fornecidas por cada algoritmo, e o valor de ϵ é calculado apenas em relação ao conjunto de *REF* das melhores soluções conhecidas. Assim, temos que $I_\epsilon^1(A) = I_\epsilon(A, R)$. De maneira que $I_\epsilon(A, REF)$ mede a distância máxima do conjunto A em relação ao *REF*, assim acredita-se que um valor próximo de 1 para a medida $I_\epsilon^1(A)$ indica a qualidade do conjunto A (ZITZLER et al., 2005).

5.4.3. Métricas $R2$ e $R3$

Os pesquisadores Hansen e Jaszkiwicz, propuseram em 1998 as métricas $R2$ e $R3$. Essas métricas levam em consideração a expectativa dos valores da função de utilidade. Para o desenvolvimento das métricas devem-se considerar dois conjuntos aproximados A e B , onde u^* representa a função objetivo que é uma

função de utilidade, para a qual os menores valores são piores do que valores maiores, e as restrições representam o conhecimento prévio sobre os possíveis valores dos parâmetros e U é o conjunto de funções de utilidade (HANSEN; JASZKIEWICZ, 1998).

Para a análise da métrica $R2$ deve-se considerar:

$$R2(A, B, U, p) = E(u^*(A)) - E(u^*(B)) \quad (27)$$

De acordo com esta medida de aproximação, A é melhor do que B , se $R2(A, B, U, p) > 0$ e A é não pior do que B se $R2(A, B, U, p) \geq 0$.

A métrica $R2$ calcula a diferença esperada na utilidade de um conjunto A estar aproximado de um conjunto B . É uma métrica considerada como comparativa direta, e induz uma ordenação completa.

O mesmo método pode ser usado para construir uma medida que avalia a qualidade de uma única aproximação A em relação a um conjunto de referência fixo R . Assim, o valor encontrado em relação à referência R é chamado de $R2_R$ (HANSEN; JASZKIEWICZ, 1998).

$$R2_R(A, U, p) = R2(R, A, U, p) = E(u^*(A)) - E(u^*(B)) \quad (28)$$

Neste caso, quanto menor for o valor da medida $R2_R$, maior será a estimativa de A .

As vantagens de $R2$ surgem a partir da sua compatibilidade com todas as relações excedentes e o fato de que é capaz de distinguir entre diferentes níveis de desempenho. Porém, a sua aplicação depende do pressuposto de que cada função de utilidade deve ser adequadamente dimensionada em relação aos níveis relativos de importância (CZYIAK; JASZKIEWICZ, 1998).

Em alguns casos, as proporções dos melhores valores de utilidade podem ser mais significativas do que as diferenças. Por este motivo, Hansen e Jaszkiwicz também propuseram a métrica comparativa $R3$, que analisa a razão entre as medidas.

$$R3(A, B, U, p) = E\left(\frac{u^*(B) - u^*(A)}{u^*(B)}\right) \quad (29)$$

Quando um conjunto de referência é conhecido se pode usar a idéia de $R3$ para construir a seguinte medida:

$$R3_R(A, U, p) = R3(A, R, U, p) = E \left(\frac{u^*(R) - u^*(A)}{u^*(R)} \right) \quad (30)$$

$R3_R$ é utilizada quando se tem uma abordagem com um único objetivo de otimização, onde soluções aproximadas obtidas por heurísticas são avaliadas pelo quociente entre o seu valor real e o valor referência que foi fixado (HANSEN; JASZKIEWICZ, 1998).

As métricas comparativas multiobjetivo são ferramentas que podem ser utilizadas para avaliar e comparar aproximações e definir uma boa aproximação do conjunto de soluções não dominadas.

Cada métrica vislumbra uma forma adequada de se obter o melhor desempenho do AEMO em estudo, e ao mesmo tempo indicar a qualidade dos resultados encontrados. Portanto, ao se aplicar a métrica hipervolume espera-se alcançar o maior valor possível de HV, pois como vimos, quanto maior o valor de HV maior será a chance de se encontrar a convergência do método, ou seja, melhor performance terá esse AEMO. A métrica epsilon se empenha em encontrar um valor mínimo que multiplicado por um conjunto de soluções seja fracamente dominado por outro. Já as métricas $R2$ e $R3$ são baseadas no cálculo da probabilidade de que em algum ponto um conjunto de soluções é melhor que o outro.

Para aumentar a convalidação dos resultados encontrados através da utilização das métricas comparativas e do teste de hipótese, se utiliza a função de resultado empírico, abordada na próxima seção, e que tem como objetivo explorar a desempenho dos AEMOs de forma gráfica.

5.5. EAF - *Empirical Attainment Function*

A função de resultado empírico - EAF descreve a distribuição probabilística dos resultados obtidos por um algoritmo no espaço de objetivos. A função possibilita a implementação de parcelas de superfícies, bem como as diferenças de primeira ordem entre dois EAFs. Ainda, pode ser usada para explorar o desempenho dos algoritmos em problemas de otimização multiobjetivo, e também auxilia na identificação do comportamento dos algoritmos de forma gráfica (IBÁÑEZ, 2010).

A EAF tem como critério o princípio Pareto-otimização, e este por sua vez, pode ser estendido para comparar pares de conjuntos não dominados. Desta forma, é utilizado para a análise do desempenho dos algoritmos. Assim, dado dois conjuntos não dominados em um espaço de objetivos A e B , pode-se dizer que A é melhor que B em termos de Pareto-otimização se a cada $\mathbf{b} \in \mathbf{B}$ é dominado por pelo menos um ou igual a um $\mathbf{a} \in \mathbf{A}$, onde $A \neq B$. Se tivermos um A que não é um subgrupo normal de B ($A \not\subseteq B$), $B \not\subseteq A$ e $A \neq B$ se diz que A e B são incomparáveis, e nenhum conjunto pode ser preferido sobre o outro de acordo apenas com a noção de Pareto-otimalidade (IBÁÑEZ, 2010).

Para gerar os gráficos comparativos é necessário programar as funções no *software* R e inserir os dados que serão posteriormente lidos. A idéia principal é traçar a localização das diferenças entre os resultados de dois algoritmos em relação aos seus correspondentes EAFs. A EAF de um algoritmo calcula a probabilidade de realização de cada ponto no espaço de objetivos. Se a diferença entre os valores estimado das probabilidades de dois algoritmos é grande, isso indica um melhor desempenho de um algoritmo naquele ponto (IBÁÑEZ, 2010).

As diferenças entre os EAFs de dois algoritmos podem ser calculados computando primeiro a união dos resultados de ambos os algoritmos. Em seguida, para cada ponto no espaço é necessário calcular o valor da EAF do primeiro algoritmo nessa altura menos o valor da EAF do segundo algoritmo. Finalmente, as diferenças positivas e negativas são traçadas separadamente, e as magnitudes das diferenças entre as EAFs são codificadas utilizando diferentes tons de cinza, desta maneira, quanto mais escuro o ponto, maior é a diferença. Os pontos recebem um nível de cinza de acordo com a sua probabilidade, e quanto mais preenchido estiver essa região melhor serão as soluções.

O próximo capítulo utiliza todo o conhecimento proposto através das métricas, do teste de hipótese e do EAF e os aplica em algoritmos evolutivos multiobjetivo que tratam o problema de restabelecimento de energia elétrica. Assim, o capítulo 6 apresenta os resultados encontrados neste trabalho.

6. RESULTADOS

Os testes realizados e descritos neste capítulo, mostram os resultados das simulações computacionais realizadas no *software* R. Foi utilizado o SDR real da cidade de São Carlos no estado de São Paulo em operação no ano de 1994 para a implementação das metodologias. Foram consideradas todas as linhas de distribuição, as chaves e as barras do sistema. O sistema de distribuição empregado é composto por:

- 3860 barras;
- 533 setores;
- 632 chaves, subdivididas em: $\begin{cases} \text{NF} = 509 \text{ chaves} \\ \text{NA} = 123 \text{ chaves} \end{cases}$
- 1 subestação, no caso, a da cidade de São Carlos/São Paulo;
- 23 alimentadores;
- 2 transformadores de 25 MVA.

As simulações abordadas se concentram em problemas de restabelecimento de energia elétrica após a ocorrência de uma falta no sistema de distribuição. Foi escolhida esta abordagem devido à necessidade do operador em ter uma resposta rápida, ou seja, em tempo real e também por apresentar computacionalmente maior complexidade.

A implementação comparativa multiobjetivo e o teste de Wilcoxon foram implementados em linguagem R. Utilizou-se um notebook com processador Pentium Dual-Core 2,2GHz, 4 GB de memória RAM, Sistema Operacional Windows 8.1 Pro de 64 bits para implementar os métodos comparativos.

A análise foi realizada a partir dos resultados obtidos pelas metodologias propostas para o tratamento de problemas de restabelecimento de energia elétrica em sistemas de distribuição. As metodologias AEMT, AEMT-SP e NSGA-II foram comparadas entre si com o uso do teste de Wilcoxon, em que foi possível comparar a medida de posição das amostras, mostrando as diferenças entre elas em relação a sua disposição no espaço de soluções. Para avaliar as fronteiras de Pareto obtidas pelas três metodologias, foram utilizadas algumas métricas para medir a qualidade destas fronteiras, sendo elas: hipervolume, epsilon, R2 e R3, apresentadas no capítulo 5.

6.1. SIMULAÇÕES PARA O PROBLEMA DE RESTABELECIMENTO DE ENERGIA

Nesta seção as metodologias AEMT, AEMT-SP e NSGA-II serão analisadas e aplicadas no sistema de distribuição radial de São Carlos para o tratamento do problema de restabelecimento de energia elétrica, onde se considera a ocorrência de apenas uma falta.

Foi considerada a metodologia com o melhor desempenho aquela que obtiver o menor número de manobras operacionais sem violar as restrições operacionais impostas. Em relação às restrições operacionais, foram considerados os seguintes limites:

- Queda de tensão de no máximo 10%, porém os algoritmos obtêm valores abaixo dos 7% exigidos em norma;
- Carregamento da rede e das subestações de no máximo 100%.

Ademais, as metodologias utilizadas propõem a criação de subpopulações para armazenar os indivíduos avaliados por uma função agregação, desta forma, a tabela gerada para armazenar estes indivíduos nas três metodologias é composta pela somatória das perdas ôhmicas [kW], pelo máximo carregamento da rede em p.u., máximo carregamento das subestações em p.u., a máxima queda de tensão em p.u. e o número de chaveamentos.

Em uma primeira investigação das abordagens, observou-se que o problema é de difícil análise por tratar de muitas restrições operacionais. Inicialmente foram simulados 50 experimentos, onde se constatou que nem sempre nestas simulações as abordagens conseguiam atingir uma solução factível. Na Figura 19 é possível visualizar o comportamento das soluções dos AEMOs por meio de um gráfico de eficiência, que verifica o quanto um AEMO produz de soluções factíveis em porcentagem em relação ao número de experimentos simulados. Mediante ao exposto, observa-se que o algoritmo AEMT-SP atinge soluções factíveis em 94% dos experimentos, enquanto que o AEMT alcança em 78% das vezes e o NSGA-II em 36%.

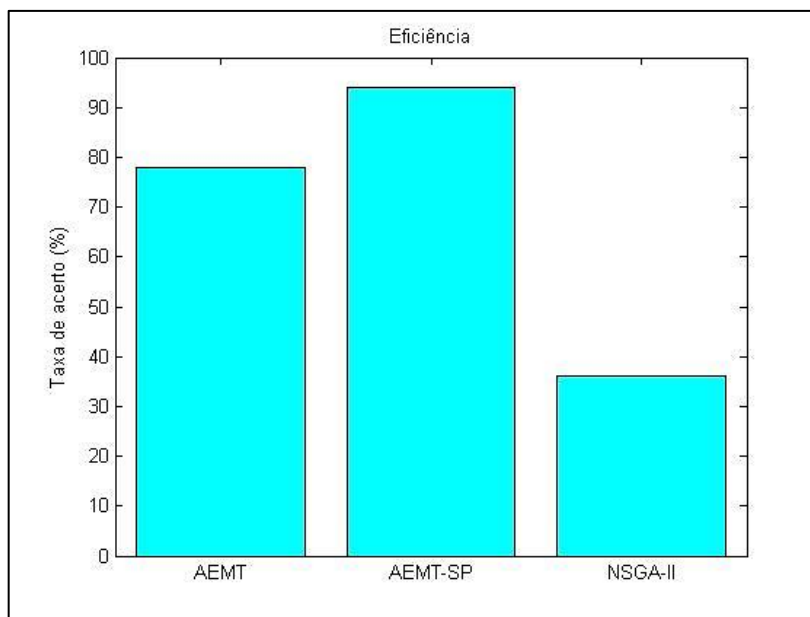


Figura 19 - Eficiência

Fonte: Autoria própria.

6.2. SIMULAÇÕES COM O TESTE DE WILCOXON

Para comparar o desempenho das metodologias AEMT, AEMT-SP e o NSGA-II, em relação ao número de manobras operacionais necessárias para reconfigurar o sistema, realizou-se a equiparidade das metodologias, de forma a verificar se existem diferenças entre os resultados encontrados.

O resultado apresentado na Figura 20 refere-se à distribuição do conjunto de dados, neste caso, o número de manobras operacionais, de forma que, esses valores foram obtidos a partir da execução de 50 simulações realizadas com as três metodologias. É importante mencionar que pelo exposto na seção 6.1 e exibido na Figura 19, que nenhum dos métodos conseguiu 50 conjuntos factíveis para a comparação, assim preencheu-se para todos os métodos os valores faltantes com a média para garantir que não haja nenhum tipo de tendência ao valor mínimo de cada AEMO. Vale ressaltar que, os valores obtidos são provenientes da tabela da função agregação de cada metodologia.

Na sequência é feita a comparação das três metodologias para o teste de Wilcoxon através da representação gráfica por *BoxPlot*. O *BoxPlot* apresenta, em um formato de caixa, o primeiro quartil, o terceiro quartil e a mediana. A haste inferior se estende a partir do limite inferior até o menor valor, e a haste superior se

estende do quartil superior até o maior valor. Os pontos fora das hastes inferior e superior são considerados valores discrepantes também chamados de *outliers*.

A Figura 20 exibe a dispersão dos conjuntos de solução dos algoritmos AEMT, AEMT-SP e do NSGA-II. Após a análise através do *BoxPlot* é possível por meio de uma inspeção visual verificar que a metodologia AEMT-SP possui a menor quantidade de manobras operacionais para a reconfiguração do sistema e também maior distribuição das soluções, ou seja, nesta configuração existe maior dispersão do conjunto de soluções. Em linhas gerais, para a maioria dos experimentos o AEMT-SP obteve o melhor desempenho com foco no menor número de manobras operacionais, isso é possível afirmar, pois, através da análise visual comparativa com os demais AEMOs, observa-se que o pior caso do AEMT-SP que é no *outlier*, ainda é melhor do que o melhor caso do AEMT. Em relação a comparação do AEMT-SP e do NSGA-II nada se pode atestar visualmente. Assim, a fim de garantir um maior grau de confiança nesta análise aplica-se o teste de hipótese.

Mediante a aplicação do teste de Wilcoxon é possível concluir que comparando o AEMT e AEMT-SP com um intervalo de confiança de 95% e com um nível de significância $\alpha = 0,05$ que é maior que o p-valor = $4,34 \cdot 10^{-8}$ encontrado para este caso, indica o que foi possível observar graficamente, ou seja, o algoritmo com melhor desempenho em relação ao número de manobras é o AEMT-SP. Já para a comparação do AEMT-SP e o NSGA-II, observou-se que com um intervalo de confiança de 95% que o p-valor é igual a $5,204 \cdot 10^{-7}$ que é menor que o nível de significância de $\alpha = 0,05$, assim o AEMT-SP também possui melhor desempenho nesta comparação. Por conseguinte, nota-se que de fato a metodologia AEMT-SP possui a menor quantidade de manobras operacionais para a reconfiguração do sistema.

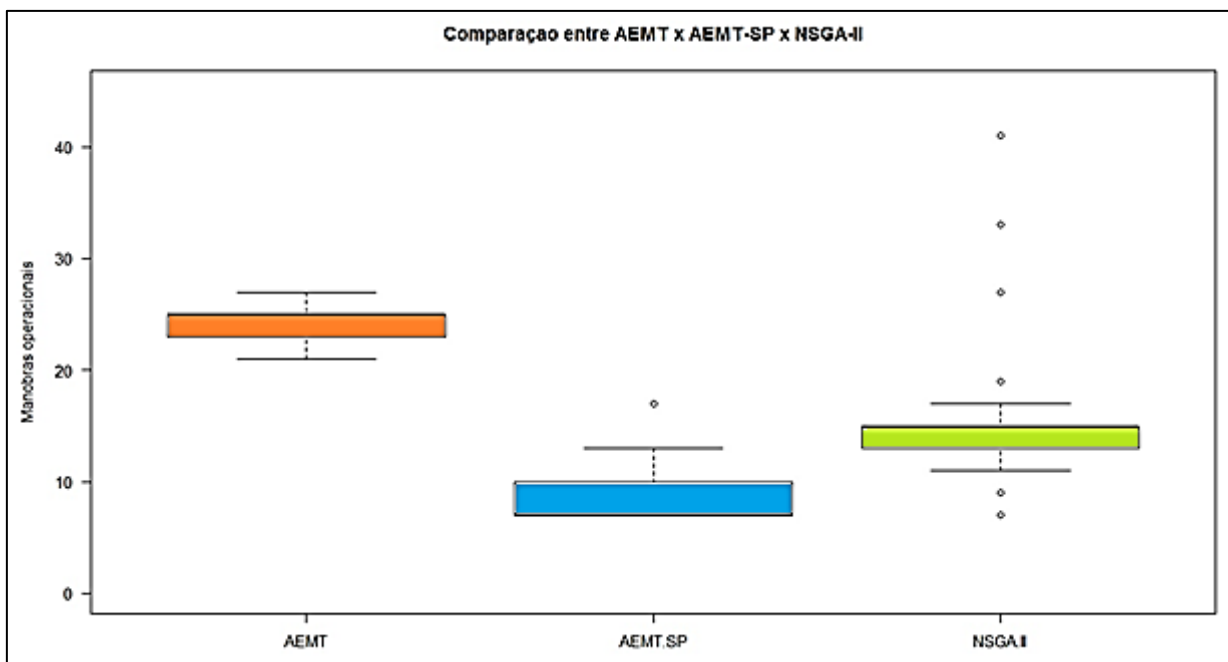


Figura 20 - Comparação entre os AEMOs

Fonte: Autoria própria.

6.3. FRONTEIRA DE PARETO

Nesta seção é apresentada a fronteira de Pareto produzida pelos dados dos algoritmos AEMT, AEMT-SP e do NSGA-II assim, a Figura 21 mostra a fronteira de Pareto para a minimização de dois objetivos, a redução do número de manobras operacionais para a reconfiguração do sistema de distribuição e a função ponderação.

A fronteira de referência é a somatória de todas as fronteiras de todos os métodos, ou seja, se utiliza todas as fronteiras geradas em todos os experimentos pelos três métodos e aplica-se o conceito de não dominância para gerar uma única fronteira.

Nem sempre em otimização multiobjetivo pode-se afirmar através de uma análise visual qual é o melhor AEMO. Neste caso, como pode ser observado na Figura 21, estima-se visualmente que a metodologia AEMT-SP apresenta o melhor conjunto de soluções, porém isso só é possível mensurar porque a figura exhibe o conjunto de soluções para apenas um experimento aleatório assim, nada se pode dizer sobre os outros 49 experimentos, visto que em algum momento os dados podem estar sobrepostos.

Face ao exposto, visualmente não se pode falar qual o AEMO é o melhor, desta forma, para identificar qual metodologia possui o melhor desempenho deve-se aplicar as métricas comparativas multiobjetivo.

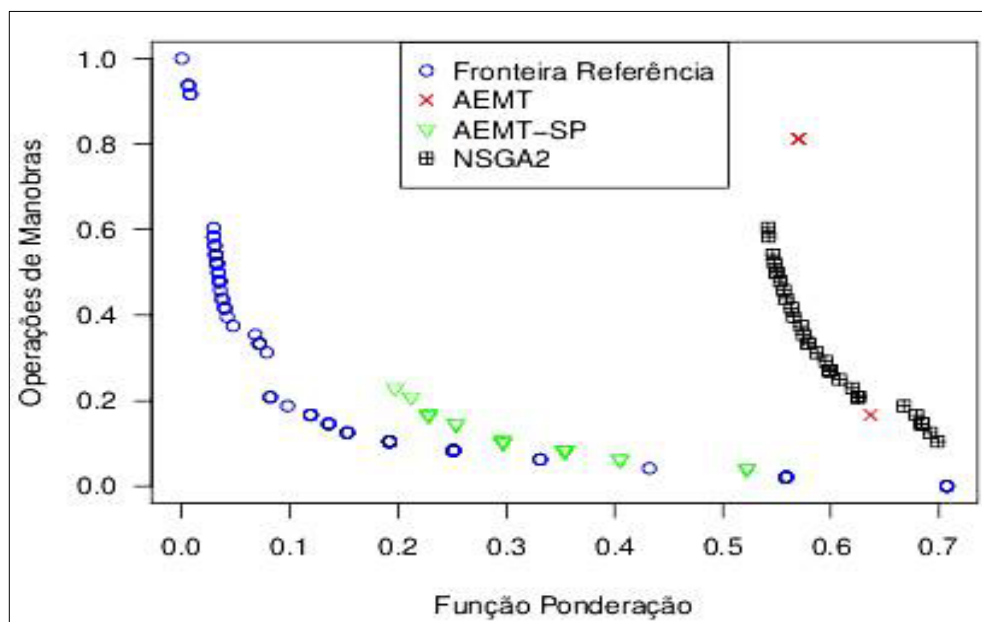


Figura 21 – Fronteira de Pareto comparativa com os algoritmos AEMOs AEMT, AEMT-SP e NSGA-II

Fonte: Autoria própria.

6.4. SIMULAÇÕES COM AS MÉTRICAS COMPARATIVAS MULTIOBJETIVO

As métricas comparativas multiobjetivo serão utilizadas nesta seção para a comparação dos dados encontrados por cada AEMO em relação ao seu desempenho. Para tanto, são consideradas todas as soluções dos 50 experimentos, onde os dados que foram encontrados representam manobras operacionais factíveis ou não para o restabelecimento de energia elétrica.

Os algoritmos AEMT, AEMT-SP e NSGA-II foram equiparados em *BoxPlots*, e a análise dos resultados obtidos será realizada individualmente através de cada métrica empregada.

6.4.1. Gráfico *BoxPlot* para Métrica Hipervolume

A Figura 22 apresenta a comparação dos algoritmos AEMT, AEMT-SP e o NSGA-II em relação à métrica hipervolume com dominância, essa característica do

HV analisa ponto a ponto os conjuntos de soluções, e apresenta as soluções melhor dispostas. É possível observar que o algoritmo AEMT-SP apresentou maior porcentagem de dominância, isso quer dizer que o algoritmo possui soluções que dominam as soluções atingidas pelos demais algoritmos. O AEMT e o AEMT-SP apresentaram baixa dispersão dos resultados, e ainda, demonstraram um comportamento simétrico em torno da mediana. Já o NSGA-II possui uma vasta dispersão dos dados, porém o conjunto de dados que ele domina não é superior ao do AEMT-SP. Em relação a comparação do AEMT-SP e o NSGA-II nota-se que os pontos de máximo, para as duas metodologias, ficam próximos do valor um, indicando que em algum experimento as soluções encontradas são semelhantes, porém em sua maioria o AEMT-SP ainda é melhor.

O algoritmo AEMT-SP possui o melhor desempenho, pois, detém o melhor intervalo de convergência do método que é de 58% a 100%.




Figura 22 - Comparação dos AEMOs em relação ao HV com dominância

Fonte: Autoria própria.

A Figura 23 mostra a equiparidade das três metodologias AEMT, AEMT-SP e NSGA-II para a métrica hipervolume indicadora, que calcula o valor do indicador de qualidade do conjunto de manobras operacionais em cada AEMO, para tanto, isto é feito pareando se as soluções de cada AEMO em relação à matriz de pontos de referência, no nosso caso, a fronteira de Pareto. A fim de comparar a qualidade dos

AEMOs, se observa que o NSGA-II apresenta alta dispersão das soluções, ou seja, a qualidade de sua solução esta afastada da sua mediana, indicando neste caso, baixa qualidade, porém o algoritmo com a pior qualidade é o AEMT, desta forma, considera-se a qualidade da solução nos pontos próximos de 100% ruins. Observa se que, pela proximidade da mediana e pelo baixo valor encontrado na comparação com a matriz de referência, o algoritmo AEMT-SP possui o conjunto de soluções mais eficiente.

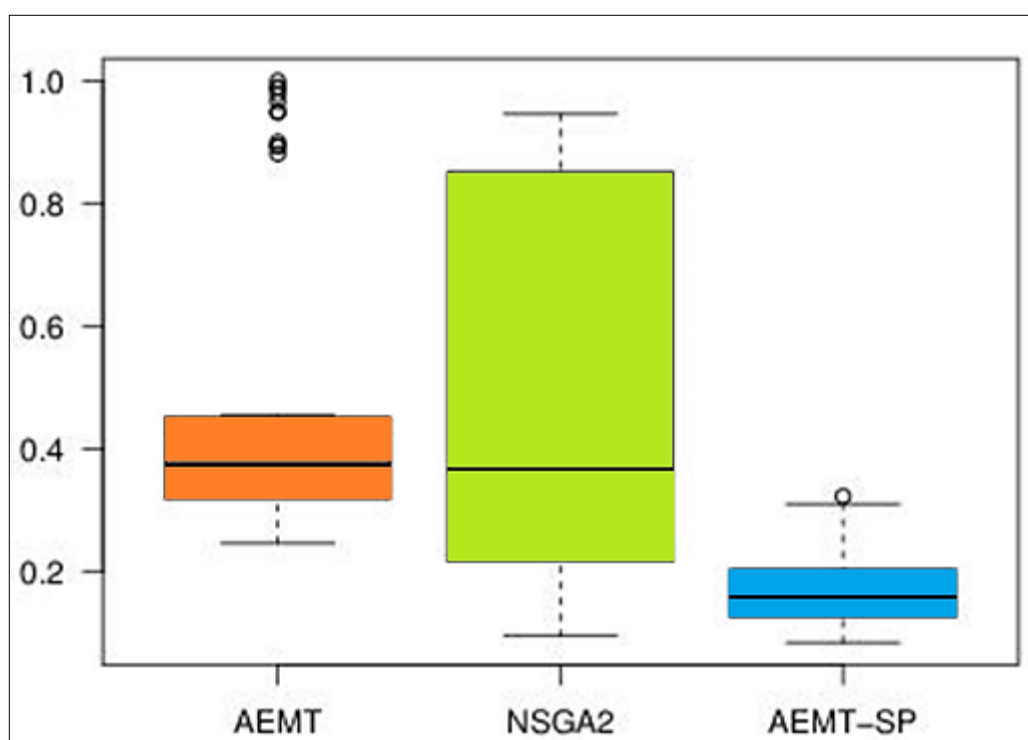


Figura 23 - Comparação dos AEMOs em relação ao HV indicador

Fonte: Autoria própria.

6.4.2. Gráfico *BoxPlot* para Métrica Epsilon

A métrica epsilon é um indicador de qualidade que analisa o conjunto de soluções encontrado por cada algoritmo em relação a um ponto de referência, neste caso, também foi considerada a função ponderação, ou seja, a fronteira de Pareto como o referencial.

A Figura 24 apresenta a comparação das metodologias estudadas em relação à qualidade indicada através da métrica epsilon. A metodologia AEMT-SP mostrou novamente o melhor desempenho do que o algoritmo AEMT e o NSGA-II,

conseguindo gerar soluções não dominadas mais próximas do conjunto de referência. O AEMT-SP ainda apresentou baixa dispersão dos resultados gerados.

O algoritmo AEMT conseguiu obter uma baixa dispersão do conjunto de dados obtidos, já o NSGA-II ficou bem disperso e as soluções geradas ficaram muito distantes do conjunto de referência.




Figura 24 - Comparação dos AEMOs em relação à qualidade obtida pela métrica epsilon
Fonte: Autoria própria.

6.4.3. Gráfico *BoxPlot* para Métrica R2 e R3

As duas metodologias abordadas são exibidas nas Figuras 25 e 26, onde elas representam graficamente a comparação da qualidade dos AEMOs para as métricas R2 e R3, respectivamente.

As duas abordagens são muito parecidas, diferenciando-se apenas na forma como é calculada a qualidade de cada metodologia comparativa, análise discutida na seção 5.4.3, desta forma, observa-se que as soluções gráficas obtidas são muito próximas. Mediante esta análise, é permitido dizer que nas duas métricas o AEMT-SP apresenta o melhor desempenho, pois possui menor dispersão e as suas soluções estão próximas do conjunto de referência, desta forma, conclui-se que esta metodologia está adequadamente dimensionada em relação aos seus objetivos nas duas métricas. O segundo algoritmo com menor conjunto de dispersão é o AEMT,

porém ele possui pontos discrepantes que prejudicam a qualidade da solução. Em seguida, é analisado o algoritmo NSGA-II que tem alta dispersão, com grande diferença entre os valores de máximo e mínimo, considera-se essa metodologia como a pior.




Figura 25- Comparação dos AEMOs em relação à qualidade obtida pela métrica R2
Fonte: Autoria própria.

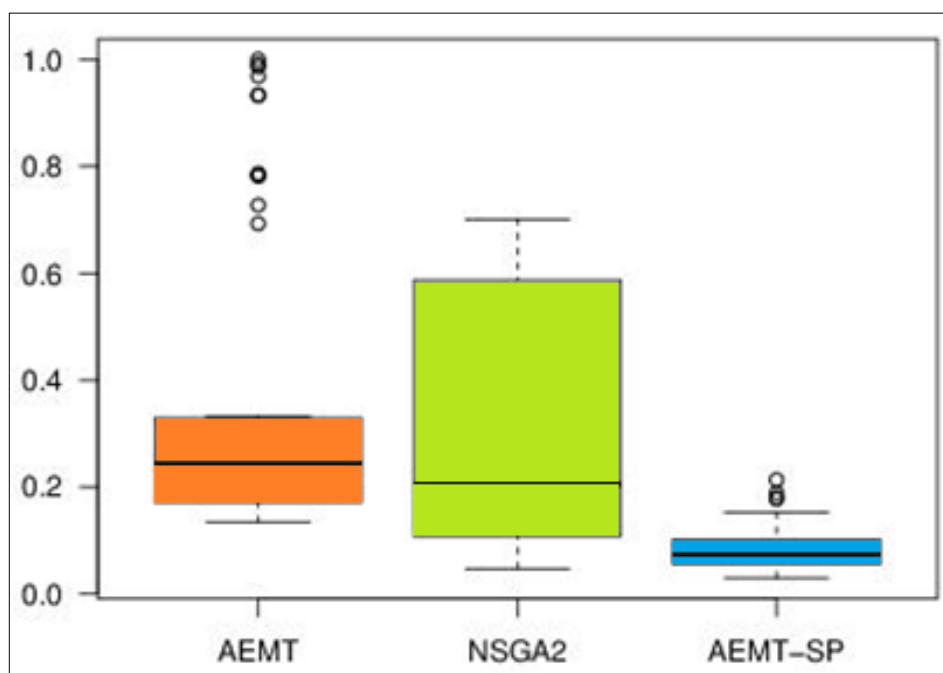


Figura 26 - Comparação dos AEMOs em relação à qualidade obtida pela métrica R3
Fonte: Autoria própria.

6.5. SIMULAÇÃO DA SOLUÇÃO DAS MÉTRICAS COMPARATIVAS MULTIOBJETIVO PELO TESTE DE WILCOXON

Nesta seção se fez uso dos conjuntos de soluções encontrados na seção 6.4. para uma nova análise. As saídas das métricas, que são os dados referidos a qualidade das soluções apresentadas pelos AEMOs, serão utilizadas para a aplicação do teste de Wilcoxon, de forma que seja possível observar a variabilidade das soluções já obtidas.

A Figura 27 mostra a comparação entre os três AEMOs para as soluções obtidas pela métrica hipervolume de dominância, a resposta encontrada a partir do teste de Wilcoxon indica que com um intervalo de confiança de 95% é possível afirmar que o algoritmo AEMT-SP é dominante sobre as outras metodologias comparadas, pois cobre uma região maior de soluções.

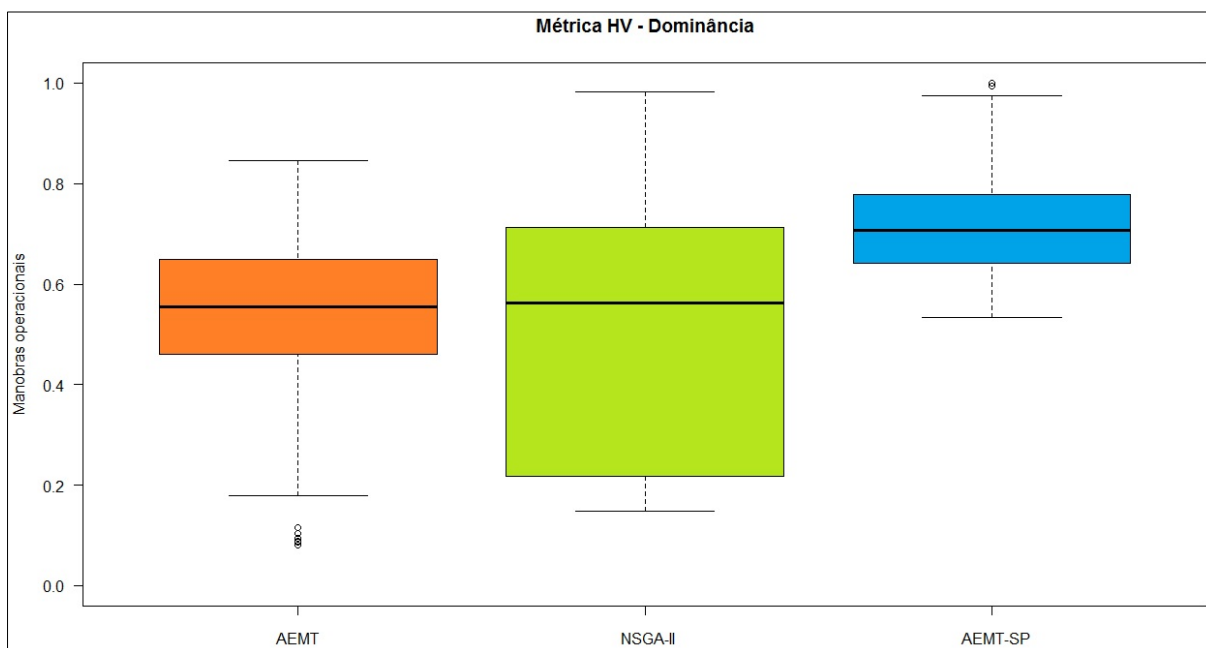


Figura 27 - Comparação da solução da métrica HV com dominância para os AEMOs

Fonte: Autoria própria.

O teste de Wilcoxon aplicado para as soluções obtidas através da métrica hipervolume indicadora mostrada na Figura 28, deixou evidente que o algoritmo AEMT possui o conjunto com a pior qualidade para este caso. Nesta análise é possível constatar a inferioridade da metodologia, pois o teste aplicado indicou com

um intervalo de confiança de 95% que o exposto na subseção 6.4.1 é verdade. Ainda, isso pode ser confirmado, pois o p-valor obtido é igual a $2,721 \cdot 10^{-8}$ que é menor que o nível de significância estipulado por $\alpha=0,05$.

Para as métricas HV indicadora, epsilon, R2 e R3 quanto mais próximo de zero estiver o conjunto de soluções de um AEMO mais aproximado da fronteira de Pareto estará esta solução, ou seja, indica quanto ela irá dominar a próxima solução.

A equiparidade das soluções realizada por meio da métrica epsilon exibida na Figura 29 possibilitou concluir com um intervalo de confiança de 95%, que de fato, o algoritmo NSGA-II é o que possui o melhor espalhamento de suas soluções, porém é o algoritmo AEMT-SP que possui o melhor desempenho. Como o nível de significância estipulado por $\alpha=0,05$ é superior ao p-valor $1,297 \cdot 10^{-7}$ encontrado, o conjunto de soluções obtidos não deve ser considerado igual.

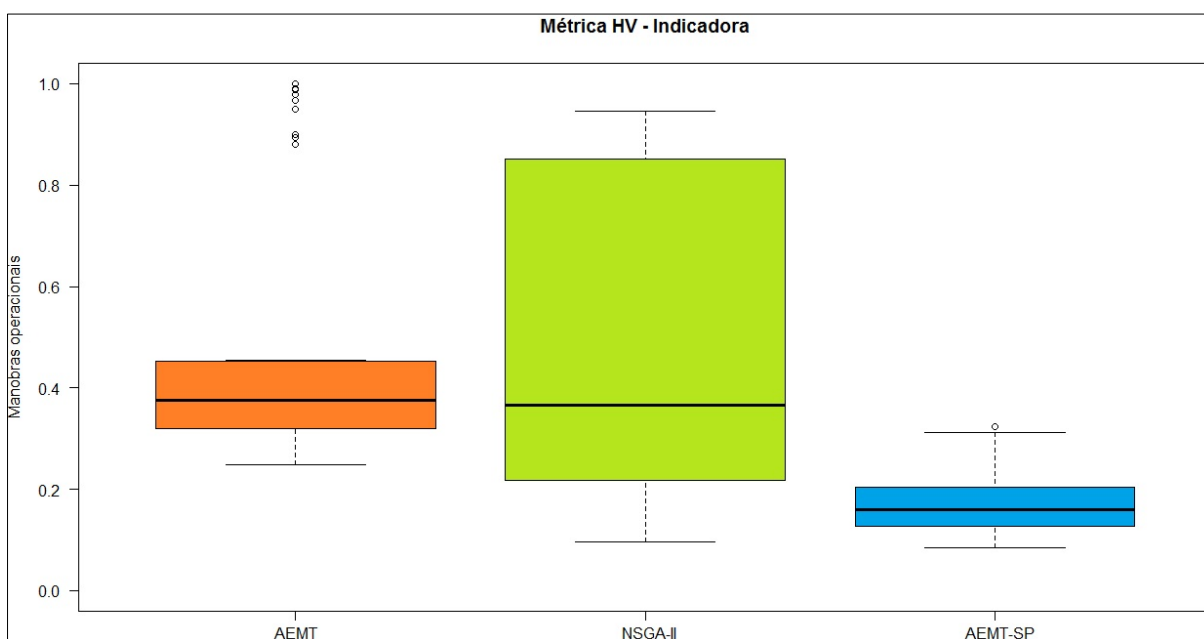


Figura 28 - Comparação da solução da métrica HV indicadora para os AEMOs

Fonte: Autoria própria.

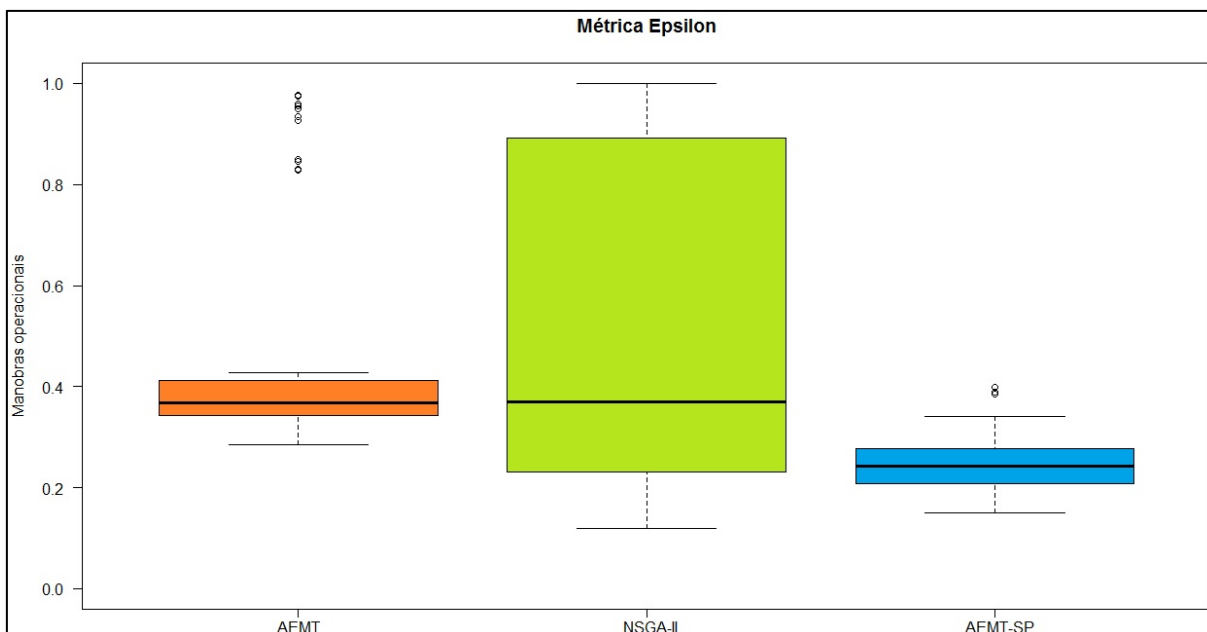


Figura 29 - Comparação da solução da métrica epsilon para os AEMOs

Fonte: Autoria própria.

As Figuras 30 e 31 mostram a comparação das metodologias utilizadas, em relação ao conjunto de soluções encontrados para as métricas R2 e R3. Face ao exposto na seção 6.4.3., o conjunto de saída das soluções para as duas métricas R2 e R3 com um intervalo de confiança de 95% apresentam p-valor igual $4,34 \cdot 10^{-8}$ e p-valor $5,44 \cdot 10^{-8}$ respectivamente, isso afirma que os conjuntos de soluções não são iguais, e que a metodologia AEMT, seguida de NSGA-II possuem os piores desempenhos, visto que, o nível de significância estipulado por $\alpha = 0,05$ é superior ao p-valor.

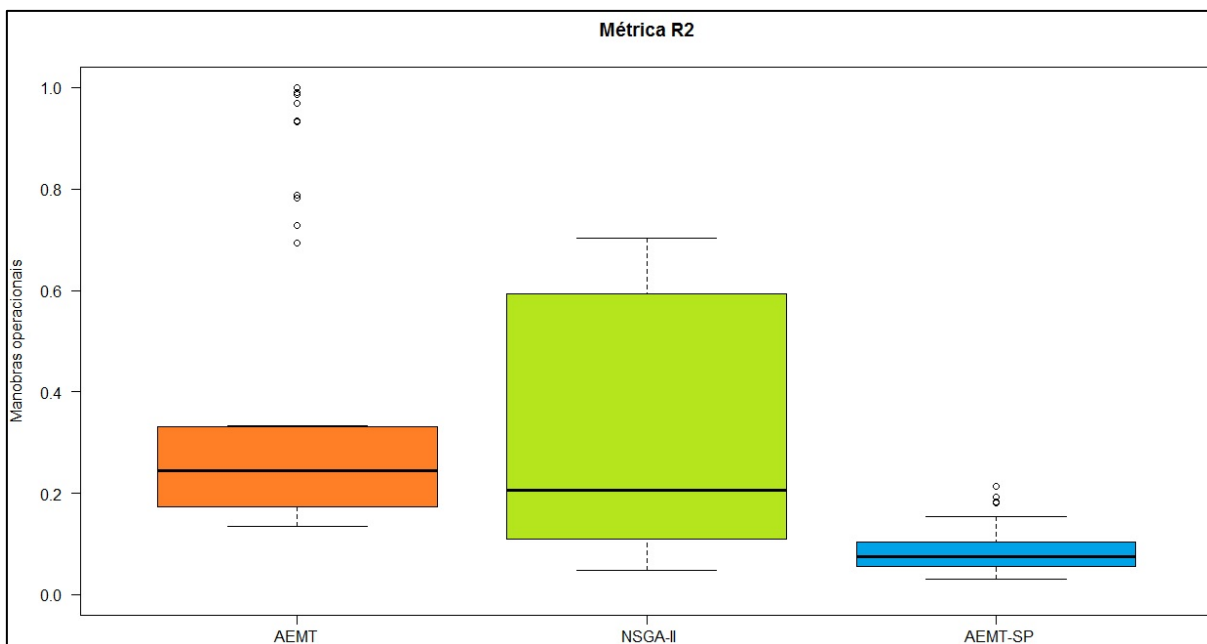


Figura 30 - Comparação da solução da métrica R2 para os AEMOs

Fonte: Autoria própria.

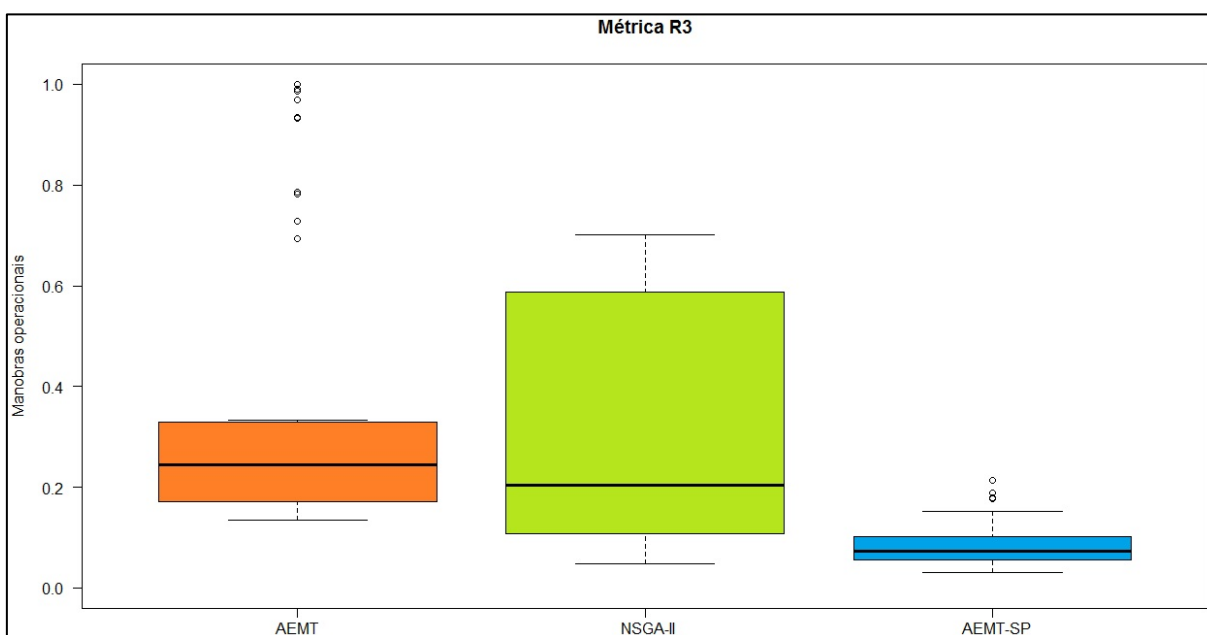


Figura 31 - Comparação da solução da métrica R3 para os AEMOs

Fonte: Autoria própria.

6.6. SIMULAÇÃO DA EAF

A função de resultado empírico (EAF) descreve a distribuição probabilística dos resultados obtidos por um algoritmo no espaço de objetivos e demonstra

visualmente a diferença entre os conjuntos de dados. As Figuras 32, 33 e 34 mostram áreas de cobertura, onde cada área descreve um comportamento em relação aos objetivos impostos. Estes gráficos serão utilizados para explorar o desempenho dos algoritmos em problemas de otimização multiobjetivo. Para tanto, os objetivos estão organizados em 1 e 2, e se referem a redução do número de manobras operacionais e a função ponderação, respectivamente.

As diferenças entre os EAFs de dois algoritmos podem ser calculadas computando primeiro a união dos resultados de ambos os algoritmos. Em seguida, para cada ponto no espaço é necessário calcular o valor da EAF do primeiro algoritmo nessa altura menos o valor da EAF do segundo algoritmo. Finalmente, as diferenças positivas e negativas são traçadas separadamente, e as magnitudes das diferenças entre os EAFs são codificadas utilizando diferentes tons de cinza, desta maneira, quanto mais escuro o ponto, maior é a diferença.

Nas Figuras 32, 33 e 34 os algoritmos AEMT, AEMT-SP e o NSGA-II são comparados entre si. As figuras exibem três linhas distintas, estas linhas são referências, onde a linha na cor cinza claro é considerada a pior solução, a linha tracejada na cor preta é a mediana e a linha contínua na cor preta é considerada como a melhor solução.

A Figura 32 mostra a comparação entre o algoritmo AEMT e o AEMT-SP, nesta análise é realizado a comparação dos conjuntos de manobras operacionais do sistema em relação a sua superfície de abrangência, assim nota-se que o conjunto de solução do AEMT-SP é melhor que o de AEMT, pois a tonalidade cinza apresentada esta próximo da melhor solução. Desta forma, pelo principio de Pareto otimização, o qual a função EAF utiliza, o conjunto de soluções de AEMT-SP domina o conjunto de soluções de AEMT. Ainda, por meio da Figura 32 é possível dizer que há falta de diversidade no AEMT, isso ocorre porque tanto nos extremos como onde ocorre a intersecção entre os eixos existem indivíduos, já o AEMT-SP está bem adequado.

A Figura 33 representa a equiparidade dos AEMOs AEMT e NSGA-II, aqui fica evidente que as soluções de NSGA-II estão mais próximas da melhor solução.

São confrontados na Figura 34 os conjuntos de dados de AEMT-SP e NSGA-II. Nessa comparação percebe-se que os dois algoritmos são similares e a qualidade da distribuição deles esta boa, contudo se as soluções forem mapeadas tem-se para a metodologia AEMT-SP um achatamento vertical, isso indica que ele é

mais dominante do que NSGA-II. Assim, é possível dizer para este caso que a diversidade das duas metodologias esta boa, porém a convergência do AEMT-SP é melhor do que a do NSGA-II.




Figura 32 - EAF comparativo dos algoritmos AEMT x AEMT-SP

Fonte: Autoria própria.

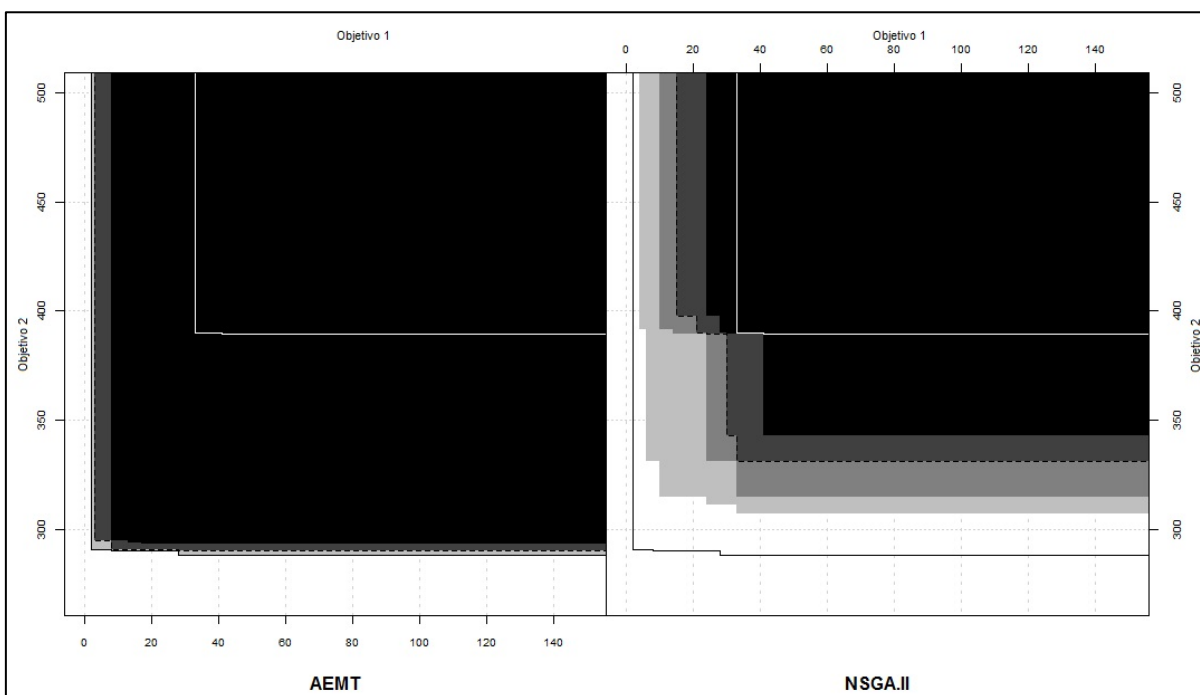


Figura 33 - EAF comparativo dos algoritmos AEMT x NSGA-II

Fonte: Autoria própria.




Figura 34 - EAF comparativo dos algoritmos AEMT-SP x NSGA-II

Fonte: Autoria própria.

6.7. RANKING COM RESULTADO COMPARATIVO ENTRE OS AEMOS

A Tabela 1 sintetiza os resultados das métricas comparativas multiobjetivo em um ranking com as melhores abordagens. Para a melhor reconfiguração, espera-se que o número de manobras operacionais utilizado seja sempre a menor quantidade possível, e para que isso aconteça, o AEMO que dominar os demais conjuntos de soluções será o que está mais próximo da fronteira de Pareto indicando que ele representa a melhor solução. Como pode ser observado na Tabela 1, a metodologia AEMT não consegue alcançar bons resultados, enquanto que as metodologias NSGA-II e a AEMT-SP obtêm os melhores conjuntos de manobras para a reconfiguração do sistema de distribuição. Porém, é a metodologia AEMT-SP que detém em um menor intervalo o conjunto de manobras operacionais com a melhor qualidade e confiabilidade, desta maneira é justificável afirmar que o AEMO AEMT-SP é a melhor metodologia para o problema de restabelecimento de energia elétrica em sistemas de distribuição.

A Tabela 1 apresenta a classificação dos algoritmos em ordem de desempenho para o restabelecimento de energia elétrica para seus consumidores.

Tabela 1 – Ranking de desempenho dos algoritmos

ALGORITMO	HV DOMINÂNCIA	HV INDICADORA	EPSILON	R2	R3
AEMT	1	1	1	0	0
NSGA-II	7	7	14	7	7
AEMT-SP	42	42	35	43	43

Fonte: Autoria própria.

Na primeira análise realizada por meio da métrica HV dominância observou-se que o AEMT-SP em 42 simulações realizadas obteve o melhor desempenho. Em uma comparação entre os AEMOs AEMT e NSGA-II, notou-se que o AEMT dominava as soluções de NSGA-II em apenas 13 simulações, ou seja, a qualidade do NSGA-II é melhor.

A métrica HV indicadora mostrou que dentre os 50 experimentos realizados em 42 o AEMT-SP dominou as demais soluções indicando que é o melhor AEMO.

Para a métrica epsilon o algoritmo com péssima qualidade e desempenho nas simulações é o AEMT. Nota-se por meio de comparação que o AEMT-SP foi pior que o NSGA-II em 14 simulações, porém em sua totalidade ele dominou mais vezes o conjunto de soluções, indicando que apresenta melhor qualidade e desempenho.

Nas métricas R2 e R3 observou-se um comportamento similar, onde o AEMO AEMT também apresentou o pior desempenho, ou seja, essas métricas indicaram que o AEMT tem a pior qualidade e o AEMT-SP a melhor.

7. CONCLUSÕES E TRABALHOS FUTUROS

7.1. CONCLUSÕES

Este capítulo sintetiza os principais resultados obtidos e também aborda perspectivas futuras de pesquisa relativas a este trabalho.

O restabelecimento de energia elétrica para SDRs reais normalmente envolve a reconfiguração da rede de distribuição de energia elétrica, este problema possui múltiplos objetivos e estes geralmente são conflitantes, além de possuir restrições operacionais que não podem ser violadas de forma alguma. Mediante a esta problemática, cada vez mais são propostos AEMOs com o intuito de se obter metodologias que sejam mais eficientes para o problema de reconfiguração de redes de energia elétrica. Porém, a maioria das metodologias encontradas na literatura não tem uma análise de qualidade das soluções multiobjetivo, isto acaba dificultando a precisão da escolha da solução pelo operador do sistema elétrico. Neste sentido, este trabalho explorou com maior ênfase técnicas que possibilitam afirmar com segurança qual abordagem de AEMO possui o conjunto de soluções com melhor desempenho e qualidade para o problema de restabelecimento de energia elétrica em sistemas de distribuição.

É importante destacar que este trabalho utilizou como base as metodologias AEMT, AEMT-SP e o NSGA-II, que são consideradas na literatura como sendo as melhores abordagens para a reconfiguração do sistema de distribuição. Para a análise do desempenho destes AEMOs, utilizou-se o conjunto de soluções obtido por cada algoritmo evolutivo aplicado ao sistema de distribuição da cidade de São Carlos/SP. Após a validação dos algoritmos para o sistema de distribuição estudado, foram realizadas comparações entre os algoritmos utilizando primeiramente um teste de Wilcoxon e na sequência aplicaram-se métricas comparativas multiobjetivo, bem como, as métricas Hipervolume, Epsilon, R2 e R3. Os resultados obtidos das comparações dos AEMOs se encontram no capítulo 6.

As soluções obtidas nas simulações com o AEMT, AEMT-SP e o NSGA-II para o sistema proposto, mostram que a metodologia AEMT-SP e a NSGA-II são capazes de obter conjuntos de manobras operacionais mais eficientes, e que exploram o espaço de soluções factíveis, desta forma, pode se dizer que estes métodos possuem conjuntos de soluções de alta qualidade. Contudo, observou-se

através das seções 6.4 e 6.5, que em relação à qualidade das soluções, o algoritmo AEMT-SP tem a melhor capacidade e agilidade em reconfigurar o sistema, necessitando de poucas manobras operacionais, essa característica ficou evidente na seção 6.2, onde se aplicou o *Boxplot* do teste de Wilcoxon.

O algoritmo NSGA-II foi considerado o segundo melhor em qualidade, porém existem pontos, ou seja, quantidades de manobras operacionais que o método aceita que estão no limite da estabilidade do sistema.

O AEMO AEMT é conceituado nesta abordagem como o pior conjunto de manobras operacionais, pois utiliza uma quantidade elevada de chaveamento para a reconfiguração da rede de distribuição, isso pode ser interpretado em relação ao tempo que demora para atingir o restabelecimento de energia, o que acarreta na falta de energia elétrica para os centros consumidores por um intervalo maior de tempo.

Considerando a qualidade das soluções e o desempenho das metodologias que foram abordadas nas seções 6.6 e 6.7, foi comprovado que a metodologia AEMT-SP possui de fato o melhor desempenho, seguido do algoritmo NSGA-II e do AEMT.

Acredita-se que a utilização da estrutura de dados RNP como base de desenvolvimento para as metodologias AEMT-SP, NSGA-II e AEMT contribuiu para o desempenho das metodologias, uma vez que geram sempre configurações factíveis e avaliações mais rápidas das configurações que vão sendo geradas.

Por fim, é indicado que utilize a metodologia AEMT-SP, a fim de que o operador do sistema de distribuição encontre sempre manobras operacionais de qualidade e de alto desempenho.

7.2. TRABALHOS FUTUROS

Para o desenvolvimento de trabalhos futuros listam-se a seguir algumas perspectivas:

- Desenvolver outras abordagens evolutivas para o problema de restabelecimento de energia. Algumas possíveis abordagens seriam a utilização da otimização por colônia de formigas e o método de otimização por enxame de partículas para valores discretos;

- Analisar um estudo comparativo com outras abordagens de AEMOs recentes da literatura como os AEMOs baseados em decomposição e o NSGA3, a fim de possibilitar a inclusão de novas características na abordagem AEMT-SP;
- Considerar características práticas para o restabelecimento de energia elétrica, além das manobras operacionais, como chaves automáticas, a sequência dos chaveamentos e os consumidores prioritários.

REFERÊNCIAS

- BARAN, M.; WU, F. Network reconfiguration in distribution systems for loss reduction and load balancing. *Power delivery, IEEE Transactions on*. v. 4, n. 2, p. 1401-1407. 1989.
- BATISTA, Lucas de S. **Investigação de Novas Abordagens para Otimização Multiobjetivo em Algoritmos Evolutivos**. 2011. 182f. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte. 2011.
- BENAYOUN, R.; MONTGOLFIER, J.; TERGNY, J.; LARITCHEV, O. **Linear programming with multiple objective functions: step method (stern)**, *Mathematical Programming*. v.1., p. 366-375. 1971.
- BIRATTARI, Mauro; STUTZLE, Thomas; PAQUETE, Luis; VARRENTRAPP, KLAUS. A racing algorithm for configuring metaheuristics. *Proceedings of the Genetic and Evolutionary Computation Conference*. p.11-18. 2002.
- BONA, Anderson A. **Algoritmo de otimização combinatorial: Uma proposta híbrida utilizando os algoritmos *simulated annealing* e genético em ambiente multiprocessado**. 2005. 65f. Tese (Mestrado em Ciências da Computação) – Universidade Federal de Santa Catarina, Florianópolis, 2005.
- BOULAXIS, N. G.; PAPADOULOS, M. P. Optimal feeder routing in distribution system planning using dynamics programming technique and GIS facilities. *IEEE Transaction on Power Delivery*. v.17, p.242-247. 2002.
- BRANDINI, Antonio C. **Análise crítica de algoritmos de fluxo de carga usados em sistemas de distribuição radial**. 2000. 71f. Tese (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista, Ilha Solteira, 2000.
- BUSSAB, Wilton de O. **Estatística básica**. São Paulo: Saraiva. 8º ed. 2013.
- CARRANO, Eduardo G.; WANNER, Elizabeth. F.; TAKAHASHI, Ricardo H. C. A multicriteria statistical based comparison methodology for evaluating evolutionary algorithms. *IEEE Transactions on Evolutionary Computation*. v.15, p. 848 – 870. 2010.
- CZYIAK, P.; JASZKIEWICZ, Andrzej. Pareto simulated annealing - a metaheuristic technique for multiple-objective combinatorial optimization. *Journal of Multi-Criteria Decision Analysis*. p. 34-47. 1998.
- DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. **A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II**. p. 849-858. 2000.
- DEB, K. **Multi-objective optimization using evolutionary algorithms**. New York: Wiley. 2001.

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*. v. 6, p.182-197. 2002.

DELBEM, Alexandre C.B.; CARVALHO, André C.P.L.F.; POLICASTRO, C. A.; PINTO, A. K. O.; HONDA, K.; GARCIA, A. C. **Node-Depth Encoding for Evolutionary Algorithms Applied to Network Design**. p. 678-687. 2004.

DELBEM, Alexandre C.B.; CARVALHO, André C.P.L.F.; BRETAS, Newton G. Main chain representation for evolutionary algorithms applied to distribution system reconfiguration. *IEEE Transactions on Power Systems*. v. 20, p. 425-436. 2005.

DIAZ-DORADO, E.; PIDRE, J. C. Optimal planning of unbalanced network using dynamics programming optimization. *IEEE Transactions on Power Delivery*, v. 19, p.2077-2085. 2004.

DUTTA, P.; DUTTA MAJUMDER, D. Performance comparison of two evolutionary schemes. *Proc. Int. Conf. Pattern Recognit.* p. 659-663. 1996.

EL-KHATTAM, W.; HEGAZY, Y.G.; SALAMA, M. M. A. Na integrated distributed generation optimization model for distribution system planning. *IEEE Transaction on Power System*. v. 20, p. 1158-1165. 2005.

FARRAG, M. A.; EL-METWALLY, M. M.; EL-BAGES, M. S. A new model for distribution system planning. *International Journal of Electrical Power & Energy Systems*. v. 21, p.523-531. 1999.

FERREIRA, Armando M. **Método estatístico e delineamento experimental: Testes não paramétricos**. 2004. Castelo Branco, Portugal. Disponível em:<http://docentes.esa.ipcb.pt/mede/apontamentos/testes_ao_parametricos.pdf>. Acesso em: 16 set. 2014.

FERREIRA, Flávio A. L. **Metodologia para Reconfiguração de Redes de Distribuição Trifásicas Assimétricas e Não Balanceadas com Geração Distribuída**. 2010. 144f. Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2010.

GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning**. Boston, MA: Addison-Wesley Longman Publishing Co.Inc. 1989.

GRAINGER, John J.; STEVENSON Jr., William D. **Power system analysis**. 4. ed. São Paulo: McGraw – Hill, Inc. 1994.

HANSEN, Michael P.; JASZKIEWICZ, Andrzej. Evaluating the quality of approximations of the non-dominated set. *IMM Technical report, IMM-REP-1998-7*. Institute of Mathematical Modeling, Technical University of Denmark. p. 12-14. 1998.

IBÁÑEZ, Manuel L.; PAQUETE Luís; STUTZLE Thomas. Exploratory Analysis of Stochastic Local Search Algorithms in Biobjective Optimization. In T. Bartz Beielstein,

M. Chiarandini, L. Paquete, and M. Preuss, editors, ***Experimental Methods for the Analysis of Optimization Algorithms***. p. 209–222. 2010.

KNOWLES, Joshua; CORNE, David. The pareto archived evolution strategy: A new baseline algorithm for pareto multiobjective optimization. ***Congress Evolutionary Computation, IEEE Transactions on***. p.98-105. 1999.

KNOWLES, Joshua; CORNE, David. On Metrics for Comparing Nondominated Sets. ***Evolutionary Computation, IEEE Transactions on***. v.1, n. 1, p.1-6, 2002.

LUREG, Lancaster University Renewable Energy Group. **Optimisation of collector form and response**. Disponível em: <http://www.engineering.lancs.ac.uk/lureg/group_research/wave_energy_research/Collector_Shape_Design.php>. Acesso 31 ago. 2014.

MANSOUR, Moussa R. **Algoritmo para a obtenção de planos de restabelecimento para sistemas de distribuição de grande porte**. 2009. 147f. Tese (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2009.

MENDOZA, F.; BERNAL-AGUSTIN, J. L.; DOMINGUES-NAVARRO, J. A. NSGA and SPEA applied to multiobjective design of power distribution systems. ***IEEE Transactions on Power systems***. v. 21, p.1983-1945. 2006.

MITCHELL, Melanie. ***An Introduction to Genetic Algorithms***. MIT Press, 1. ed. 1998.

MONTGOMERY, Douglas C.; RUNGER, George C. **Estatística aplicada e probabilidade para engenheiros**. Rio de Janeiro: LTC, 2002.

MONTICELLI, A. J. Fluxo de Carga em Redes de Energia Elétrica. São Paulo: Edgard Blucher, 1983.

MORELATO, A.; MONTICELLI, A. Heuristic search approach to distribution system restoration. ***Power Delivery, IEEE Transactions on***. v.4, n. 4, p.2235-2241.1989.

NÓBREGA, Sophia. **Desenvolvimento de Cronogramas de Projetos de Software Utilizando Otimização Heurística**. 2013. 100f. Tese (Mestrado em Modelagem Matemática e Computacional) – Centro Federal de Educação Tecnológica de Minas Gerais, 2013.

PortalAction. Distribuição normal. **Revista Produção On-Line**. Disponível em: <<http://www.portalaction.com.br/content/62-distribui%C3%A7%C3%A3o-normal>>. Acesso em: 15 set. 2014.

REGO, Marcelo F. **Algoritmos Multiobjetivos para o Problema de Sequenciamento de Tarefas em Uma Máquina com Tempo de Preparação Dependente da Sequência e da Família**. 2013. 76f. Tese (Mestrado em Engenharia da Computação) – Universidade Federal de Ouro Preto. 2013.

RSTUDIO. **R for Statistical Computing**. R versão 3.2.0 Copyright (C). Boston, MA. 2015.

SANCHES, Danilo S; MANSOUR, Moussa R.; LONDON, J.; DELBEM, Alexandre; Santos, A. Integrating relevant aspects of moeas to solve loss reduction problem in large-scale distribution systems. *PowerTech, IEEE Trondheim*. p. 1 – 6. 2011.

SANCHES, Danilo S. **Algoritmos Evolutivos Multi-Objetivo para Reconfiguração de Redes em Sistemas de Distribuição de Energia Elétrica**. 2013. 125f. Tese (Doutorado em Ciências) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

SANCHES, Danilo S.; JR. MAZUCATO, Sergio C.; CASTOLDI, Marcelo F.; DELBEM, Alexandre C. B.; LONDON, J. B. A. **Algoritmo evolutivo multi-objetivo baseado em tabelas de subpopulações de soluções não dominadas e força de Pareto para tratar do problema de restabelecimento de energia em sistemas de distribuição**. p. 1 – 6, 2013.

SANTOS, Augusto C. dos. **Restabelecimento de energia considerando todas as barras e chaves de um sistema de distribuição real**. 2004. 110f. Tese (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.

SANTOS, Augusto C. dos. **Algoritmo Evolutivo Computacionalmente Eficiente para Reconfiguração de Sistemas de Distribuição**. 2009. 166f. Tese (Doutorado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2009.

SANTOS, Augusto; DELBEM, Alexandre; LONDON, João B.; BRETAS, Newton G.. Node-Depth Encoding and Multiobjective Evolutionary Algorithm Applied to Large-Scale Distribution System Reconfiguration. *Power System, IEEE Transactions on*. v. 25, n. 3, p. 1254-1265. 2010.

SHILANE, D.; MARTIKAINEN, J.; DUDOIT, S.; OVASKA, S. A general framework for statistical performance comparison of evolutionary computation algorithms. *Proc. Artif. Intell. Applicat. Conf*. p. 7-12. 2006.

SHIRMOHAMMADI, D.; HONG, H.; SEMLYEN, A.; LUO, G. A compensation-based power flow method weakly meshe distribution and transmission networks. *Power Systems, IEEE transactions on*. v. 3, n. 2, p. 753-762. 1988.

TAKAHASHI, Ricardo H. C.; VASCONCELOS, J. A.; RAMIREZ, J. A; KRAHENBUHL, L. A multiobjective methodology for evaluating genetic operators. *IEEE Trans. Magn*. v. 39, n. 3, p. 1321–1324. 2003.

VAN VELDHUIZEN, David A.; LAMONT, Gary B.. Multiobjective evolutionary algorithms: Analyzing the state-of-the-art. *Evolutionary Computation*. v. 8, p. 125-147. 2000.

ZITZLER, Eckart; THIELE, Lothar. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach. ***IEEE Transactions on Evolutionary Computation***. v. 3, n. 4, p. 257–271, 1999.

ZITZLER, Eckart; LAUMANNNS, M.; THIELE, Lothar. SPEA2: Improving the strength Pareto evolutionary algorithm. ***Tech Report***. 2001.

ZITZLER, Eckart; THIELE, Lothar; LAUMANNNS, M.; FONSECA, C. M.; FONSECA, V. G. Performance assessment of multiobjective optimizers: An analysis and review. ***IEEE Transactions on Evolutionary Computation***. v. 7, n. 2, p. 117-132. 2003.

ZITZLER, Eckart; FONSECA, C. M.; KNOWLES, J. D.; THIELE, Lothar. A tutorial on the performance assessment of stochastic multiobjective optimizers. ***Third International Conference on Evolutionary Multi-Criterion Optimization***. v. 216. 2005.