

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

RECONFIGURAÇÃO E ALOCAÇÃO DE MEDIDORES EM REDES DE DISTRIBUIÇÃO

ANTONIO ADOLPHO MARTINS RAPOSO

São Luís – MA, Brasil

2020

ANTONIO ADOLPHO MARTINS RAPOSO

**RECONFIGURAÇÃO E ALOCAÇÃO DE MEDIDORES EM REDES DE
DISTRIBUIÇÃO**

Tese submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão como parte dos requisitos para obtenção do título de doutor em Engenharia Elétrica.

Orientadores: Prof. Anselmo Barbosa Rodrigues, D. Sc.

Prof^ª. Maria da Guia da Silva, Ph. D.

São Luís – MA, Brasil

2020

Martins Raposo, Antonio Adolpho.

Reconfiguração e alocação de medidores em redes de distribuição / Antonio Adolpho Martins Raposo. - 2020.

165 p.

Impresso por computador (fotocópia).

Orientador: Anselmo Barbosa Rodrigues.

Coorientadora: Maria da Guia da Silva.

Tese (Doutorado) - Programa de Pós-Graduação em Engenharia de Eletricidade/CCET, Universidade Federal do Maranhão, São Luís, 2020.

1. Estimção de estado. 2. Redes de distribuição. 3. Otimização multiobjetivo. 4. Alocação de medidores. 5. Algoritmo Genético de Chaves Aleatórias Viciadas. 6. Teoria Pareto. I. Barbosa Rodrigues, Anselmo. II. Da Silva, Maria da Guia. III. Título.

**RECONFIGURAÇÃO E ALOCAÇÃO DE MEDIDORES EM REDES DE
DISTRIBUIÇÃO**

ANTONIO ADOLPHO MARTINS RAPOSO

Tese _____ em ____ de _____ de 2020.

BANCA EXAMINADORA

Prof. Anselmo Barbosa Rodrigues, D. Sc.

(Orientador – UFMA)

Prof. Maria da Guia da Silva, Ph. D.

(Co-Orientadora – UFMA)

Prof. Madson Cortes de Almeida, D. Sc.

(Examinador – UNICAMP)

Prof. Ubiratan Holanda Bezerra, D. Sc.

(Examinador – UFPA)

Prof. Denisson Queiroz Oliveira, D. Sc.

(Examinador – UFMA)

Prof. José Eduardo Onoda Pessanha, D. Sc.

(Examinador – UFMA)

“Nunca deixe ninguém te dizer que não pode fazer alguma coisa. Se você tem um sonho tem que correr atrás dele. As pessoas não conseguem vencer e dizem que você também não vai vencer. Se você quer uma coisa corre atrás.”,
À Procura da Felicidade

AGRADECIMENTOS

À Deus, que me capacitou e me sustentou física, mental e espiritualmente durante todo esse período em que estive envolvido nesse projeto.

À minha mãe pelos ensinamentos, conselhos e incentivo.

À minha irmã pela ajuda e disponibilidade.

À minha orientadora Prof^a. Dra. Maria da Guia da Silva pelas contribuições, críticas e sugestões, pelo compartilhar de sua experiência e de seus conhecimentos, e principalmente pela amizade.

Ao meu orientador Prof. Dr. Anselmo Barbosa Rodrigues por orientar de forma clara e sucinta cada etapa desta tese e por compartilhar de sua vasta experiência e de seus conhecimentos em sistemas de distribuição.

Aos professores do PPGEE da UFMA pelas contribuições.

Aos amigos que fiz durante o doutorado.

E as pessoas que contribuíram direta ou indiretamente para que mais um sonho fosse realizado na minha vida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001.

RESUMO

Esta tese apresenta uma metodologia para Reconfiguração da Rede de Distribuição (RRD) multiobjetivo. Os objetivos considerados na técnica proposta são as perdas anuais de energia e a precisão do estimador de estado. A degradação da precisão do estimador de estado, causada pela RRD, é compensada pela instalação de medidores durante a geração da topologia ótima. Devido a isso, é também considerado como um dos objetivos do problema de reconfiguração a minimização do número de medidores instalados para reduzir os custos de instalação dos equipamentos de medição. As componentes da função objetivo foram minimizadas considerando-se as seguintes restrições: radialidade, fluxo de potência ativa e reativa, limites de carregamento, intervalos para as magnitudes das tensões nodais e níveis de risco para a acurácia do estimador de estado. O problema de otimização definido acima foi solucionado usando-se uma formulação multiobjetivo baseada na combinação da Teoria Pareto (para modelar múltiplos critérios) com o algoritmo genético com chaves viciadas aleatórias. A aplicação do método proposto para a RRD foi realizada em uma rede de distribuição de 69 nós. Os resultados dos testes demonstram que as soluções obtidas pelo método proposto têm boa qualidade e estabelecem um compromisso aceitável entre os objetivos, isto é: topologias com reduções significativas nas perdas anuais de energia e planos de medição com alta precisão e com baixo custo de instalação. Além disso, a metodologia proposta para alocação de medidores é flexível para considerar o número de topologias definidas pelos engenheiros de planejamento da operação. Desta forma, as principais contribuições desta tese são: (i) o desenvolvimento de uma metodologia para a solução concomitante dos problemas de minimização de perdas de energia via RRD e maximização da precisão do estimador através da alocação de medidores com o objetivo de evitar a degradação da precisão do estimador de estado pela alteração na topologia da rede; (ii) introdução de uma técnica analítica para avaliar a precisão do estimador de estados considerando-se nós de injeções nulas; (iii) proposição de uma versão multiobjetivo do BRKGA; (iv) apresentação de uma nova codificação para soluções candidatas geradas pelo BRKGA para a solução do problema de RRD.

Palavras-chaves: Estimação de estado, Redes de distribuição, Otimização multiobjetivo, Alocação de medidores, Algoritmo Genético de Chaves Aleatórias Viciadas, Teoria Pareto.

ABSTRACT

This thesis presents a methodology for multiobjective Distribution Network Reconfiguration (DNR). The objectives considered in the proposed technique are the losses and accuracy of the state estimator. The degradation of the accuracy of the state estimator, caused by the DNR, is compensated by the installation of meters during the optimal topology generation. Due to this, it is also considered as one of the objectives of the reconfiguration problem the minimization of the number of meters installed to reduce the installation costs of the measuring equipment. The objective function components were minimized subject to the following constraints: radiality, active and reactive power flow, loading limits, intervals for the magnitudes of the nodal voltages, and risk levels for the accuracy of the state estimator. The optimization problem defined above was solved using a multiobjective formulation based on the combination of Pareto Theory (to model multiple criteria) with the genetic algorithm with biased random keys. The application of the proposed method for DNR was performed in a distribution network of 69 nodes. The results of the tests demonstrate that the solutions obtained by the proposed method are of good quality and establish an acceptable compromise among the objectives, that is, topologies with significant reductions in annual energy losses and measurement systems with high accuracy and low installation costs. In addition, the proposed methodology for allocating meters is flexible to take into account the number of topologies defined by the operation planning engineers. In this way, the main contributions of this thesis are: (i) the development of a methodology for the concomitant solution of the problems of minimization of the energy loss through DNR and maximization of the state estimation accuracy by the meter placement aiming to avoid the degradation of the state estimation accuracy by the network topology change; (ii) introduction of an analytical approach to assess the state estimation accuracy considering null injection nodes; (iii) proposition of a multiobjective version of BRKGA; (iv) presentation of a new codification for the candidate solutions generated by the BRKGA for the solution of the DNR problem.

Keywords: State estimation, Distribution networks, Multiobjective optimization, Meter placement, Biased Random-Key Genetic Algorithm, Pareto theory.

LISTA DE ABREVIATURAS/SIGLAS

AG – Algoritmo Genético

AENS – *Average Energy Not Supplied*

AIS – *Artificial Immune Systems*

AMI – *Advanced Metering Infrastructure*

BPSO – *Binary Particle Swarm Optimization*

BRKGA – *Biased Random-Key Genetic Algorithm*

CAAOM – Colônia de Abelhas Artificiais para Otimização Multiobjetivo

CIS – *Customer Information System*

CSA – *Cuckoo Search Algorithm*

DEC – Duração Equivalente de Interrupção por Unidade Consumidora

DMS – *Distribution Management System*

DOAA – Decomposição Ortogonal de Autovalores e Autovetores

EERD – Estimação de Estado em Redes de Distribuição

ENNS – *Expected Energy Not Supplied*

ER – *Error Ratio*

FCM – *Fuzzy C-Means*

FEC – Frequência Equivalente de Interrupção por Unidade Consumidora

FPO – Fluxo de Potência Ótimo

GD – Geradores Distribuídos

GDM – *Generational Distance Metric*

GIS – *Geographic Information System*

GSA – *Gravitational Search Algorithm*

HSA – *Harmony Search Algorithm*

HV – Hipervolume

IED – *Intelligent Electronic Devices*

MAEE – Método Analítico de Enumeração de Estados

MAPE – *Mean Absolute Percentage Error*

MDM – *Meter Data Management*

MGN – Método iterativo de Gauss-Newton

MQP – Mínimos Quadrados Ponderados

MSF – *Minimum Spanning Forest*

MST – *Minimum Spanning Tree*

MVAP – Mínimos Valores Absolutos Ponderados

NA – Normalmente Aberta

NAN – *Neighborhood Area Network*

NF – Normalmente Fechada

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

PDF – *Probability Density Function*

PMU – *Phasor Measurement Unit*

POM – Problema de Otimização Multiobjetivo

PSO – *Particle Swarm Optimization*

RRD – Reconfiguração da Rede de Distribuição

RTU – *Remote Terminal Unit*

SAIDI – *System Average Interruption Duration Index*

SAIFI – *System Average Interruption Frequency Index*

SC – *Set Coverage*

SCADA – *Supervisory Control and Data Acquisition*

SE – Barra da Subestação

SEL – *Schweitzer Engineering Laboratories*

SEN – Sistema Especialista Nebuloso

SMC – Simulação Monte Carlo

SOM – *Self-Organizing Maps*

SP – *Spacing*

SPREAD – Dispersão

TLC – Transformação Linear de variáveis aleatórias Correlacionadas

TLD – Transformação Linear de variáveis aleatórias Descorrelacionadas

THD – *Total Harmonic Distortion*

WAN – *Wide Area Network*

LISTA DE FIGURAS

Figura 1.1: Arquitetura funcional de alto nível de um ADMS. (Adaptada de Boardman (2020)).	6
Figura 1.2: Estratégia proposta para alocação de medidores em conjunto com a reconfiguração.	29
Figura 2.1: Método de Gauss-Newton para estimação de estado.	41
Figura 2.2: Modelo π da linha.	42
Figura 3.1: Diagrama unifilar do sistema de 95 nós.	52
Figura 4.1: Modelo de uma rede neural auto-organizável de Kohonen.	64
Figura 4.2: Curva de carga utilizada para agrupamento de demanda de energia.	66
Figura 4.3: Índices MAPE para as técnicas de agrupamento de cargas.	66
Figura 4.4: Número de patamares de carga obtido através do SOM para o mínimo MAPE.	67
Figura 4.5: Configurações de conexão das medições. (a) bifásica. (b) trifásica (Adaptada de Caro et al. (2010)).	69
Figura 4.6: Medições de tensão/corrente e medições processadas para a configuração trifásica (Adaptada de Caro et al. (2010)).	69
Figura 4.7: Fluxograma para o cálculo de R^{max} a partir das probabilidades $P_{k,l}^V$ e $P_{k,l}^\theta$.	74
Figura 4.8: Potenciais pontos de abertura para a RRD da rede de distribuição (Adaptado de Gers (2013)).	77
Figura 5.1: Composição da próxima geração no BRKGA (Adaptado de Gonçalves e Resende (2011)).	83
Figura 5.2: Demonstração do operador de <i>crossover</i> no BRKGA (Adaptado de Gonçalves e Resende (2011)).	84
Figura 5.3: Fluxograma do BRKGA (Adaptado de Gonçalves e Resende (2011)).	86
Figura 5.4: Árvores geradas a partir de um grafo.	88

Figura 5.5: Mutaç�o no BRKGA aplicado a RRD.....	92
Figura 5.6: <i>Crossover</i> no BRKGA aplicado a RRD.	94
Figura 6.1: Funç�o de pertin�ncia em que $\mu_A(x) = 1$ se, e somente se, $2 \leq x \leq 8$	100
Figura 6.2: Funç�o de pertin�ncia que expressa a ideia de que a velocidade de um avi�o tem seu valor em torno de 865 km/h.	101
Figura 6.3: Funç�o de pertin�ncia trapezoidal.	102
Figura 6.4: Funç�o de pertin�ncia senoidal truncada.	102
Figura 6.5: Estrutura b�sica de um SEN (Adaptado de Tanscheit (2007)).	103
Figura 6.6: Superf�cie do SEN produzida a partir das 9 regras geradas a partir das combinaç�es de vari�veis de entrada <i>alto</i> , <i>m�dio</i> e <i>baixo</i>	106
Figura 6.7: Exemplo de uma fronteira de Pareto.	108
Figura 6.8: Fluxogramas dos algoritmos. (a) Algoritmo para minimizaç�o anual de perda de energia atrav�s da RRD e alocaç�o de medidores p�s-RRD. (b) Algoritmo para soluç�o simult�nea da minimizaç�o anual de perda de energia via RRD e alocaç�o de medidores.	116
Figura 7.1: Diagrama unifilar do S69.....	122
Figura 7.2: R^{max} (parte superior) e perdas ativas (parte inferior) para cada n�vel da curva de carga para o caso #0.	125
Figura 7.3: Aproximaç�o da Fronteira de Pareto para o caso #1 (parte superior) e risco nodal (parte inferior), considerando um plano de mediç�o com 6 medidores instalados.	126
Figura 7.4: Demonstraç�o do SEN com $N^{meter} = 6$ e $R^{max} = 0,9792\%$ – caso #1...	127
Figura 7.5: Visualizaç�o do plano de mediç�o com 6 medidores no S69 (1 na SE + 5 na rede) – caso #1.	128
Figura 7.6: Aproximaç�o da fronteira de Pareto para uma topologia – caso #3.	130
Figura 7.7: Riscos nodais considerando tr�s planos de mediç�o para uma topologia – caso #3.	131
Figura 7.8: Demonstraç�o do SEN com $N^{meter} = 12$ e $R^{max} = 1,0078\%$ – caso #3.	132

Figura 7.9: Localização do plano de medição com 10 medidores no S69 (1 na SE + 9 na rede) para uma topologia – caso #3.	132
Figura 7.10: Localização do plano de medição com 11 medidores no S69 (1 na SE + 10 na rede) para uma topologia – caso #3.	133
Figura 7.11: Localização do plano de medição com 12 medidores no S69 (1 na SE + 11 na rede) para uma topologia – caso #3.	133
Figura 7.12: Aproximação da fronteira de Pareto para cada topologia – caso #3.....	135
Figura 7.13: Riscos nodais considerando um plano de medição para cada topologia – caso #3.	136
Figura 7.14: Aproximação da fronteira de Pareto para o caso #4 via MOBRKGA....	138
Figura 7.15: Riscos nodais para as soluções \mathcal{Z}_{42} e \mathcal{Z}_{59} – caso #4.	139
Figura 7.16: Aproximação da fronteira de Pareto para o caso #4 via NSGA-II.	144

LISTA DE TABELAS

Tabela 3.1: Número de condicionamento segundo sistema (3.4).....	51
Tabela 3.2: Número de condicionamento segundo a equação (2.7).....	51
Tabela 6.1: Regras geradas a partir das combinações de variáveis de entrada do SEN.	106
Tabela 7.1: Principais dados do S69.	122
Tabela 7.2: Elementos da fronteira de Pareto para o caso #1.....	126
Tabela 7.3: Número de medições por medidor multifuncional – caso #1.....	128
Tabela 7.4: Resultados do caso #2.	129
Tabela 7.5: Elementos da fronteira de Pareto para uma topologia – caso #3.....	130
Tabela 7.6: Número de medições por medidor multifuncional com 10 medidores no S69 (1 na SE + 9 na rede) para uma topologia – caso #3.....	134
Tabela 7.7: Número de medições por medidor multifuncional com 11 medidores no S69 (1 na SE + 10 na rede) para uma topologia – caso #3.....	134
Tabela 7.8: Número de medições por medidor multifuncional com 12 medidores no S69 (1 na SE + 11 na rede) para uma topologia – caso #3.....	134
Tabela 7.9: Elementos da fronteira de Pareto para quatro topologias – caso #3.....	137
Tabela 7.10: Elementos da fronteira de Pareto para o caso #4.....	140
Tabela 7.11: Comparação dos custos computacionais associados com o MOBRKGA e NSGA-II.	144
Tabela 7.12: Métricas de desempenho MOBRKGA vs. NSGA-II – caso #1, onde ✓ (✗) indica o melhor (pior) algoritmo com relação a uma métrica.	145
Tabela 7.13: Métricas de desempenho MOBRKGA vs. NSGA-II – caso #4, onde ✓ (✗) indica o melhor (pior) algoritmo com relação a uma métrica.	145
Tabela 7.14: Comparação dos custos computacionais associados com o MOBRKGA nas linguagens MATLAB e Julia.	147

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Reconfiguração de Redes de Distribuição de Energia Elétrica	1
1.2 Estimação de Estado em Redes de Distribuição.....	4
1.3 Alocação de Medidores para Melhoria da Precisão do Estimador de Estado em Redes de Distribuição	9
1.4 Alocação de Medidores Considerando Alterações Topológicas na Rede de Distribuição	12
1.5 Reconfiguração Multiobjetivo na Rede de Distribuição.....	17
1.6 Motivação	25
1.7 Objetivos.....	27
1.8 Contribuições da Tese	30
1.9 Estrutura da Tese.....	31
2 ESTIMAÇÃO DE ESTADO VIA MÉTODO DE MÍNIMOS QUADRADOS PONDERADOS NÃO-LINEAR	33
2.1 Introdução	33
2.2 Classificação dos Estimadores de Estado.....	34
2.3 Método de Gauss-Newton com Medições Descorrelacionadas	36
2.4 Algoritmo de Estimação de Estado via Método de Gauss-Newton.....	39
2.5 Funções de Medição e Estrutura da Matriz Jacobiana H	42
2.5.1 Funções de medição $h(x)$	42
2.5.2 Estrutura da matriz Jacobiana H	43
3 AVALIAÇÃO DA PRECISÃO DO ESTIMADOR DE ESTADO PARA REDES DE DISTRIBUIÇÃO.....	48
3.1 Introdução	48

3.2 Estimador de Estado via MQP Baseado no MGN com Restrições de Igualdade para Modelagem de Nós de Injeções Nulas.....	49
3.3 Avaliação da Precisão do Estimador de Estado com Restrições de Igualdade e Medições Correlacionadas	52
3.4 Modelagem das Medições Associadas com as Cargas	58
4 FORMULAÇÕES MONOBJETIVO DOS PROBLEMAS DE RRD E ALOCAÇÃO DE MEDIDORES.....	62
4.1 Introdução	62
4.2 Mapas Auto-Organizáveis de Kohonen para Agrupamento de Cargas.....	62
4.3 Formulação Monobjetivo do Problema de Alocação de Medidores em Redes de Distribuição	67
4.4 Formulação Monobjetivo do Problema de RRD sob Demanda Variável	76
5 ALGORITMO GENÉTICO DE CHAVES ALEATÓRIAS VICIADAS PARA SOLUÇÃO DO PROBLEMA DE RECONFIGURAÇÃO MONOBJETIVO	82
5.1 Introdução	82
5.2 Descrição do BRKGA.....	82
5.3 Modelagem da Restrição de Radialidade da Rede no BRKGA	87
6 METODOLOGIA MULTI OBJETIVO PARA A SOLUÇÃO CONJUNTA DOS PROBLEMAS DE RECONFIGURAÇÃO E ALOCAÇÃO DE MEDIDORES VIA BRKGA	98
6.1 Introdução	98
6.2 Conceitos da Teoria de Conjuntos Nebulosos	98
6.2.1 Representação de conjuntos nebulosos	99
6.3 SEN para o Problema de Alocação de Medidores com RRD	103
6.4 Conceitos da Teoria Pareto	107
6.5 Formulação Multiobjetivo Pareto para o Problema de Alocação de Medidores com RRD.....	110
6.6 Avaliação da Performance de Métodos de Otimização Multiobjetivo.....	117

7 RESULTADOS DOS TESTES.....	121
7.1 Introdução	121
7.2 Descrição do Sistema Teste.....	121
7.3 Hipóteses Assumidas nos Testes	123
7.4 Resultados dos Estudos de Casos.....	124
7.5 Análise de Desempenho do MOBRKGA	143
8 CONCLUSÕES.....	148
8.1 Introdução	148
8.2 Comentários sobre o MOBRKGA	149
8.3 Sugestões para Trabalhos Futuros	150
8.3.1 Extensão da metodologia proposta em coordenadas de fase	150
8.3.2 Alocação ótima de medidores multifuncionais considerando-se as falhas nos medidores e equipamentos da rede de distribuição.....	150
8.3.3 Alocação de medidores para detecção de perdas não-técnicas	151
8.3.4 Inclusão de restrições associadas com o número de manobras na RRD.....	152
8.3.5 RRD considerando-se aspectos de confiabilidade.....	153
8.4 Artigos Publicados	154
REFERÊNCIAS	157

Capítulo 1

INTRODUÇÃO

Nesta seção é apresentada uma descrição dos principais problemas associados com esta tese: a Reconfiguração da Rede de Distribuição (RRD) e a alocação de medidores. Primeiramente, serão abordados aspectos gerais do problema de RRD monobjetivo. Em seguida, é introduzida a Estimação de Estado em Redes de Distribuição (EERD) e a alocação de medidores para melhorar a precisão do estimador de estado. Também, é realizada uma revisão bibliográfica sobre alocação de medidores para múltiplas topologias da rede de distribuição. Após esta revisão bibliográfica, é feito o levantamento do estado da arte sobre a RRD multiobjetivo de redes de distribuição. A RRD multiobjetivo é o principal pré-requisito para a contribuição desta tese: a realização conjunta da alocação de medidores e da RRD considerando variações na carga no período anual. Finalmente, são definidos a motivação, os objetivos e a estrutura da tese.

1.1 Reconfiguração de Redes de Distribuição de Energia Elétrica

A RRD consiste basicamente na abertura e no fechamento de chaves para modificar a topologia da rede elétrica durante a operação normal ou em um estado de contingência da rede de distribuição. Esta modificação na topologia é realizada preservando-se a radialidade da rede de distribuição. Ou seja, a existência de um único caminho entre um ponto de carga e a fonte. No domínio da teoria dos grafos, a radialidade está associada com grafos acíclicos, ou seja, sem a presença de malhas (laços). Em outras palavras, o número de arcos (ramos) em uma árvore para conectar todos os seus vértices (nós) deve ser igual ao número de vértices menos um.

No estado de operação normal, o principal objetivo da reconfiguração é a minimização de perdas resistivas. No entanto, a reconfiguração também é usada para otimizar os seguintes índices de desempenho da rede de distribuição: balanceamento de

cargas (Kasehm et al., 1999), confiabilidade (Brown, 2009), margem de estabilidade de tensão (Venkatesh et al., 2004), custos de afundamentos de tensão (Bahadoorsingh et al., 2007), harmônicos (Jazebi et al., 2014), etc. Estes objetivos são otimizados sujeito a restrições técnicas associadas com: carregamento dos circuitos (seções dos alimentadores), intervalos nas magnitudes das tensões nodais e limites referentes a indicadores de qualidade de energia.

Por outro lado, nos estados de contingência (quando ocorre a falha de um componente), a RRD é usada para isolar o componente falhado e restaurar o fornecimento de energia para os consumidores interrompidos pela falha. Esta restauração é realizada através de transferências de carga para alimentadores adjacentes via chaves Normalmente Abertas (NA) e da reenergização de circuitos através da abertura de uma chave Normalmente Fechada (NF) acima da falta e do religamento da proteção que eliminou a falta (Brown, 2009). A RRD orientada a restauração do fornecimento de energia também é realizada considerando-se restrições de tensão e carregamento. No entanto, ela também considera algumas restrições típicas do problema de restauração. Por exemplo, o número máximo de manobras que pode ser realizado antes do reparo do componente defeituoso ser concluído. Além disso, deve-se considerar que o fornecimento de energia deve ser restaurado primeiramente para cargas críticas, por exemplo, instalações elétricas onde há risco de fatalidades devido a interrupção no fornecimento de energia. Geralmente, os objetivos da RRD na restauração são: minimização do número de consumidores interrompidos pela falha de um componente, o custo de interrupção ou o montante total de energia não-fornecida. Desta forma, no contexto de restauração, as perdas e outros índices de desempenho tem menos prioridade do que aspectos relacionados a confiabilidade da rede de distribuição.

Os status das chaves (aberta ou fechada) são variáveis discretas binárias (1 para o status fechado e zero para o aberto). Adicionalmente, a identificação de violações de tensão e carregamento para uma dada topologia radial requer a solução do problema de fluxo de potência. Este problema está associado com a solução de um sistema de equações algébricas não-lineares. Desta forma, a RRD está associada com um problema de programação não-linear inteira mista. Devido a isto, diversas metodologias têm sido aplicadas para solucionar o problema de RRD. Estas metodologias podem ser classificadas em dois tipos:

i) Programação matemática: programação cônica inteira-mista (Jabr et al., 2012; Taylor e Hover, 2012); programação linear inteira-mista (Borghetti, 2012); programação inteira mista com restrições quadráticas (Ramos et al., 2010); etc.

ii) Técnicas Heurísticas: intercâmbio de ramos (Baran e Wu, 1989b; Ababei e Kavasseri, 2011) algoritmo genético (AG) (Wang e Gao, 2013), algoritmo memético (Mendes et al., 2013), busca informada (Botea, 2012), algoritmo de busca harmônica (HSA – *Harmony Search Algorithm*) (Srinivasa et al., 2013; Rao et al., 2013); sistemas imunológicos artificiais (AIS – *Artificial Immune Systems*) (Alonso, Oliveira e De Souza, 2015; Ashisa, Sanjoy e Anil, 2007); otimização por enxame de partículas (PSO – *Particle Swarm Optimization*) (Andervazh et al., 2013; Kayal e Chanda, 2013); etc.

No âmbito da operação normal (sem falhas de componentes), a reconfiguração da rede de distribuição pode ser realizada para um nível de demanda fixo (carga média ou pico de carga) ou para uma demanda variável com um horizonte de tempo de um dia (López et al., 2004; Pfitscher et al., 2013; Souza et al., 2016) até um ano (Yin e Lu, 2009; Tahboub et al., 2015; Takenobu et al., 2018). Geralmente, a inclusão da demanda variável no tempo na RRD produz melhores resultados do que para um nível de demanda fixo. Este fato é devido a demanda variável representar de forma mais precisa as flutuações cronológicas na carga entre as classes de consumidores. É importante destacar que a realização da RRD com dependência temporal é um pré-requisito importante para a modelagem de Geradores Distribuídos (GD) baseados em fontes renováveis (solar, eólica e maremotriz) no planejamento da operação de redes de distribuição. Além disso, a determinação de um conjunto de topologias para um período de estudo é mais eficaz do que obter uma topologia para cada intervalo de tempo da curva de carga, por exemplo, 24 topologias para uma curva de carga diária com patamares horários. Esta eficiência é devido ao número excessivo de manobras causar transitórios de chaveamento que degradam a vida útil das chaves e de outros componentes. Tahboub et al. (2015) propuseram três estratégias para RRD em um período anual visando minimizar o número de operações de chaveamento:

i) Topologia simples (única): recomendada para redes de distribuição com baixo nível de automação, ou seja, com pequeno número de chaves controladas remotamente.

ii) Quatro topologias: uma topologia para cada estação do ano (verão, inverno, primavera e outono). Esta estratégia é recomendada para locais onde as curvas de demanda são consideravelmente distintas entre as estações do ano.

iii) Oito topologias: quatro topologias para cada estação do ano e duas topologias para diferenciar as cargas de dia de semana e final de semana. Desta forma, tem-se um total de oito topologias, pois há duas topologias para cada estação (fim de semana e dia de semana).

Quando a RRD determina um conjunto de topologias para um período de estudo, diversos índices de desempenho da rede de distribuição e funções do DMS (*Distribution Management System*) são afetados pelas alterações topológicas durante todo o período de tempo considerado, por exemplo: indicadores de qualidade de energia, a coordenação/seletividade das proteções e a precisão do estimador de estado da rede de distribuição.

Nas próximas seções é apresentada uma introdução sobre a estimação de estado em redes de distribuição e a alocação de medidores para a melhoria da precisão do estimador de estado.

1.2 Estimação de Estado em Redes de Distribuição

O estimador de estado é um recurso fundamental na operação de sistemas de energia elétrica. Essencialmente, o estimador processa telemidas redundantes (magnitude das tensões nas barras, injeções de potência nas barras, fluxos de potência e/ou de corrente nos circuitos), corrompidas por erros de diversos tipos, para estimar valores de módulo e fase das tensões em todas as barras. Isto é, o estado do sistema em regime permanente. A partir do estado, é possível determinar outras variáveis necessárias para a análise e monitoramento do sistema, tais como: fluxos de potência nos circuitos, correntes nas linhas, injeções de potência nas barras, etc. Além do conjunto de medições tomadas ao longo do sistema, existem outras quantidades que não são medidas diretamente, mas também contém informações relevantes sobre o estado do sistema e podem ser processadas pelo estimador de estado. Estas quantidades que podem ser estimadas sem a utilização de instrumentos de medição são denominadas de

pseudo-medidas. As principais aplicações da função de estimação de estado nos centros de controle dos sistemas de transmissão são (Costa e Salgado, 2018):

- i) Monitoramento da segurança, cujo objetivo é monitorar a condição atual de operação do sistema (normal, emergência ou restaurativa);
- ii) Análise de segurança, cuja função é avaliar os efeitos de eventuais contingências no sistema;
- iii) Previsão de carga, cujo objetivo é estimar a demanda futura nas barras do sistema.

A Figura 1.1 mostra a arquitetura funcional de alto nível de um Sistema de Gerenciamento de Distribuição Avançado (ADMS – *Advanced Distribution Management System*), onde:

- GD: Geradores Distribuídos;
- RTU: Unidade Terminal Remota (*Remote Terminal Unit*);
- AMI: Infraestrutura de Medição Avançada (*Advanced Metering Infrastructure*);
- MDM: Gerenciamento de Dados do Medidor (*Meter Data Management*);
- CIS: Sistema de Informação do Consumidor (*Customer Information System*);
- GIS: Sistema de Informação Geográfica (*Geographic Information System*);
- SCADA: Sistema de Supervisão e Aquisição de Dados (*Supervisory Control and Data Acquisition*);
- FEC: Frequência Equivalente de Interrupção por Unidade Consumidora;
- DEC: Duração Equivalente de Interrupção por Unidade Consumidora.

A partir da Figura 1.1, pode-se observar que o ADMS recebe dados de diversos sistemas de informação, por exemplo: GIS, CIS, AMI, etc. Estes dados são usados por módulos funcionais para realizar diversas tarefas no ambiente do ADMS. Os quatro módulos funcionais que compõem o ADMS são:

- i) Gerenciamento de Interrupções: responsável pela restauração do fornecimento de energia elétrica para os consumidores após uma interrupção no fornecimento de energia;
- ii) Operações de chaveamento: encarregado da criação, validação e execução de ordens de manobra, por exemplo, transferências de carga para a realização de manutenções programadas na rede de distribuição;

- iii) Simulador de Treinamento: realiza o treinamento dos operadores da rede de distribuição;
- iv) Análise de redes de distribuição: é responsável pela realização de estudos baseados em modelos computacionais para melhorar o desempenho da rede de distribuição.

A estimação de estado é uma função associada com o módulo funcional de Análise da Rede de Distribuição. Este módulo também realiza diversos estudos, tais como: curto-circuito, controle var/volt, reconfiguração de alimentadores, etc. Neste ponto, deve-se destacar que muitas das variáveis de saída do estimador de estado (tais como, os valores das cargas ativa e reativa nas barras calculados a partir das estimativas de módulo e fase das tensões nodais) são dados de entrada para outros estudos do módulo funcional de Análise da Rede de Distribuição. Por exemplo, o controle var/volt através de algoritmos de Fluxo de Potência Ótimo (FPO) para obter um ajuste de taps de transformadores e potência reativa dos GDs para minimizar as perdas na rede de distribuição. Desta forma, o estimador de estado está no topo das ferramentas computacionais referentes ao módulo funcional de Análise da Rede de Distribuição.

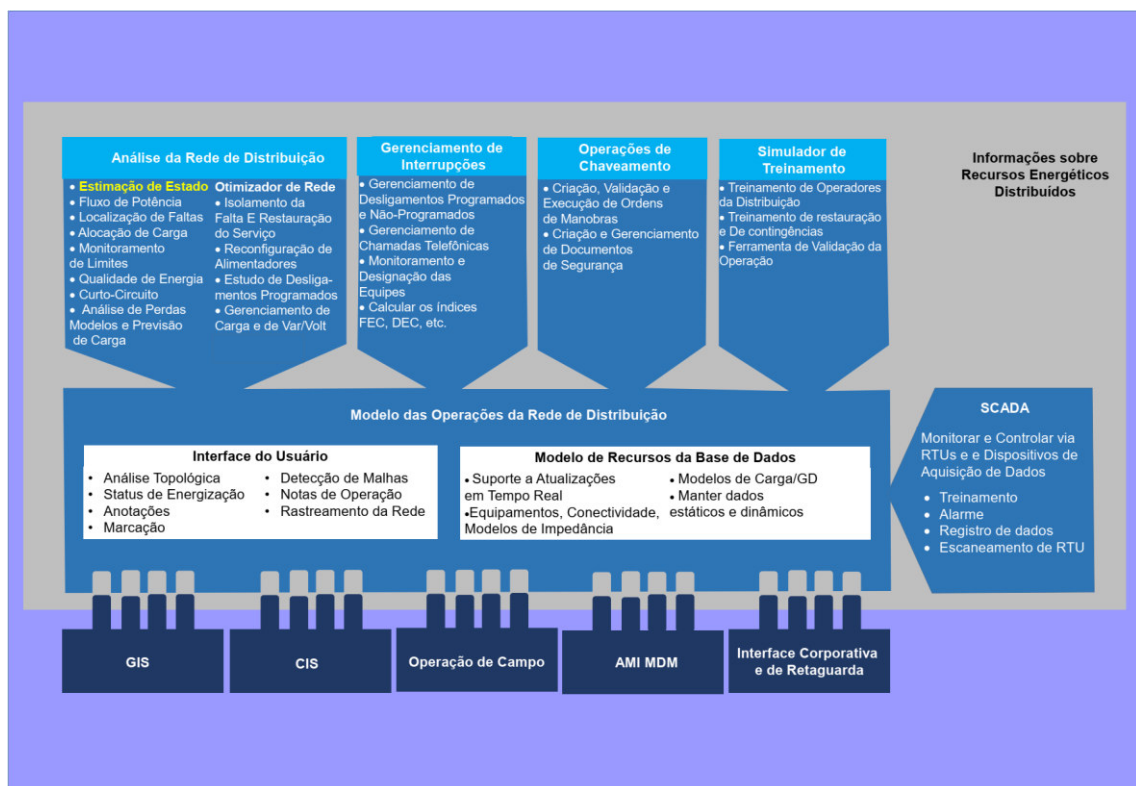


Figura 1.1: Arquitetura funcional de alto nível de um ADMS. (Adaptada de Boardman (2020)).

Geralmente, o problema de estimação é resolvido minimizando-se os desvios quadráticos ponderados entre os valores medidos e calculados de grandezas elétricas (Monticelli, 1999; Abur e Expósito, 2004). Os algoritmos existentes para EERD podem ser classificados em duas categorias:

- i) Matriciais (Lu et al., 1995; Lin e Teng, 1996; Singh et al., 2008): utilizam o método de Gauss-Newton para minimizar os desvios quadráticos ponderados.
- ii) Híbridos (Lin, Teng e Chen, 2001; Wang e Schulz, 2004): combinam o método de Gauss-Newton com técnicas de varredura progressiva/regressiva (*backward/forward sweep*) para estimar variáveis de estado com base na topologia radial da rede de distribuição.

As principais diferenças entre a estimação de estado em redes de distribuição e transmissão são descritas abaixo:

- i) Utilização de modelagem em coordenadas de fase para estimadores de distribuição, pois esta rede é desbalanceada por natureza devido a não-transposição dos circuitos e conexão de cargas desequilibradas. Por outro lado, as redes de transmissão são razoavelmente equilibradas, devido a transposição dos circuitos e podem ser modeladas usando apenas os modelos de sequência positiva.
- ii) Em sistemas de transmissão há uma grande quantidade de medidores instalados e devido a isto o número de pseudo-medições é relativamente pequeno. Por outro lado, em sistemas de distribuição o número de medidores instalados é muito pequeno e o número de pseudo-medições é bastante elevado. As principais pseudo-medições usadas em EERD são aquelas associadas com as cargas ativas e reativas nos transformadores abaixadores que alimentam a rede secundária. Geralmente, estas cargas são estimadas usando-se técnicas de alocação de carga ou dados estatísticos de campanhas de medição realizadas pelas concessionárias.
- iii) No sistema de transmissão as variáveis de estado são geralmente o módulo e a fase das tensões nodais. Por outro lado, em redes de distribuição podem ser utilizadas outras grandezas como variáveis de estado, tais como: partes real e imaginária das tensões nodais (notação retangular) e também o módulo e a fase das correntes nos ramos. A escolha destas grandezas tem como objetivo evitar problemas de singularidade da matriz Jacobiana quando medições de corrente são processadas pelo estimador de estado.

A presença de um número reduzido de medições pode tornar a rede elétrica não-observável no âmbito da estimação de estado. Isto é, as variáveis de estado (módulo e fase das tensões nodais em todas as barras) não podem ser determinadas a partir de um conjunto de medições por um estimador de estado. Matricialmente, a não-observabilidade está associada com o fato do posto da matriz Jacobina associada com as medições não ser igual a dimensão do vetor de variáveis de estado. Do ponto de vista prático, não é viável alocar medidores na rede de distribuição para assegurar a sua observabilidade. Esta restrição é devido às dimensões das redes de distribuição serem consideravelmente maiores do que aquelas das redes de transmissão. A dimensão elevada das redes de distribuição é causada pelo grande número de seções e ramificações necessárias para rotear os alimentadores através de vias públicas. Desta forma a trajetória dos ramais, entre o tronco principal do alimentador e um ponto de carga, geralmente não corresponde a menor distância entre dois pontos. Além disso, a escassez de medições na rede de distribuição se deve ao custo elevado do sistema de telecomunicações requerido para transmitir as grandezas medidas dos locais de instalação dos respectivos medidores para os centros de operação da distribuição. Desta forma, só existem medições instaladas nos disjuntores de saída dos alimentadores e as únicas grandezas medidas associadas com as cargas são as suas demandas mensais de energia. É importante mencionar que há um grande número de nós de injeções nulas em redes de distribuição devido as restrições de roteamento da rede citadas acima. Estes nós podem fornecer medições virtuais de potência ativa e reativa para estimar o módulo e a fase das tensões nestas barras. Todavia, ainda seriam necessárias medições nos nós de carga para estimar as tensões nestes nós. Desta forma, as redes de distribuição de média e baixa tensão podem ser vistas como um sistema indeterminado, isto é, mais incógnitas do que equações. Em outras palavras, o número de medições é insuficiente para tornar a rede de distribuição completamente observável (Al-Wakeel et al., 2016). Devido a isto, para viabilizar a EERD geralmente utiliza-se um grande número de pseudo-medições que são adicionadas ao plano de medição existente para assegurar a observabilidade. É importante ressaltar que as pseudo-medições são necessárias mesmo com a existência da AMI, pois a latência da AMI é muito maior que a do SCADA (as medições do SCADA são transmitidas em uma escala de segundos enquanto a transmissão na AMI pode variar de 15 minutos até 24 horas) (Expósito et al., 2015). Devido a isso, as pseudo-medições são importantes para contornar a perda de observabilidade causada

pelos dados desatualizados da AMI. Contudo, espera-se que a disponibilidade de medições mais precisas seja melhorada em um futuro próximo com a aplicação de Dispositivos Eletrônicos Inteligentes (IED – *Intelligent Electronic Devices*) na rede de distribuição que recebem e enviam informações através da internet. Uma desvantagem do uso das pseudo-medições é que a precisão do estado estimado é comprometida devido ao fato de que os erros associados com as pseudo-medições são consideravelmente maiores do que aqueles referentes às medições reais. Conseqüentemente, o problema de alocação de medidores, para fins de EERD, tem como objetivo maximizar a precisão do estimador de estado em vez de assegurar a observabilidade da rede elétrica.

1.3 Alocação de Medidores para Melhoria da Precisão do Estimador de Estado em Redes de Distribuição

A precisão do estimador de estado está associada com os erros entre os valores verdadeiros e estimados das tensões nodais. As tensões nodais estimadas são variáveis aleatórias, pois elas são funções das medições que contém erros em razão da presença de incertezas de natureza diversa. No entanto, uma execução do estimador de estado está associada somente com uma amostra/realização/observação resultante da aleatoriedade das medições. Em outras palavras, execuções repetidas do estimador de estado para a mesma configuração do sistema com valores de medições observados ou simulados (sorteados aleatoriamente) fornecem estimativas distintas das tensões nodais. Na verdade, uma avaliação completa das flutuações nas tensões nodais, devido às incertezas nas medições, exigiria a representação de todo o espaço amostral de cada medição e da combinação destas incertezas individualizadas. No âmbito da estatística, este tipo de avaliação está associado com o problema de propagação de incertezas ou de erros. Ou seja, o estimador de estado é o sistema/modelo sob estudo da propagação de incertezas. As tensões nodais são as variáveis de saída do modelo sob estudo e as medições são as variáveis de entrada que contém incertezas.

A propagação de incertezas permite avaliar a dispersão dos valores estimados das tensões nodais em torno dos seus valores médios através de vários índices, por exemplo: desvio padrão, percentis e riscos (probabilidades) associados com os limites

para os erros relativos entre os valores verdadeiros e estimados das tensões nodais. Estas estatísticas são usadas na função objetivo do problema de alocação de medidores para incorporar aspectos de precisão do estimador de estado no plano de medição ótimo.

A maioria das metodologias existentes para a alocação de medidores em redes de distribuição visa a minimização de uma das seguintes funções:

- i)** Probabilidade do erro relativo entre os valores verdadeiros e estimados das grandezas monitoradas ser maior do que um valor especificado (Singh et al., 2009; Singh et al., 2011). Os valores verdadeiros das tensões são obtidos a partir da solução do fluxo de potência para a condição do caso base para a rede sob estudo.
- ii)** Soma ponderada das variâncias associadas com as variáveis de estado estimadas (Shafiu et al., 2005; Muscas et al., 2006; Muscas et al., 2009).

A partir da descrição acima, pode-se concluir que o problema de alocação de medidores para EERD tem as seguintes características:

- i)** Não-linear: devido a natureza não-linear das equações de fluxo de potência que são a base para o problema de EERD.
- ii)** Combinatorial: pois as variáveis de decisão são os locais da rede (barras ou ramos) nos quais deve-se instalar (variável de decisão é unitária) ou não um medidor (variável de decisão é nula).
- iii)** Estocástico: as funções objetivo são baseadas em índices estatísticos (variâncias e probabilidades) para reconhecer as incertezas associadas com o estado estimado da rede elétrica a partir de medições corrompidas por erros de natureza diversificada.

Um componente importante do método usado para resolver o problema de alocação de medidores é a técnica probabilística usada para estimar a função objetivo, ou seja, os índices de precisão do estimador de estados. Geralmente, estes índices são estimados usando-se métodos probabilísticos para realizar a propagação de incertezas. Os principais métodos usados na avaliação da precisão do estimador de estados são: a Simulação Monte Carlo (SMC) (Shafiu et al., 2005; Muscas et al., 2006; Muscas et al., 2009; Singh et al., 2009; Singh et al., 2011; Liu et al., 2014) e o método analítico (Raposo, 2016; Raposo et al., 2017; Raposo et al., 2018; Raposo et al., 2019a; Raposo et al., 2019b; Raposo et al., 2020).

A SMC tem sido preferencialmente utilizada para avaliar a precisão do estimador de estados em diversos estudos de alocação de medidores devido as seguintes vantagens: simplicidade/facilidade de implementação e capacidade para modelar qualquer tipo de incerteza em modelos lineares e não lineares. A avaliação da precisão do estimador de estado baseada na SMC consiste em sortear os valores das medições. Estes valores sorteados são obtidos usando-se geradores de números aleatórios com distribuições gaussianas para representar os erros nas medições. Após uma amostra de vetores de medições ser sorteada, realiza-se a estimação de estado para cada vetor de medições da amostra usando-se um estimador de estado não-linear, por exemplo, o estimador de mínimos quadrados ponderados baseado no Método de Gauss-Newton. Em seguida, calculam-se os índices estatísticos de precisão para a amostra usando-se os valores estimados e verdadeiros das tensões nodais. A avaliação da precisão via SMC é relativamente simples e direta. Todavia, esta torna-se bastante dispendiosa com relação ao tempo de execução devido a necessidade de realizar uma estimação de estado não-linear para cada elemento da amostra de vetores de medições. Tipicamente, utiliza-se uma amostra com 100 elementos (Singh et al., 2009). Este número não é suficiente para assegurar que os índices de precisão sejam estimados com um erro aceitável devido a variabilidade amostral (Raposo, 2016). Em outras palavras, a variabilidade amostral é causada pelas mudanças nos índices para diferentes amostras aleatórias dos vetores de medições.

Uma alternativa para reduzir o custo computacional e os erros da análise da precisão do estimador é realizar a propagação de incertezas via métodos analíticos (Raposo, 2016; Raposo et al., 2017; Raposo et al., 2018; Raposo et al., 2019a; Raposo et al., 2019b; Raposo et al., 2020). Os métodos analíticos obtêm fórmulas matemáticas fechadas para as variáveis de saída (estimativas das tensões nodais) de um modelo em função das distribuições de probabilidade das variáveis de entrada (erros nas medições). A partir destas fórmulas, pode-se obter as distribuições de probabilidade das variáveis de saída usando-se diversas técnicas probabilísticas, por exemplo, as expansões em funções ortogonais (Gram-Charlier, Cornish-Fisher e Edgeworth) usadas em estudos de fluxo de potência probabilístico (Chagas et al., 2018). A derivação de um método analítico para a avaliação da precisão do estimador de estado se baseia na linearização das condições de otimalidade do problema de mínimos quadrados ponderados usando-se a expansão de Taylor de primeira ordem. Desta forma, obtém-se uma transformação

linear de variáveis aleatórias com distribuições gaussianas cujo resultado é um vetor de saída aleatório com distribuição gaussiana com média e desvio padrão conhecidos. A partir deste resultado, pode-se estimar os índices de precisão do estimador de estado usando-se apenas a relação de sensibilidade fornecida pela expansão de Taylor sem a necessidade de solucionar vários problemas de estimação de estado não-lineares.

1.4 Alocação de Medidores Considerando Alterações Topológicas na Rede de Distribuição

O estimador de estado calcula as tensões nodais a partir dos dados dos medidores (magnitude da tensão, fluxo de potência e corrente) instalados na rede de distribuição. A precisão das estimativas das tensões nodais é determinada através da propagação de incertezas em um modelo linearizado que é dependente dos seguintes fatores: tipos de medidores, quantidade de medições disponíveis, parâmetros dos circuitos (resistências, reatâncias, susceptâncias) e conectividade da rede de distribuição. Conseqüentemente, uma alteração na topologia da rede pode melhorar ou degradar a precisão do estimador de estado.

Quando a RRD é orientada para a restauração a perda de precisão do estimador é temporária visto que a alteração topológica só dura até ser concluído o reparo do componente defeituoso. Por exemplo, o tempo de reparo típico dos componentes de redes de distribuição aéreas varia de 1,5 até 5 horas (Brown, 2009). Além disso, as agências reguladoras estabelecem limites para a duração acumulada média das interrupções, por exemplo, 90 minutos por ano (Brown, 2009). Conseqüentemente, é muito pequeno o período de tempo no qual a RRD orientada a restauração afeta a precisão do estimador de estado. Por outro lado, na RRD orientada a minimização de perdas, as alterações topológicas podem permanecer por um longo período de tempo, por exemplo, 8760 horas para uma programação anual da RRD com topologia simples (Tahboub et al., 2015). Desta forma, há um risco do estimador de estado fornecer estimativas de baixa precisão ao longo de todo o ano mesmo que a precisão do plano de medição seja adequada na topologia pré-reconfiguração. Portanto, a RRD orientada a minimização de perdas representa uma maior ameaça a precisão do estimador de estado do que a RRD orientada a restauração. Este fato compromete a aplicação do estimador como um pré-requisito para diversas funções no DMS, por exemplo: o controle var/volt,

gerenciamento pelo lado da demanda, a coordenação do carregamento de veículos elétricos, o despacho de GD e de dispositivos de armazenamento de energia.

Uma alternativa para contornar a perda de precisão do estimador causada pela programação anual da RRD é a atualização do plano de medição da rede de distribuição original. Ou seja, a instalação de novos medidores para restaurar a precisão do estimador para o conjunto de topologias (que pode ser unitário com uma topologia simples ou contendo várias topologias) gerado pela RRD. Esta atualização pode ser realizada com base em dois paradigmas:

- i) Alocação pós-reconfiguração: a instalação dos medidores é realizada para uma ou mais topologias obtidas após a RRD.
- ii) Alocação simultânea com a reconfiguração: os problemas de alocação de medidores e RRD são resolvidos de forma concorrente.

A alocação pós-reconfiguração é mais simples de ser realizada, pois ela desacopla os problemas de alocação e RRD em uma estratégia de dois estágios. Primeiramente, a RRD é realizada para gerar uma ou mais topologias para um ou vários níveis de demanda. Em seguida, a alocação de medidores é realizada para o conjunto de topologias ótimas obtido. Esta alocação exige a definição de um índice para avaliar a precisão do estimador de estado para um conjunto de topologias. Por exemplo, um índice de precisão médio ou o pior índice de precisão para o conjunto de topologias. Uma desvantagem da alocação pós-reconfiguração é a tendência para instalar um número excessivo de medidores, pois a topologia é fixa e a sua alteração não é explorada para melhorar a precisão do estimador de estado.

A maioria das publicações existentes sobre a alocação de medidores para múltiplas topologias da rede de distribuição se baseia no paradigma de alocação de medidores pós-reconfiguração devido a sua simplicidade (Muscas et al., 2006; Singh et al., 2009; Abdelsalam et al., 2014; Liu et al., 2014; Damavandi et al., 2015; Wang et al., 2018).

Abdelsalam et al. (2014) analisaram o impacto da RRD sobre unidades de medição fasorial (PMU – *Phasor Measurement Units*). Os autores dividiram o problema original em dois subproblemas independentes. O Sistema de colônia de formigas foi usado para a RRD para reduzir as perdas resistivas. Em seguida, o algoritmo guloso foi aplicado para obter o número mínimo de PMU instalados na rede. A principal

desvantagem desta técnica é que a precisão do estimador de estado é desconsiderada após a reconfiguração da rede de distribuição.

Damavandi et al. (2015) propõem uma metodologia para alocar medidores de magnitude da tensão e PMU que é robusta para várias configurações da rede de distribuição. Neste artigo, a precisão do estimador de estado é avaliada através da matriz de informação de Fisher. O algoritmo de saturação submodular foi usado para alocar medidores para cada topologia selecionada. Embora os autores tenham considerado a precisão do estimador de estado, a topologia da rede não é otimizada para melhorar índices de desempenho, tais como as perdas, nem a precisão do estimador de estado.

Wang et al. (2018) propuseram um método robusto para a alocação de medidores baseado em técnicas de saturação e algoritmos heurísticos. Primeiramente, uma topologia radial é obtida a partir de um conjunto de configurações possíveis. Em seguida, um plano de medição composto de pseudo-medições, medidores de magnitudes das tensões e medidores de fluxo de potência é obtido usando-se algoritmos heurísticos. Os resultados mostram que a técnica proposta é computacionalmente eficiente para garantir a precisão do estimador de estado. Todavia, os autores ignoraram a correlação das medições. Além disso, o cálculo da precisão do estimador se baseia na SMC. Consequentemente, a técnica proposta em (Wang et al., 2018) tem alto custo computacional. É importante mencionar que os autores de (Wang et al., 2018) consideraram um conjunto de topologias na alocação de medidores. Entretanto, a topologia não é modificada para melhorar o desempenho da rede nem a precisão do estimador de estados.

Liu et al. (2014) propuseram um método de alocação de medidores para redes de distribuição radiais que considera a incerteza na potência de saída da GD. A técnica proposta incorpora PMU e medidores inteligentes na estimação de estado. A função objetivo definida pelos autores é a minimização dos desvios padrões relacionados com os erros relativos entre os valores verdadeiros e estimados das tensões nodais. O método proposto em (Liu et al., 2014) considera múltiplas topologias, mas somente um pequeno conjunto de topologias foi selecionado para a alocação de PMU e medidores de tensão. Adicionalmente, a correlação nas medições é desprezada e o custo computacional da metodologia é alto devido ao uso da SMC. Novamente, o impacto da RRD sobre o

número de medidores instalados para obter um nível de precisão especificado é desconsiderado.

Uma metodologia para a alocação de medidores multicanais é proposta em (Muscas et al., 2006) considerando incertezas relacionadas ao comportamento estocástico da demanda e erros de medições. A precisão do plano de medição é avaliada pela soma ponderada dos desvios padrões das variáveis de estado estimadas. Esta avaliação da precisão se baseia na SMC. Medidores multicanais são alocados para um conjunto de configurações de rede selecionadas usando-se a técnica de programação dinâmica. Assim como nas referências citadas anteriormente, a configuração da rede de distribuição não é modificada para reduzir o investimento na aquisição de medidores multicanais.

A partir da revisão bibliográfica, pode-se observar que as metodologias existentes para a alocação de medidores têm as seguintes deficiências:

- i) Tipicamente, a alocação de medidores é obtida para uma topologia ou um conjunto limitado de configurações da rede. Em outras palavras, o potencial da RRD para obter uma redução considerável nos custos de instalação dos medidores e melhorar a precisão do estimador de estado não é explorado.
- ii) Alto custo computacional devido ao uso da SMC para avaliar a precisão do estimador de estado.
- iii) A otimização conjunta dos índices de desempenho e da precisão do estimador não são consideradas nas metodologias atuais. A solução deste problema de otimização multiobjetivo requer a avaliação de um grande número de planos de medição candidatos. Entretanto, esta técnica não pode ser aplicada, pois a precisão do estimador de estado é geralmente avaliada através da MCS. Consequentemente, o custo computacional para a alocação multiobjetivo de medidores torna-se extremamente alto.

Por outro lado, a alocação simultânea com a reconfiguração é mais complexa devido aos seguintes fatores:

- i) Necessidade de solucionar um problema de otimização com múltiplos objetivos: minimização das perdas e outros índices de desempenho, maximização da precisão do estimador e minimização dos custos de instalação de medidores.

ii) Alto custo computacional, pois a avaliação de cada solução candidata exige a solução de um fluxo de potência (para determinar as perdas e violações nas restrições) e uma análise de sensibilidade combinada com uma técnica de propagação de incertezas para avaliar a precisão do estimador de estado. Esta limitação se torna mais crítica quando meta-heurísticas populacionais (algoritmos genéticos, exames de partículas, evolução diferencial, etc.) são usadas para determinar a alocação e a topologia da rede. Nestes métodos, a solução ótima é identificada calculando-se a função objetivo e as restrições para diversas gerações de uma população de indivíduos (soluções candidatas). Se a população de uma meta-heurística tiver 100 indivíduos e forem avaliadas 1000 gerações desta população, então deve-se realizar 100000 cálculos de fluxos de potência e de avaliação da precisão do estimador de estado. Este número de avaliações da precisão do estimador pode ser computacionalmente inviável quando a avaliação da precisão do estimador se baseia na combinação de modelos não-lineares com a SMC. Esta inviabilidade é devido a SMC ser um algoritmo estatístico computacionalmente intensivo que é embarcado (inserido) no núcleo de um algoritmo de otimização que também se baseia em simulação estocástica.

No entanto, a alocação simultânea a reconfiguração tem potencial para obter soluções com menor custo de instalação de medidores, pois a alteração na topologia é considerada como uma variável de decisão para melhorar a precisão do estimador de estado. Consequentemente, pode-se obter soluções com um menor número de medidores sem sacrificar de forma significativa as reduções nas perdas e outros índices de desempenho otimizados na reconfiguração. Desta forma, é oportuno desenvolver pesquisas para contornar as complexidades associadas com a alocação de medidores simultânea com a reconfiguração.

Já existe uma solução para minimizar o problema do alto custo computacional da avaliação da precisão do estimador de estado: o método analítico proposto nas referências (Raposo, 2016) e (Raposo et al., 2017). No entanto, deve-se ainda investigar a factibilidade da formulação e solução do problema de RRD em uma estrutura multiobjetivo que é o principal pré-requisito para o desenvolvimento de uma metodologia de alocação de medidores simultânea a RRD. A seguir é apresentada uma revisão bibliográfica e o levantamento do estado da arte sobre a RRD multiobjetivo.

1.5 Reconfiguração Multiobjetivo na Rede de Distribuição

Na referência (Gupta et al., 2010) é apresentada uma metodologia baseada em algoritmos genéticos para a RRD com o objetivo de minimizar perdas, perfil de tensão, carregamento e número de manobras das chaves. Estes objetivos são combinados em uma única função objetivo usando-se funções de pertinência nebulosa trapezoidal e senoidal e média geométrica máxima. A restrição de radialidade para cada indivíduo da população do algoritmo genético é checada através da definição de vetores de: laços, ramos em comum e grupos proibidos. Se um indivíduo viola a restrição de radialidade, então seleciona-se e manobra-se uma chave para repará-lo/retificá-lo.

Malekpour et al. (2013) apresentaram um algoritmo multiobjetivo para solucionar o problema de reconfiguração estocástica em rede de distribuição que contém GD eólica e células de combustível. A técnica proposta considerou quatro componentes na função objetivo: (i) perdas de energia elétrica totais; (ii) custo da energia elétrica gerada; (iii) emissões totais produzidas; (iv) desvios nas magnitudes das tensões nodais. O fluxo de potência probabilístico baseado na estimação por pontos é aplicado para considerar as seguintes incertezas: erro de previsão de carga e variabilidade na potência de saída da GD eólica. As componentes da função objetivo são combinadas em uma única função usando-se funções de pertinência nebulosas trapezoidais e a minimização do máximo desvio com relação ao valor de referência nebuloso de cada componente. Esta função do problema monobjetivo equivalente é otimizada através de PSO. Nestes artigos, os autores não explicam como a restrição de radialidade é satisfeita durante o processo de otimização.

Andervazh et al. (2013) propuseram uma RRD baseada na teoria multiobjetivo Pareto usando o algoritmo de PSO discreto. Os objetivos minimizados em (Andervazh et al., 2013) são: as perdas de potência, número de operações de chaveamento e os desvios nas magnitudes das tensões nominais com relação aos seus respectivos valores nominais. Estes objetivos foram minimizados sujeito as seguintes restrições: balanço de potência nos nós, limites de carregamento dos circuitos, intervalos para as magnitudes das tensões nodais e radialidade. A restrição de radialidade e outras restrições de igualdade foram modeladas usando-se funções de penalidade estáticas. Heurísticas probabilísticas e técnicas de teoria de grafos foram aplicadas para melhorar a busca

aleatória do algoritmo de forma auto-adaptativa durante o processo de otimização. O conceito de dominância Pareto é usado para guiar a busca em direção ao conjunto Pareto ótimo.

Narimani et al. (2014) apresentam um método para solucionar o problema de RRD multiobjetivo incluindo a presença de GD. A técnica proposta considera a minimização simultânea dos seguintes objetivos: custos de operação da GD, perdas resistivas e confiabilidade. A confiabilidade é inserida na função multiobjetivo através da estimação da energia não fornecida (ENNS – *Expected Energy Not Supplied*) para a rede de distribuição. A adição da confiabilidade como uma das metas da otimização torna o problema de RRD mais complexo e torna-se necessário solucioná-lo com um algoritmo preciso. Portanto, os autores Narimani et al. (2014) usaram um algoritmo de busca gravitacional (GSA – *Gravitational Search Algorithm*) melhorado que usa uma estratégia de mutação especializada para reduzir os tempos de processamento e melhorar a qualidade das soluções impedindo que as soluções candidatas fiquem presas em ótimos locais. Neste artigo, a técnica de fatores de penalidade estáticos é usada para modelar restrições de igualdade, incluindo a de radialidade, e as de desigualdade, tais como os limites de carregamento e de queda de tensão.

A referência (Eldurssi et al., 2015) apresenta uma metodologia de RRD multiobjetivo baseada em um algoritmo genético de classificação não-dominada. Os objetivos considerados pelos autores são: minimização das perdas reais, melhoramento do perfil de tensão, balanceamento de carga e o mínimo número de operações de chaveamento. Se há alguma função objetivo de preferência do ponto de vista prático ou operacional, então a melhor solução é identificada a partir do conjunto de soluções não-dominadas. Caso contrário, se não há uma função objetivo de preferência, a melhor solução é identificada através do valor mínimo da soma normalizada das componentes da função multiobjetivo com relação aos seus respectivos valores mínimos e máximos. A radialidade da topologia da rede é assegurada através da criação da matriz de incidência de ramo-barra e calculando-se o posto (*rank*) desta matriz para cada topologia candidata.

Fard et al. (2015) apresentam uma técnica para melhorar a confiabilidade da rede de distribuição através da reconfiguração da rede elétrica. Uma contribuição do artigo é a modelagem da taxa de falhas dos componentes como função do carregamento. Conseqüentemente, quando o carregamento é reduzido através da reconfiguração a sua

taxa de falha também é diminuída e consequentemente a confiabilidade da rede de distribuição é aumentada. Outro aspecto importante considerado neste artigo é modelagem de incertezas associadas com variações sazonais na carga para um período anual usando-se o método de estimação por pontos. A RRD é formulada como um problema de otimização multiobjetivo cujo objetivo é minimizar os seguintes índices: perdas de energia resistivas, SAIFI (*System Average Interruption Frequency Index*), SAIDI (*System Average Interruption Duration Index*) e AENS (*Average Energy Not Supplied*). Estes objetivos são simultaneamente otimizados usando-se um algoritmo de Busca de Cuco (CSA – *Cuckoo Search Algorithm*) Modificado baseado no conceito de dominância Pareto com funções objetivo normalizadas através do conceito de funções membro nebulosas trapezoidais. A radialidade das soluções candidatas é assegurada através de um processo de retificação/reparo das soluções no qual as malhas são eliminadas pela abertura de ramos até que a condição de radialidade seja satisfeita: o número de arcos em uma árvore para conectar todos os seus vértices deve ser igual ao número de vértices menos um.

Na referência (Paterakis et al., 2016) é apresentada uma metodologia para a RRD que visa determinar a topologia ótima da rede de distribuição que minimiza as perdas de potência ativa e um conjunto de índices de confiabilidade baseados no número de consumidores dos pontos de carga. Os índices de confiabilidade são definidos de forma consistente com um modelo de otimização baseado em programação linear inteira mista. Adicionalmente, as equações de fluxo de potência e as perdas resistivas são linearizadas para se acomodar a este modelo de programação matemática. Devido a isso, há aproximações envolvidas tanto no cálculo das perdas e das tensões como na estimação dos índices de confiabilidade. Por exemplo, as variações sazonais na demanda não são consideradas. Uma vantagem do modelo linearizado é que a restrição de radialidade (o número de arcos em uma árvore para conectar todos os seus vértices deve ser igual ao número de vértices menos um) pode ser inserida diretamente no modelo, pois os status das chaves são variáveis de decisão binárias explicitamente definidas. A principal contribuição do artigo é a aplicação do método de ϵ -restrito usando otimização lexicográfica para resolver o problema de otimização multiobjetivo. Após o conjunto de soluções eficientes Pareto ser gerado, as configurações resultantes são avaliadas usando-se um algoritmo de fluxo de potência para verificar se as soluções obtidas são não-dominadas e compatíveis. Esta avaliação com base no fluxo de potência

iterativo é devido ao fato de que o algoritmo que gerou o conjunto Pareto (ϵ -restrito) se baseia em um modelo linear aproximado da rede de distribuição. Portanto, não há garantia de que as soluções do conjunto Pareto sejam factíveis ou que as perdas sejam precisas com relação ao modelo não-linear original da rede de distribuição. É importante destacar que é necessário realizar esta avaliação a posteriori da geração do conjunto Pareto também para os índices de confiabilidade. Contudo, os autores ignoram os erros envolvidos na estimação dos índices de confiabilidade. O método do ϵ -restrito gera a fronteira Pareto, mas não incorpora preferências do tomador de decisão. Desta forma, um procedimento de tomada de decisão multiatributo, denominado de técnica de ordem de preferência por similaridade a solução ideal, é usado para ordenar as soluções obtidas de acordo com as preferências do tomador de decisões para facilitar a seleção final da solução ótima do conjunto Pareto.

Zare et al. (2018) propuseram uma metodologia para solucionar simultaneamente os problemas de RRD e de alocação de chaves e turbinas eólicas com o objetivo de melhorar a confiabilidade e a eficiência da rede de distribuição. A função multiobjetivo é composta pelas seguintes componentes: perdas resistivas, índice de desvio de tensão, custos de instalação das chaves e custos de confiabilidade baseados nos custos de interrupção das classes consumidoras. Estes objetivos são minimizados sujeito as seguintes restrições, fluxo de potência, limites de tensão e carregamento, número máximo de operações de chaveamento e radialidade. Novamente, a radialidade das soluções é garantida usando-se o procedimento de retificação/reparo das soluções no qual as malhas são eliminadas pela abertura de ramos até que a condição de radialidade seja satisfeita. A técnica proposta se beneficia de um novo algoritmo de otimização multiobjetivo baseado em colônias de abelhas artificiais para fornecer a solução de melhor compromisso entre as metas da otimização.

Na referência (Muhammad et al., 2018) é introduzida uma metodologia para encontrar soluções ótimas para o problema de RRD com baixo custo computacional (tempo de solução moderado). Segundo os autores Muhammad et al. (2018), um dos fatores que tornam a solução do problema de RRD computacionalmente dispendioso, em termos de tempo de solução, é a eliminação de soluções não radiais (topologias com malhas ou componentes isolados) durante o processo de otimização. Desta forma, eles propõem o armazenamento de topologias radiais pré-determinadas da rede em um banco de dados antes do processo de otimização. O banco de dados topológico é criado

aplicando-se transformações elementares baseadas na adição e remoção de um ramo de uma árvore inicial (topologia/configuração do caso base). Estes conjuntos de soluções são usados na RRD através de técnicas de programação evolucionária discreta e PSO evolucionário discreto. Estes métodos de otimização são usados para minimizar uma função multiobjetivo com os seguintes componentes: perdas resistivas, desvio de tensão e número de ações de chaveamento. Estes objetivos são minimizados sujeito as seguintes restrições: fluxo de potência e limites de tensão e carregamento. É importante enfatizar que as restrições de radialidade são relaxadas no modelo de otimização proposto em (Muhammad et al., 2018), pois o espaço de busca pela solução ótima é composto por um banco de dados de topologias radiais.

Shukla et al. (2017) apresentam uma metodologia para a RRD considerando a presença de GD visando minimizar os seguintes objetivos: perdas de potência ativa e o número de operações de chaveamento. Além disso, são maximizadas a margem de estabilidade de tensão e a razão de amortecimento mínima do sistema (estabilidade de pequenos sinais). As soluções Pareto-ótimas para este problema de otimização multiobjetivo são obtidas usando-se um algoritmo evolucionário acionado por ponto de joelho. A radialidade das topologias candidatas é identificada usando-se um algoritmo de processamento topológico de grafos baseado na busca em superfície. Se a radialidade não é preservada a solução candidata não-radial é descartada. Ou seja, a radialidade é mantida usando-se o método da pena de morte para os indivíduos não-radiais.

Raposo et al. (2018) e Raposo et al. (2019a) introduzem metodologias para a redução nas perdas resistivas e melhoria da precisão do estimador de estado através da solução de problemas de otimização multiobjetivo via Algoritmo Genético de Chaves Aleatórias Viciadas e Algoritmo de Colônia de Abelhas Artificiais, respectivamente. Em Raposo et al. (2018) as componentes da função objetivo foram modeladas usando-se funções de pertinência nebulosas. Por outro lado, Raposo et al. (2019a) modelaram os múltiplos critérios a serem otimizados usando a Teoria Pareto. Ambas as metodologias solucionaram de forma conjunta os problemas de alocação de medidores e RRD para a condição de pico de carga considerando-se restrições técnicas do problema de RRD (radialidade, tensão e carregamento) e tolerâncias para a precisão do estimador de estado. Todavia, nenhuma das duas metodologias modelou as flutuações sazonais da carga em um período anual.

A partir da revisão bibliográfica realizada acima pode-se concluir que:

i) Os índices de desempenho da rede de distribuição mais usados na definição da função objetivo são: perdas resistivas (Andervazh et al., 2013; Eldurssi et al., 2015; Fard et al., 2015; Gupta et al., 2010; Malekpour et al., 2013; Muhammad et al., 2018; Narimani et al., 2014; Paterakis et al., 2016; Raposo et al., 2018; ; Raposo et al., 2019a; Shukla et al., 2017; Zare et al., 2018) (100% dos artigos), desvio de tensão (Andervazh et al., 2013; Gupta et al., 2010; Malekpour et al., 2013; Muhammad et al., 2018; Narimani et al., 2014; Zare et al., 2018) (55% dos artigos), número de operações de chaveamento (Andervazh et al., 2013; Eldurssi et al., 2015; Gupta et al., 2010; Muhammad et al., 2018; Shukla et al., 2017) (45% dos artigos) e a confiabilidade (Fard et al., 2015; Narimani et al., 2014; Paterakis et al., 2016; Zare et al., 2018) (36% dos artigos). Outras componentes da função objetivo que são consideradas com menos frequência são: custos de GD (Malekpour et al., 2013; Narimani et al., 2014) e instalação de chaves (Zare et al., 2018), estabilidade (Shukla et al., 2017) e precisão do estimador de estado (Raposo et al., 2018; Raposo et al., 2019a). Conforme mencionado anteriormente, o estimador de estados é um pré-requisito importante para as diversas funções do DMS. No entanto, a inclusão da precisão do estimador na RRD é bastante complexa e recente (Raposo et al., 2018; Raposo et al., 2019a). Devido, a isso há poucas publicações sobre este aspecto da RRD, demonstrando-se a relevância da pesquisa desenvolvida nesta tese.

ii) As restrições típicas consideradas na RRD multiobjetivo são: fluxo de potência, carregamento máximo, limites de tensão e radialidade. Em aplicações mais específicas da RRD, pode-se também encontrar restrições referentes a: estabilidade (Shukla et al., 2017), precisão do estimador (Raposo et al., 2018; Raposo et al., 2019a) e limites de potência ativa e reativa da GD (Malekpour et al., 2013; Narimani et al., 2014).

iii) A restrição típica mais difícil de ser modelada é a de radialidade. Além disso, a técnica de modelagem pode afetar a qualidade da solução (topologia ótima) e tornar mais difícil a adaptação de uma meta-heurística ao problema de RRD. Devido a isto, diversas técnicas tem sido propostas para modelar a restrição de radialidade na RRD e identificar se uma solução candidata é factível (sem malhas ou componentes isolados). As técnicas mais usadas na modelagem da restrição de radialidade e checagem da factibilidade topológica na RRD são: fator de penalidade estático, restrição de igualdade sem função de penalidade (para formulações baseadas em programação matemática), retificação/reparo, penalidade por morte (para formulações baseadas em meta-

heurísticas), banco de dados de topologias radiais, posto da matriz de incidência ramo-barra e desenvolvimento de operadores específicos para otimização de grafos em árvore (para formulações baseadas em meta-heurísticas) e posto da matriz de incidência. As técnicas mais usadas para modelar a restrição de radialidade e para checar a factibilidade topológica são a retificação (36% dos artigos) (Eldurssi et al., 2015; Fard et al., 2015; Gupta et al., 2010; Zare et al., 2018) e a penalidade estática (Andervazh et al., 2013; Narimani et al., 2014) (18% dos artigos). A opção por estas técnicas, principalmente com relação a penalidade estática, é a simplicidade de implementação. Todavia, é importante destacar que as técnicas mais complexas, tais como o banco de dados radial (Muhammad et al., 2018) e os operadores especializados (Raposo et al., 2018; Raposo et al., 2019a), tem potencial para obter soluções de melhor qualidade devido ao processo de busca da solução ótima explorar somente o domínio de soluções topologicamente factíveis.

iv) Os métodos mais usados para a solução do problema de RRD multiobjetivo são: AG (Raposo et al., 2018; Gupta et al., 2010; Eldurssi et al., 2015; Shukla et al., 2017); PSO (Malekpour et al., 2013; Andervazh et al., 2013; Muhammad et al., 2018); o algoritmo de busca gravitacional (Narimani et al., 2014); algoritmo de busca de cuco (Fard et al., 2015); programação matemática (Paterakis et al., 2016) e colônia de abelhas artificiais (Zare et al., 2018; Raposo et al., 2019a). A partir desta lista de métodos, pode-se concluir que a maioria dos artigos aplica algoritmos meta-heurísticos para solucionar o problema de RRD multiobjetivo. Por exemplo, as técnicas mais usadas para obter a topologia ótima da rede de distribuição com uma função objetivo multicritério são o AG (36% das publicações) e o PSO (27% das publicações). Esta escolha é devido ao fato destas técnicas serem capazes de modelar com relativa facilidade funções objetivos complexas (como por exemplo, confiabilidade, estabilidade e precisão do estimador de estado) sem introduzir aproximações no modelo. É importante destacar que existem variantes de meta-heurísticas que estão sendo aplicadas na RRD multiobjetivo, por exemplo: AG com chaves aleatórias viciadas (Raposo et al., 2018; Raposo et al., 2020), PSO discreto evolucionário (Muhammad et al., 2018) e o AG com classificação não-dominada (Shukla et al., 2017). Algumas destas variantes foram descobertas recentemente, tais como AG com chaves aleatórias viciadas e o PSO discreto evolucionário. Elas têm mostrado grande potencial para aplicação em problemas de otimização contínuos e discretos em sistemas de potência, tais como a RRD.

v) Na RRD multiobjetivo os múltiplos critérios da função objetivo tem sido modelados nos algoritmos de otimização enumerados no item (iv) através da aplicação das seguintes técnicas: Funções de Pertinência Nebulosas (Raposo et al., 2018; Gupta et al., 2010; Malekpour et al., 2013; Narimani et al., 2014; Fard et al., 2015); Teoria Pareto com meta-heurísticas (Andervazh et al., 2013; Narimani et al., 2014; Eldurssi et al., 2015; Fard et al., 2015; Shukla et al., 2017); Teoria Pareto com o método ε -restrito (Paterakis et al., 2016); colônia de abelhas artificiais multiobjetivo (Zare et al., 2018; Raposo et al., 2019a) e método de soma ponderada (Muhammad et al., 2018). Desta forma, pode-se concluir que as técnicas mais usadas na modelagem de múltiplos critérios na função objetivo são a Teoria Pareto (55% das publicações) e as Funções de Pertinência Nebulosas (45% das publicações). É importante destacar que existem técnicas híbridas, por exemplo, metodologias que combinam a Teoria Pareto com as Funções de Pertinência Nebulosas (Narimani et al., 2014; Fard et al., 2015). As Funções de Pertinência Nebulosas têm o benefício da simplicidade, pois convertem um problema de otimização multiobjetivo em um problema de otimização monoobjetivo. No entanto, tem a desvantagem de fornecer somente uma única solução ótima. Alternativamente, a Teoria Pareto fornece um conjunto de soluções ótimas, mas requer um procedimento pós-otimização para identificar a melhor solução a partir do conjunto de soluções ótimas com base em algum critério de preferência do tomador de decisão. Este processo de identificação pode ser estruturado através de um Sistema Especialista Nebuloso (SEN).

A revisão bibliográfica realizada acima revelou que a RRD multiobjetivo é uma área de pesquisa bem desenvolvida com preferência para a aplicação de meta-heurísticas para a obtenção da topologia ótima da rede. Este fato demonstra claramente que é possível realizar uma RRD multiobjetivo visando-se otimizar a precisão do estimador de estado e índices de desempenho da rede de distribuição, por exemplo, as perdas resistivas.

É importante destacar que todos os artigos citados sobre RRD multiobjetivo usaram um modelo equilibrado da rede de distribuição para estimar índices de desempenho. Entretanto, a rede de distribuição é desbalanceada por natureza devido ao desequilíbrio das cargas entre as fases e a presença de seções trifásicas e monofásicas/bifásicas em um mesmo alimentador. Estas características exigiriam uma modelagem da rede de distribuição em coordenadas de fase. A modelagem em coordenadas de fase pode ser facilmente incluída nos algoritmos meta-heurísticos

devido a sua flexibilidade para se adaptar ao problema de otimização a ser resolvido. No entanto, há duas dificuldades associadas com a modelagem em coordenadas de fase na RRD multiobjetivo: alto custo computacional devido ao aumento no número de variáveis (três tensões de fase para cada nó) e dificuldade para expandir alguns índices de desempenho de redes de distribuição do domínio de sequência positiva para o de coordenadas de fase, por exemplo: precisão do estimador de estados e estabilidade. Esta última dificuldade é causada pelo fato de que a estabilidade e a estimação de estado foram recentemente incorporadas na análise do desempenho de redes de distribuição devido ao surgimento das redes elétricas inteligentes. Devido a isso, a modelagem equilibrada (sequência positiva) da rede elétrica será usada nesta tese para avaliar a precisão do estimador de estado e calcular as perdas anuais de energia.

1.6 Motivação

No contexto de redes elétricas inteligentes, o DMS tem diversas novas funções, tal como: gerenciamento do sistema de armazenamento de energia (ex: baterias), gerenciamento pelo lado da demanda (corte de carga para reduzir o pico de demanda), despacho de recurso de geração distribuída (solar, eólica, gás, biomassa, etc.) e coordenação do carregamento de veículos elétricos (nos modos residencial e comercial onde o carregamento é realizado em estacionamentos privados). O estimador de estado é um pré-requisito para estas novas funções, pois fornece uma estimativa do estado atual da rede elétrica (a magnitude e o ângulo das tensões nodais complexas) em tempo real a partir de dispositivos de medição instalados na rede elétrica. A coexistência do estimador de estado com outras funções no DMS criará novos requerimentos e desafios para o planejamento da operação da rede de medição. Um destes desafios é assegurar que a acurácia do estimador de estado não seja degradada pela programação da RRD. Se a RRD é realizada sem considerar aspectos de precisão do estimador de estado, então a precisão do estimador será deteriorada por um longo período de tempo (por exemplo, 8760 horas para uma programação anual). Consequentemente, a utilidade e aplicabilidade das ferramentas do DMS dependentes do estimador de estado ficarão comprometidas se a precisão do estimador é ignorada na programação da reconfiguração. Uma estratégia para mitigar problemas de perda de precisão do

estimador de estado devido a programação da RRD é a instalação ou realocação de medidores na rede de distribuição para restaurar a acurácia do estimador de estado. Desta forma, é oportuno desenvolver metodologias e técnicas para realizar uma RRD considerando a alocação simultânea de medidores para resgatar a precisão do estimador de estado.

Após a desregulamentação do setor elétrico, as concessionárias de distribuição deixaram de receber subsídios estatais para realizar o fornecimento de energia elétrica para os consumidores finais. Neste contexto, as concessionárias buscam maximizar seus lucros para assegurar sua sobrevivência em um ambiente competitivo. Esta situação é devido ao fato da ausência de subsídios estatais para tarifas e financiamento de obras de reforço da rede de distribuição no setor elétrico desregulamentado. Uma alternativa para alcançar este objetivo é a redução nas perdas resistivas, também conhecidas como perdas técnicas. Estas perdas podem ser reduzidas de forma bastante eficaz e com custo zero através da reconfiguração, pois este procedimento não requer a instalação de equipamentos. Desta forma, é óbvio que a redução nas perdas terá prioridade sobre a precisão do estimador de estado. Todavia, isto não faz sentido na realidade atual da indústria 4.0 que tem as redes elétricas inteligentes como seu desdobramento no setor elétrico. Neste ambiente de mudanças sem precedentes na comercialização e na distribuição da energia elétrica, o estimador de estado tem importância vital na modernização dos centros de controle de distribuição. A implantação do estimador de estado nos centros de controle de distribuição permitirá alcançar os objetivos de maior consciência operacional e recomposição automática da rede elétrica. Estes objetivos tornaram-se viáveis e necessários para a gestão das redes elétricas atendendo a novas cargas e dispositivos de flexibilização da operação (baterias), bem como um aumento nas capacidades de monitoramento e transmissão de dados nas redes de distribuição. Portanto, as perdas permanecem com alta prioridade na tomada de decisão das concessionárias, mas deve-se assegurar a precisão do estimador com o menor custo possível. Esta ambivalência entre perdas e precisão do estimador de estado evidencia novamente a carência de ferramentas e modelos para obter uma solução concomitante dos problemas de reconfiguração para minimização de perdas e alocação de medidores para maximizar a precisão do estimador de estado.

1.7 Objetivos

O problema de alocação de medidores (definição do plano de medição) é um problema típico do planejamento de longo prazo (escala anual) de redes de distribuição. Por outro lado, a RRD é um problema de operação que pode ser solucionado em horizontes de tempo de curto (diário), médio (semanal) e longo prazo (anual). Em qualquer um destes horizontes de tempos a precisão do estimador de estados pode ser penalizada pela mudança na topologia da rede. Contudo, a revisão bibliográfica sobre RRD demonstrou que a RRD de longo prazo é mais eficaz na prática, pois reduz as perdas de vida útil das chaves e é mais precisa devido a modelagem cronológica da carga e geradores distribuídos baseados em fontes renováveis. Devido a isso, a RRD para minimização das perdas anuais de energia será considerada nesta tese.

Existe uma superposição no período anual entre os problemas de planejamento (programação) da operação referente a RRD e o planejamento da expansão associado com a alocação de medidores. Esta superposição cria uma oportunidade para se explorar as vantagens e os benefícios de uma solução conjunta dos problemas de RRD e alocação de medidores. Por exemplo, aumentar a precisão do estimador de estado sem medidores adicionais com a alteração na topologia. Além disso, a solução conjunta pode evitar efeitos colaterais (indesejados) da solução de um problema sobre outro. Por exemplo, perda de precisão do estimador com a RRD. Devido a isso, a metodologia proposta nesta tese está centrada tanto no planejamento da expansão, com relação a alocação de medidores, como no planejamento (programação) da operação, concernente a RRD.

Desta forma, o principal objetivo desta tese é apresentar uma metodologia para RRD que considera aspectos de precisão do estimador de estado. Os problemas de precisão do estimador de estado serão contornados através da instalação de medidores multifuncionais e multicanais na rede de distribuição. Esta instalação será realizada de forma concorrente com a RRD. Em outras palavras, o paradigma de alocação simultânea a reconfiguração, definido anteriormente, será considerado nesta tese. Deste modo, ao mesmo tempo no qual as chaves são manobradas para obter uma nova topologia, novos medidores são instalados nos nós da rede de distribuição. A alocação simultânea a reconfiguração será realizada utilizando-se uma formulação multiobjetivo, pois foi identificado na revisão bibliográfica que é viável formular e solucionar um

problema de otimização multicritério no contexto da RRD. As componentes da função objetivo que serão minimizadas são:

- i) Perdas anuais de energia;
- ii) Número de medidores: para considerar aspectos de custos de instalação de forma indireta;
- iii) Precisão do estimador de estados: risco máximo de violar os limites para os erros relativos entre os valores estimados e verdadeiros das tensões nodais.

É importante destacar que devido aos custos do sistema de telecomunicação a relação entre o número de medidores e os custos de instalação pode não ser direta. Todavia, o projeto integrado dos sistemas de medição, distribuição de energia e telecomunicações aumenta significativamente a complexidade do problema. Esta complexidade elevada pode tornar a solução com os sistemas integrados inviável mesmo através de algoritmos meta-heurísticos. Desta forma, utilizou-se um modelo simplificado (equivalente) para incluir de forma indireta os custos de instalação dos medidores que se baseia apenas no número de medidores instalados.

Estas componentes da função objetivo foram minimizadas considerando-se as seguintes restrições: (i) intervalo de variação das magnitudes das tensões nodais; (ii) carregamento dos circuitos; (iii) valor máximo para o risco do erro relativo entre valores estimados e verdadeiros das tensões nodais; (iv) balanço de potência ativa e reativa nas barras; (v) radialidade.

O problema de otimização descrito acima é resolvido usando-se uma meta-heurística baseada no algoritmo genético de chaves aleatórias viciadas (BRKGA – *Biased Random-Key Genetic Algorithm*) (Gonçalves e Resende, 2011). Essa abordagem produz uma fronteira de Pareto relacionada ao problema de alocação de medidores para cada topologia ótima gerada pela RRD. As soluções mais econômicas na fronteira de Pareto serão selecionadas para todos os patamares de carga. No caso de haver uma topologia ótima para cada agrupamento de carga, a alocação ótima para o período anual é definida a partir de um SEN que seleciona o plano de medição com base em dois critérios: número mínimo de medidores e menor risco de violação dos limites para os erros relativos de magnitude e fase da tensão.

A metodologia proposta para alocação de medidores e RRD tem potencial de aplicação no planejamento da operação da rede de distribuição de longo prazo (base anual). A programação da RRD para um período anual tem como objetivo minimizar as perdas de energia com a utilização de diversas topologias para considerar variações sazonais na carga. Esta programação será realizada considerando-se um plano de medição previamente definido para a condição do caso base (topologia original). Após a programação da reconfiguração ser definida, verifica-se se a precisão do estimador de estado foi comprometida pela alteração na topologia. Caso afirmativo, realiza-se uma alocação de medidores em conjunto com a reconfiguração para recuperar a precisão do estimador de estado. Caso contrário, as topologias definidas serão implementadas sem a necessidade de instalar medidores adicionais. A Figura 1.2 ilustra o procedimento descrito acima para a RRD e alocação de medidores. Esta estratégia está em conformidade com práticas de planejamento das empresas de distribuição e transmissão. Por exemplo, a primeira alternativa para enfrentar um novo cenário de operação é não realizar nenhuma ação corretiva se as consequência do cenário não são severas. Esta opção é devido à ausência de custos quando nenhuma ação corretiva é realizada. Na seção de resultados, serão descritos em detalhes casos de estudo que consideram a estratégia acima na RRD com restrições de precisão do estimador de estados.

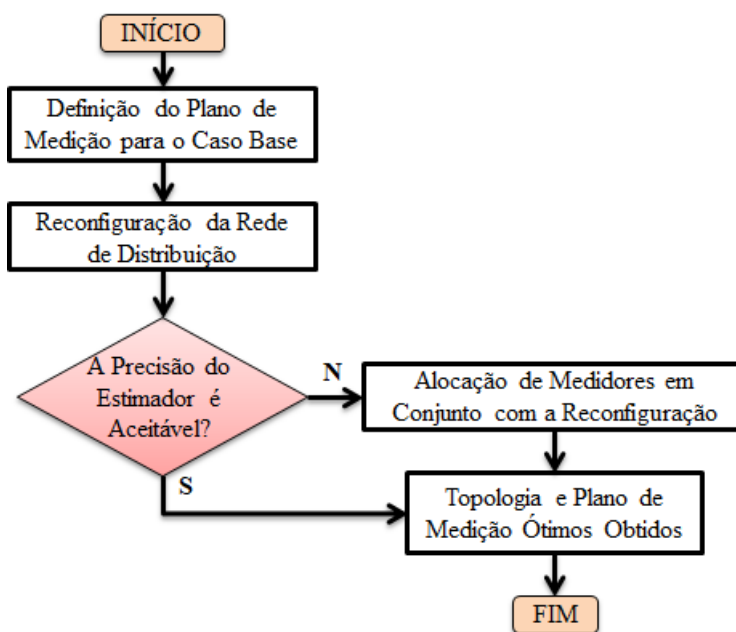


Figura 1.2: Estratégia proposta para alocação de medidores em conjunto com a reconfiguração.

A técnica proposta para a solução conjunta dos problemas de alocação de medidores e RRD se baseia na metodologia Pareto. Esta metodologia fornece um conjunto de soluções caracterizadas pelas três componentes da função objetivo: perdas anuais de energia, precisão e número de medidores (que representa de forma implícita o custo). Desta forma, o engenheiro de planejamento poderá selecionar topologias e planos de medições alternativos ao original se a RRD sem restrições de precisão resultar em perdas de precisão significativas para o estimador de estado. Na seção de resultados, será mostrado o conjunto de topologias e os planos de medição gerados pela Teoria Pareto e como a solução ótima é identificada a partir deste conjunto com base em critérios especificados pelo tomador de decisão.

1.8 Contribuições da Tese

As principais contribuições resultantes desta tese são:

- i) O desenvolvimento de uma metodologia para a solução concomitante dos problemas de minimização de perdas de energia via RRD e maximização da precisão do estimador através da alocação de medidores. Esta metodologia evitará a degradação da precisão do estimador de estado pela RRD.
- ii) Técnica analítica para avaliar a precisão do estimador de estados considerando-se nós de injeções nulas. A importância desta técnica é devido ao fato de que o número de nós de injeções nulas (nós de passagem) em redes de distribuição é muito elevado. Esta característica é devido ao fato de que geralmente os alimentadores são roteados através das vias públicas. Consequentemente, a distância entre o ponto de fornecimento e a carga nem sempre corresponde a menor distância entre dois pontos.
- iii) Proposição de uma versão multiobjetivo do BRKGA. Originalmente, o BRKGA foi formulado para problemas de otimização monobjetivos. A extensão do BRKGA para problemas multiobjetivo permitirá que este método de otimização seja aplicado em diversos problemas de planejamento da expansão e da operação de redes de distribuição que frequentemente envolvem objetivos técnicos e econômicos.
- iv) Introdução de uma nova codificação das soluções candidatas para a solução do problema de RRD via BRKGA. Os operadores canônicos de crossover e mutação dos

algoritmos genéticos não foram projetados para a solução de problemas de otimização com restrições topológicas de radialidade. Portanto, a aplicação direta destes operadores em problemas com restrições de radialidade causaria uma ocorrência elevada de indivíduos inactiváveis (redes com malhas e ilhamentos) na população. Esta ocorrência reduziria a qualidade das soluções obtidas e aumentaria o custo computacional devido a necessidade de identificar e reparar ou penalizar indivíduos inactiváveis. Portanto, a proposição de operadores customizados para problemas com restrições de radialidade melhora a qualidade e o desempenho do BRKGA. Além disso, pode-se aplicar o BRKGA proposto nesta tese em outros problemas de otimização de redes de distribuição com restrições de radialidade, por exemplo: roteamento de alimentadores e restauração.

1.9 Estrutura da Tese

Esta tese está dividida em 8 capítulos:

Capítulo 1: Contém uma introdução geral e a revisão bibliográfica dos trabalhos relacionados com RRD, alocação de medidores para múltiplas topologias e RRD multiobjetivo.

Capítulo 2: Descreve a técnica de Mínimos Quadrados Ponderados Não-Linear, baseada no Método de Gauss-Newton, usada para estimar o estado da rede de distribuição.

Capítulo 3: Apresenta uma descrição da avaliação da precisão do estimador de estado para redes de distribuição com um número significativo de nós de injeções nulas.

Capítulo 4: Mostra formulações monobjetivo dos problemas de RRD e alocação de medidores para múltiplos patamares de carga consideradas nesta tese.

Capítulo 5: Apresenta uma descrição genérica do BRKGA usado para solução do problema de RRD monobjetivo (minimização de perdas). Também, é mostrado como as restrições de radialidade são modeladas no BRKGA.

Capítulo 6: Descreve o paradigma multiobjetivo usado na RRD com alocação de medidores: teoria Pareto. Adicionalmente, esta seção mostra a versão multiobjetivo do BRKGA proposta para a RRD considerando a alocação de medidores.

Capítulo 7: Apresenta os resultados dos testes obtidos com o método proposto para realizar a RRD e alocação de medidores na rede de distribuição de 69 barras e 73 ramos proposta por (Baran e Wu, [1989a](#); Savier e Das, [2007](#)).

Capítulo 8: Apresenta um breve resumo do trabalho realizado e também sugestões para trabalhos futuros.

ESTIMAÇÃO DE ESTADO VIA MÉTODO DE MÍNIMOS QUADRADOS PONDERADOS NÃO-LINEAR

2.1 Introdução

Muitas funções que compõem o DMS, tais como otimização volt-var e análise de fluxo de carga, necessitam do estado estimado do sistema. Consequentemente, a estimação de estado tem grande importância para a operação segura do sistema de energia elétrica. Como já foi dito, o principal objetivo do estimador de estado é fornecer, de forma coerente e confiável, uma estimativa de todas as grandezas do sistema elétrico de potência. Esta tarefa é feita a partir de telemidas redundantes (geralmente a magnitude das tensões nas barras, injeções de potência nas barras, fluxos de potência e/ou de corrente nos circuitos) que são pré-filtradas para evitar que a estimação de estado seja realizada com medidas portadoras de erros grosseiros.

Matematicamente, o estimador de estado é uma ferramenta capaz de determinar a melhor estimativa de um conjunto de variáveis de estado que determina a condição operativa do sistema (Costa e Salgado, 2018). Tanto em sistemas de transmissão quanto em sistemas de distribuição, o conjunto de variáveis de estado a ser determinado, geralmente, é a tensão complexa em cada barra do sistema. Isso porque a partir do estado estimado é possível determinar outras variáveis necessárias para a análise e monitoramento do sistema, tais como: fluxos de potência nos circuitos, correntes nas linhas, injeções de potência nas barras, etc. Todavia, duas considerações na modelagem do problema de estimação de estado devem ser feitas:

- **Variação de carga:** assume-se que as cargas variem lentamente em intervalos de tempo pré-especificados, ou seja, considera-se o estado do sistema em regime permanente, invariante no tempo. Isso significa que não é necessário modelar a evolução temporal do estado, desconsiderando-se informações sobre o comportamento do sistema em instantes anteriores.

- **Número de medições:** para garantir a observabilidade da rede a quantidade de medições deve ser maior ou igual à quantidade de variáveis de estado. Isso garante a obtenção do estado, pois o sistema de equações lineares resultante fica sobredeterminado.

As considerações sobre a variação de carga não podem ser assumidas para os estimadores sequenciais. Estimadores sequenciais levam em consideração o comportamento dinâmico do sistema. Neste sentido, a técnica utilizada para caracterizar o comportamento dinâmico do sistema baseia-se no filtro de Kalman. Devido à complexidade de implementação, esta técnica tem sido empregada com algumas simplificações, ou mesmo substituída por métodos ortogonais baseados nas rotações de Givens.

2.2 Classificação dos Estimadores de Estado

As principais diferenças entre os métodos de estimação de estado são: a formulação do problema; o processamento dos dados e; o algoritmo utilizado na resolução do problema formulado. Na formulação analítica do problema, a técnica mais utilizada é baseada na minimização da soma ponderada dos quadrados dos resíduos, ou seja, são os estimadores do tipo Mínimos Quadrados Ponderados (MQP). Entretanto, modelagens alternativas baseadas na minimização da soma dos valores absolutos dos resíduos também são encontradas na literatura – estimadores do tipo Mínimos Valores Absolutos Ponderados (MVAP). Quanto ao modo de processar os dados, os estimadores de estado podem ser de dois tipos: *batch*, no qual as medidas disponíveis são processadas simultaneamente e *sequenciais*, em que as quantidades medidas são processadas uma por vez (Costa e Salgado, 2018).

Existe uma gama de algoritmos de otimização que podem resolver o problema de mínimos quadrados ponderados para estimadores do tipo *batch*. Todavia, devido às características particulares deste problema, o processo iterativo para a determinação do estado baseia-se nos seguintes métodos:

- solução via equação normal (método clássico);

- uso de métodos ortogonais (reflexões de Householder, rotações de Givens, etc);
- aplicação de métodos híbridos (fatoração ortogonal combinada a solução do sistema linear não-ortogonal);
- solução através do método de Hachtel (também conhecido como método da matriz aumentada ou *tableau* esparso);
- exploração do desacoplamento $P\delta - QV$ (estimadores desacoplados).

Quanto aos estimadores *sequenciais*, já foi visto que a solução recursiva de mínimos quadrados pode ser obtida através do filtro de Kalman ou através de métodos ortogonais baseados nas rotações de Givens. Para mais detalhes sobre esta teoria as referências Monticelli (1999), Abur e Expósito (2004) ou Lewis et al. (2008) podem ser consultadas.

Os estimadores de estado usados em redes de transmissão e distribuição também podem ser classificados com relação aos tipos de variáveis de estado e medições utilizadas. Esta classificação é definida abaixo (Silva et al., 2018):

i) Estimadores convencionais: bastante conhecidos e aplicados em sistemas de transmissão. Nestes estimadores as variáveis de estado são o ângulo e a magnitude das tensões nodais. As medições utilizadas nos estimadores convencionais são: a magnitude da tensão, fluxos de potência nos ramos e as injeções de potência nodais.

ii) Estimadores de estado baseados na matriz admitância de barra: são mais usados em redes de distribuição e consideram as partes reais e imaginárias das tensões nodais complexas como variáveis de estado. Nestes estimadores as medições de magnitude da tensão e potências são convertidas em tensões e correntes complexas equivalentes. As partes reais e imaginárias destas tensões e correntes equivalentes são usadas para formar o vetor de medições equivalente.

iii) Estimadores de estado baseados nas correntes de ramo: similares aos estimadores baseados na matriz de admitância. Nestes estimadores as partes reais e imaginárias das correntes complexas nos ramos são adotadas como variáveis de estado. Adicionalmente, as partes real e imaginária das tensões complexas são também incluídas no vetor de variáveis de estado.

Os índices de precisão considerados nesta tese para se avaliar a precisão do estimador de estado se baseiam em erros relativos associados com as magnitudes e os

ângulos das tensões nodais complexas. Desta forma, o estimador de estado convencional é o mais adequado para a proposta desta tese.

2.3 Método de Gauss-Newton com Medições Descorrelacionadas

Considere o conjunto de m medições dado pelo vetor z :

$$z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{bmatrix} = \begin{bmatrix} h_1(x_1, x_2, \dots, x_n) \\ h_2(x_1, x_2, \dots, x_n) \\ \vdots \\ h_m(x_1, x_2, \dots, x_n) \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_m \end{bmatrix} = h(x) + e_z \quad (2.1)$$

em que:

$$h^T = [h_1(x), h_2(x), \dots, h_m(x)];$$

$h_i(x)$: é a função não-linear associada com o valor calculado da medição i para o vetor de estado x ;

$x^T = [x_1, x_2, \dots, x_n]$: é o vetor de estado do sistema, e;

$e_z^T = [e_1, e_2, \dots, e_m]$: é o vetor de erros das medições.

As seguintes hipóteses são consideradas com relação aos erros de medição:

- i) $E(e_i) = 0$, para $i = 1, \dots, m$;
- ii) Os erros das medições são independentes, isto é, $E[e_i e_j] = 0$. Por conseguinte, $Cov(e_z) = E[e_z \cdot e_z^T] = R_z = diag\{\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2\}$.

O desvio padrão σ_i da cada medição i é calculado para refletir a precisão esperada do correspondente medidor utilizado. A matriz R_z é a matriz de covariância das medições. O estimador que utiliza o MQP reduzirá a função objetivo dada em (2.2).

$$J(x) = \sum_{i=1}^m \frac{[z_i - h_i(x)]^2}{R_{ii}} = [z - h(x)]^T R_z^{-1} [z - h(x)] \quad (2.2)$$

No ponto de mínimo de (2.2), as condições de optimalidade de primeira ordem devem ser satisfeitas. Na forma compacta, isso pode ser expresso através de (2.3):

$$g(x) = \frac{\partial J(x)}{\partial x} = -H^T(x)R_z^{-1}[z - h(x)] = 0 \quad (2.3)$$

no qual $H(x) = \left[\frac{\partial h(x)}{\partial x} \right]$ é a matriz Jacobiana associada com o vetor $h(x)$.

Expandindo a função não-linear $g(x)$ através da série de Taylor em torno do vetor de estado $x^{(k)}$:

$$g(x) = g(x^{(k)}) + G(x^{(k)})(x - x^{(k)}) + \dots = 0 \quad (2.4)$$

Desprezando-se os termos de segunda ordem e utilizando-se o Método iterativo de Gauss-Newton (MGN), tem-se:

$$x^{(k+1)} = x^{(k)} - [G(x^{(k)})]^{-1} \cdot g(x^{(k)}) \quad (2.5)$$

em que:

k : é o contador de iteração;

$x^{(k)}$: é o vetor solução para a iteração k ;

$g(x^{(k)}) = -H^T(x^{(k)}) \cdot R_z^{-1} \cdot [z - h(x^{(k)})]$, e;

$$G(x^{(k)}) = \frac{\partial g(x^{(k)})}{\partial x} = H^T(x^{(k)}) \cdot R_z^{-1} \cdot H(x^{(k)}) \quad (2.6)$$

A matriz $G(x)$ é denominada *Matriz Ganho* ou *Matriz de Informação*. A matriz R_z é diagonal. Por esta razão, a matriz $G(x)$ é aproximadamente duas vezes mais densa do que a matriz $H(x)$. Por outro lado, a matriz $H(x)$ é esparsa e, portanto, a matriz de informação também possui um número reduzido de elementos não-nulos, o que possibilita o uso de técnicas de esparsidade. Adicionalmente, $G(x)$ é simétrica e positiva definida, o que facilita sua fatoração. Com a fatoração de $G(x)$, o vetor solução

pode ser obtido a cada iteração k através da substituição progressiva/regressiva (*forward/backward*) de acordo com (2.7):

$$[G(x^{(k)})] \cdot \Delta x^{(k+1)} = H^T(x^{(k)}) \cdot W \cdot \Delta z^{(k)} \quad (2.7)$$

em que: $\Delta x^{(k+1)} = x^{(k+1)} - x^{(k)}$, $W = R_z^{-1}$ e $\Delta z^{(k)} = [z - h(x^{(k)})]$.

A equação (2.7) é denominada *Equação Normal* e representa o sistema linear a ser resolvido a cada iteração para a determinação do incremento do vetor de estado Δx . O problema representado em (2.7) possui tendência a um mau-condicionamento numérico, implicando em problemas de convergência ou instabilidade numérica (D.-García et al., 2011). Isto pode ser verificado analisando-se o número de condicionamento da matriz ganho. O número de condicionamento espectral de uma matriz não-singular A é definido segundo (2.8).

$$Cond(A) := \frac{\lambda_{max}}{\lambda_{min}} \quad (2.8)$$

em que, λ_{max} e λ_{min} são o máximo e o mínimo autovalores da matriz A .

Outra forma de avaliar o número de condicionamento de uma matriz não-singular A é dado por:

$$\kappa_p(A) := \|A\|_p \cdot \|A^{-1}\|_p \quad (2.9)$$

em que p é o índice de uma norma induzida ou subordinada a uma norma vetorial, isto é: norma de máxima magnitude ($p = \infty$), norma de soma das magnitudes ($p = 1$) ou a norma euclidiana ($p = 2$).

As equações (2.8) e (2.9) medem o quanto pequenas perturbações na matriz A afetam a precisão da solução x do sistema linear $Ax = b$. Quando o número de condicionamento é muito alto, pequenas perturbações na matriz A ou no vetor b produzirão grandes perturbações no vetor solução x . Em aplicações no sistema de potência, como estimação de estado, o número de condicionamento deverá ser menor ou igual a 10^{12} (D.-García et al., 2011). Para a equação normal, pode-se provar que

$Cond(H^T H) = [Cond(H)]^2$, ou seja, se H não é bem condicionada, G estará altamente mal condicionada (a condição numérica de G é igual ao quadrado da condição numérica da matriz Jacobiana H). As principais fontes de mau-condicionamento numérico de (2.7) são:

- Conexão de ramos que possuem impedâncias elevadas com ramos de impedância pequenas;
- Grande quantidade de medições de injeção;
- Nós de injeções nulas (medições fictícias).

Para viabilizar a EERD geralmente utiliza-se um grande número de pseudo-medições que são adicionadas ao plano de medição existente para assegurar a observabilidade. Como consequência, a precisão do estado estimado é comprometida devido ao fato de que os erros associados com as pseudo-medições são consideravelmente maiores do que aqueles referentes às medições reais e o condicionamento da matriz de informação é deteriorado. Adicionalmente, os nós de injeções nulas são modelados como medições fictícias de alta precisão. Desta forma, estas barras são incluídas no problema de estimação de estado atribuindo a elas um baixo desvio padrão (entre 10^{-8} e 10^{-4}). Esta modelagem também degrada o número de condição da matriz de ganho.

Devido a estas características, o algoritmo utilizado neste trabalho para estimar o estado da rede elétrica faz uso da fatoração QR da matriz ganho, ao invés de utilizar a decomposição de Cholesky.

2.4 Algoritmo de Estimação de Estado via Método de Gauss-Newton

Nesta seção é sumarizado o algoritmo utilizado para estimar o estado da rede de distribuição. Primeiramente a equação (2.7) pode ser reescrita, omitindo-se o contador de iteração k , de acordo com (2.10):

$$\underbrace{H^T W H}_G \cdot \Delta x = H^T \cdot W \cdot \Delta z \quad (2.10)$$

A matriz W é simétrica e positiva definida, logo W pode ser fatorada pela decomposição de Cholesky, com $W = DD^T$. Uma maneira de mitigar problemas de convergência ou instabilidade numérica devido ao mal condicionamento da matriz G é o uso da fatoração ortogonal. A fim de aplicar a fatoração ortogonal ao problema de estimação de estado via MQP, a equação normal (2.10) é reescrita na forma compacta:

$$\underbrace{\tilde{H}^T \tilde{H}}_G \cdot \Delta x = \tilde{H}^T \cdot \Delta \tilde{z} \quad (2.11)$$

em que:

$$\tilde{H} = D^T H \quad (2.12)$$

$$\Delta \tilde{z} = D^T \Delta z \quad (2.13)$$

Fatorando \tilde{H} através da decomposição QR, tem-se $\tilde{H} = QR$. Usando a propriedade $QQ^T = I$, (2.11) pode ser transformada sucessivamente em:

$$R \cdot \Delta x = Q^T \cdot \Delta \tilde{z} \quad (2.14)$$

Em suma, cada iteração da estimação de estado via MGN utilizando a decomposição QR consiste nos seguintes passos:

Passo #1: Determinar a estrutura da matriz Jacobiana $H(x)$;

Passo #2: Obter a decomposição de Cholesky da matriz W ($W = DD^T$);

Passo #3: Arbitrar uma estimativa inicial para o vetor de estados $\hat{x}^{(0)}$;

$k = 0$;

Passo #4: Calcular os valores numéricos de $\tilde{H} = D^T H(\hat{x}^{(k)})$ e $\Delta \tilde{z} = D^T [z - h(\hat{x}^{(k)})]$;

Passo #5: Fatorar a matriz $\tilde{H} = QR$;

Passo #6: Atribuir $\Delta z_q = Q^T \Delta \tilde{z}$ e resolver o sistema linear $R \Delta x^{(k)} = \Delta z_q$ por substituição regressiva;

Passo #7: Verificar a convergência: se $\max |\Delta x^{(k)}| \leq \epsilon$ (em geral $\epsilon = 10^{-4}$ pu), parar o processo iterativo, caso contrário, atualizar o vetor de estados $\hat{x}^{(k+1)} = \hat{x}^{(k)} + \Delta x^{(k)}$.

Passo #8: Fazer $k = k + 1$. Se $k > N_{iter}$ (N_{iter} é o máximo número de iterações), parar o processo iterativo, caso contrário, voltar ao passo #4.

A partir dos passos acima, fica evidente que não é necessário obter e fatorar a matriz ganho G . Além disso, a fatoração QR é numericamente mais estável do que a fatoração de Cholesky. Portanto, a utilização de pesos muito elevados para medições fictícias associadas com nós de injeções nulas não gera nenhum problema de instabilidade numérica. Os passos do MGN são ilustrados através do fluxograma da Figura 2.1.

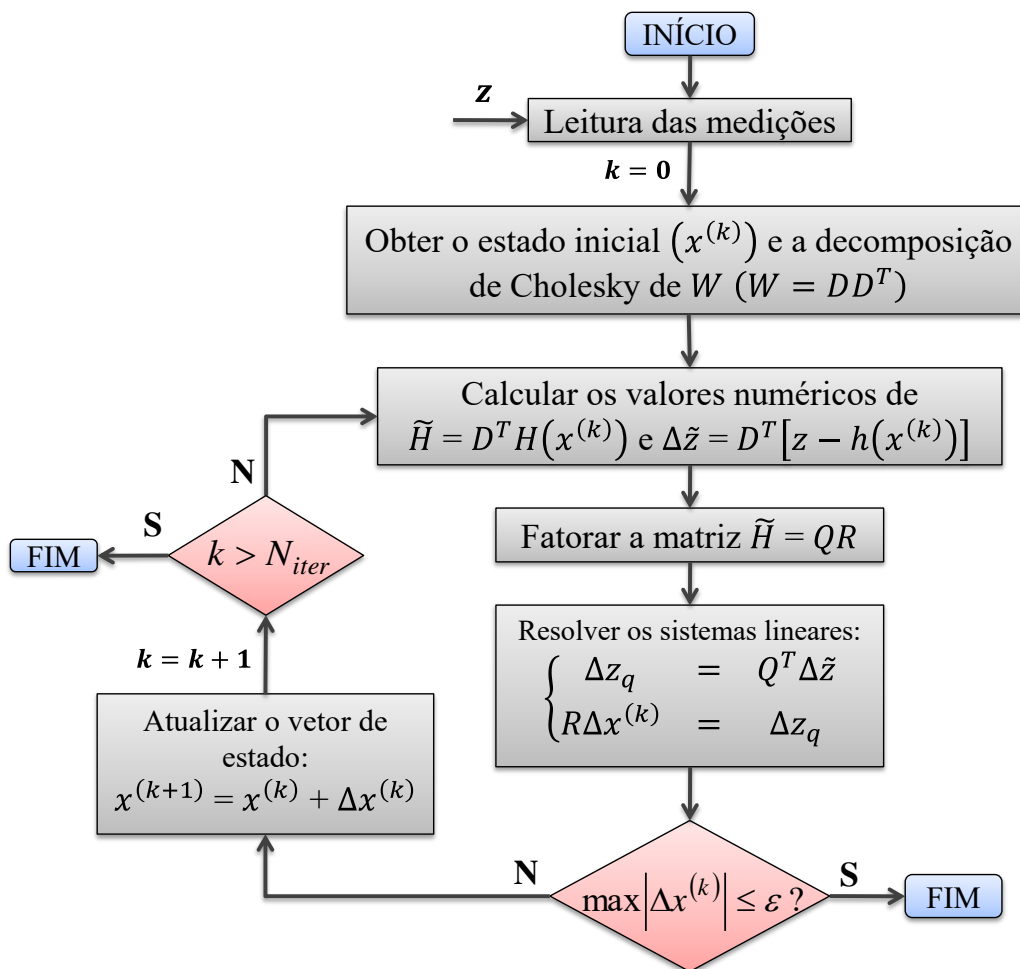


Figura 2.1: Método de Gauss-Newton para estimação de estado.

2.5 Funções de Medição e Estrutura da Matriz Jacobiana H

Nesta seção são descritas as funções não-lineares associadas a cada tipo de medição, bem como a estrutura da matriz Jacobiana H considerando-se o módulo e a fase da tensão em cada barra do sistema como variáveis de estado. As expressões para cada tipo de medição (injeção/fluxo de potência e tensão) são dadas abaixo assumindo-se o modelo π da linha ilustrado na Figura 2.2.




Figura 2.2: Modelo π da linha.

2.5.1 Funções de medição $h(x)$

- Injeções de potência ativa, P_i^{inj} , e reativa, Q_i^{inj} , na barra i :

$$P_i^{inj} = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.15)$$

$$Q_i^{inj} = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) \quad (2.16)$$

- Fluxo de potência ativa, P_{ij}^{FP} , e reativa, Q_{ij}^{FP} , da barra i para a barra j :

$$P_{ij}^{FP} = V_i^2 (g_{si} + g_{ij}) - V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.17)$$

$$Q_{ij}^{FP} = -V_i^2 (b_{si} + b_{ij}) - V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.18)$$

em que:

V_i e θ_i é a magnitude e a fase da tensão na barra i , respectivamente;

$\theta_{ij} = \theta_i - \theta_j$ é a diferença angular do ramo ij ;

$G_{ij} + jB_{ij}$ é o ij -ésimo elemento da matriz de admitância complexa;

$g_{ij} + jb_{ij}$ é a admitância da linha ij ;

$g_{si} + jb_{si}$ é a admitância do elemento *shunt* conectado na barra i ;

Ω_i é o conjunto de barras que estão diretamente conectadas à barra i .

Os métodos de alocação de medidores basearam-se em uma metodologia que utiliza apenas medições de tensão, injeção e fluxo de potência. Por esta razão, omitiu-se as funções associadas à corrente no ramo ij , assim como da estrutura da matriz Jacobiana $H(x)$. Para maiores detalhes sobre as equações de corrente sugere-se consultar Monticelli (1999) ou Abur e Expósito (2004).

2.5.2 Estrutura da matriz Jacobiana H

A matriz Jacobiana associada às funções de medição tem a seguinte estrutura:

$$H = \begin{bmatrix} \frac{\partial P^{inj}}{\partial \theta} & \frac{\partial P^{inj}}{\partial V} \\ \frac{\partial Q^{inj}}{\partial \theta} & \frac{\partial Q^{inj}}{\partial V} \\ \frac{\partial P^{FP}}{\partial \theta} & \frac{\partial P^{FP}}{\partial V} \\ \frac{\partial Q^{FP}}{\partial \theta} & \frac{\partial Q^{FP}}{\partial V} \\ \frac{\partial P}{\partial \theta} & \frac{\partial P}{\partial V} \\ 0 & \frac{\partial V^{mag}}{\partial V} \end{bmatrix} \quad (2.19)$$

As expressões para cada partição da matriz H são dadas abaixo:

- Elementos correspondendo a medições de injeção de potência ativa na barra i :

$$\frac{\partial P_i^{inj}}{\partial \theta_i} = -V_i^2 B_{ii} + \sum_{j=1}^N V_i V_j (-G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) \quad (2.20)$$

$$\frac{\partial P_i^{inj}}{\partial \theta_j} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.21)$$

$$\frac{\partial P_i^{inj}}{\partial V_i} = V_i G_{ii} + \sum_{j=1}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.22)$$

$$\frac{\partial P_i^{inj}}{\partial V_j} = V_i (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.23)$$

- Elementos correspondendo a medições de injeção de potência reativa na barra i :

$$\frac{\partial Q_i^{inj}}{\partial \theta_i} = -V_i^2 G_{ii} + \sum_{j=1}^N V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.24)$$

$$\frac{\partial Q_i^{inj}}{\partial \theta_j} = -V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.25)$$

$$\frac{\partial Q_i^{inj}}{\partial V_i} = -V_i B_{ii} + \sum_{j=1}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.26)$$

$$\frac{\partial Q_i^{inj}}{\partial V_j} = V_i (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.27)$$

- Elementos correspondendo a medições de fluxo de potência ativa no ramo ij :

$$\frac{\partial P_{ij}^{FP}}{\partial \theta_i} = V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.28)$$

$$\frac{\partial P_{ij}^{FP}}{\partial \theta_j} = -V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.29)$$

$$\frac{\partial P_{ij}^{FP}}{\partial V_i} = -V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) + 2V_i (b_{ij} + b_{si}) \quad (2.30)$$

$$\frac{\partial P_{ij}^{FP}}{\partial V_j} = -V_i (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.31)$$

- Elementos correspondendo a medições de fluxo de potência reativa no ramo ij :

$$\frac{\partial Q_{ij}^{FP}}{\partial \theta_i} = -V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.32)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial \theta_j} = V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.33)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial V_i} = -V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) - 2V_i (b_{ij} + b_{si}) \quad (2.34)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial V_j} = -V_i (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.35)$$

- Elementos correspondendo a medições de magnitude de tensão na barra i :

$$\frac{\partial V_i^{mag}}{\partial \theta_i} = 0 \quad (2.36)$$

$$\frac{\partial V_i^{mag}}{\partial \theta_j} = 0 \quad (2.37)$$

$$\frac{\partial V_i^{mag}}{\partial V_i} = 1 \quad (2.38)$$

$$\frac{\partial V_i^{mag}}{\partial V_j} = 0 \quad (2.39)$$

2.6 Método de Gauss-Newton com Medições Correlacionadas

O algoritmo utilizado para estimar o estado da rede de distribuição com medições de potência ativa e reativa correlacionadas, tanto injeções quanto fluxos, é análogo ao algoritmo proposto no início do capítulo. A única diferença está na estrutura da matriz de covariância de medições R_z . Considera-se R_z^{corr} , matriz de covariância de erros de medição correlacionados, com a seguinte estrutura (Raposo, 2016):

σ_k^V para $k = 1, \dots, N_V$ é o desvio padrão do k -ésimo medidor de magnitude das tensões;
 N_V é o número de medidores de magnitudes das tensões.

A inversa de uma matriz diagonal por blocos é a inversa dos blocos que compõem a matriz. Como considera-se apenas correlação entre medições de potência ativa e reativa para um dado medidor, há somente blocos de dimensão 2x2, formados pelas medições de injeção/fluxo de potência ativa e reativa, e blocos 1x1, formados por medições de magnitudes de tensão. Deste modo, a matriz inversa de R_z^{corr} , W^{corr} , fica completamente definida pela inversão por blocos de R_z^{corr} . W^{corr} , então, terá a mesma estrutura de R_z^{corr} .

AVALIAÇÃO DA PRECISÃO DO ESTIMADOR DE ESTADO PARA REDES DE DISTRIBUIÇÃO

3.1 Introdução

A avaliação da precisão do estimador de estado é realizada usando-se técnicas de propagação de incertezas baseadas na SMC ou em métodos analíticos. A SMC tem a vantagem da simplicidade na implementação, mas ela é computacionalmente dispendiosa. Desta forma, os métodos analíticos têm maior preferência com relação a SMC particularmente em aplicações associadas com otimização, tais como a RRD multiobjetivo. Nas referências (Raposo, 2016) e (Raposo et al., 2017) foi desenvolvido um método analítico para analisar a precisão do estimador de estado baseado na linearização das condições de optimalidade da função objetivo do método de mínimos quadrados ponderados. Esta técnica permite a modelagem de correlação entre as medições de potência ativa e reativa. No entanto, o método proposto por Raposo (2016) e Raposo et al. (2017) só pode ser aplicada para redes de distribuição com um pequeno número de nós de injeções nulas. Esta limitação é devido ao fato de que os nós de injeções nulas foram modelados usando-se medições fictícias de injeção de potência ativa e reativa com alta precisão (desvios padrões muito pequenos). Consequentemente, podem ocorrer problemas de mau-condicionamento numérico no cálculo da matriz de sensibilidade do modelo linearizado usado na propagação de incertezas. Nesta tese, é proposta uma metodologia para contornar este problema na qual os nós de injeções nulas são explicitamente modeladas no problema de estimação de estados através de restrições de igualdade. Desta forma, o problema de estimação de estados fica relacionado com um problema de programação não-linear com restrições de igualdade. Novamente, as condições de optimalidade deste problema são linearizadas para obter um modelo linearizado para propagação das incertezas que é usado na análise da acurácia do estimador de estado. A seção 3.2 deste capítulo mostra como o estado do sistema é determinado via método de Gauss-Newton com restrições de igualdade. A

seção 3.3 apresenta os métodos de linearização e avaliação da precisão do estimador de estado.

3.2 Estimador de Estado via MQP Baseado no MGN com Restrições de Igualdade para Modelagem de Nós de Injeções Nulas

A utilização de pesos elevados (desvio padrão muito pequeno) para elevar a precisão de medições virtuais, tais como, nós de injeções nulas, levam ao mau condicionamento da matriz de informação G , implicando em problemas de convergência do processo iterativo referente ao MGN (D.-García et al., 2011). Buscando-se mitigar este problema, as medições virtuais são modeladas como restrições de igualdade no método de MQP. Esta modelagem é atrativa, pois as redes de distribuição, diferentemente dos sistemas de transmissão, possuem um elevado número de nós de injeções de potência nulas. Dessa forma, o método de MQP com restrição de igualdade pode ser formulado como a seguir (Abur e Expósito, 2004):

$$\begin{aligned} \min \quad & J(x) = \frac{1}{2} [z - h(x)]^T R_z^{-1} [z - h(x)] \\ \text{sujeito a:} \quad & c(x) = 0 \end{aligned} \quad (3.1)$$

em que $c(x) = 0$ representa o vetor de medições virtuais, as quais são excluídas de $h(x)$. Estas medições virtuais são associadas com os nós de injeções de potência ativa e reativa nulas.

O problema (3.1) pode ser resolvido através do método de Lagrange, no qual o Lagrangeano é dado por:

$$\mathcal{L}(x, \lambda) = J(x) - \lambda^T c(x) \quad (3.2)$$

As condições de optimalidade de primeira ordem da função Lagrangeano definida em (3.2) são dadas por:

$$\begin{aligned} \frac{\partial \mathcal{L}(x, \lambda)}{\partial x} = 0 &\Rightarrow H^T W [z - h(x)] + C^T \lambda = 0 \\ \frac{\partial \mathcal{L}(x, \lambda)}{\partial \lambda} = 0 &\Rightarrow c(x) = 0 \end{aligned} \quad (3.3)$$

em que $C = \partial c(x)/\partial x$, é a matriz Jacobiana de $c(x)$.

Aplicando o MGN, o conjunto de equações não-lineares (3.3) pode ser resolvido de forma iterativa através do seguinte sistema linear (Abur e Expósito, 2004):

$$\begin{bmatrix} H^T W H & C^T \\ C & 0 \end{bmatrix} \cdot \begin{bmatrix} \Delta x \\ -\lambda \end{bmatrix} = \begin{bmatrix} H^T W \Delta z^k \\ -c(x^k) \end{bmatrix} \quad (3.4)$$

em que $\Delta x = x^{k+1} - x^k$ e $\Delta z^k = z - h(x^k)$.

A partir de (3.4), pode-se observar que a matriz W não possui mais valores elevados, eliminando uma das fontes de mau-condicionamento na matriz G .

Como exemplo de aplicação da melhoria no número de condicionamento da matriz G , realizou-se uma análise no sistema teste de 95 barras proposto em Raposo et al. (2017). Este sistema possui 37 nós de injeções nulas, o que corresponde a aproximadamente 38,95% do total de barras. Além disso, há duas unidades de GD do tipo eólica nas barras #18 e #95, respectivamente. A Tabela 3.1 mostra os valores dos números de condicionamento definidos em (2.8) e (2.9) para os nós de injeções nulas modelados como restrição de igualdade (equação (3.4)).

Para demonstrar a melhoria do número de condicionamento obtida com a modelagem dos nós de injeções nulas via restrições de igualdade, realizou-se uma análise deste número no sistema teste de 95 nós proposto por Singh et al. (2009). Os planos de medição usados neste sistema-teste foram obtidos de Raposo et al. (2017). O sistema-teste possui 37 nós de injeções nulas, o que corresponde a aproximadamente 38,95% do total de nós. Além disso, há duas unidades de GD do tipo eólica nos nós #18 e #95. O diagrama unifilar do sistema-teste de 95 nós é ilustrado na Figura 3.1. A Tabela 3.1 mostra os valores dos números de condicionamento, definidos em (2.8) e (2.9), para nós de injeções nulas modelados como restrição de igualdade (equação (3.4)). A Tabela 3.2 mostra os valores dos números de condicionamento considerando que os nós de injeções nulas foram modelados diretamente na matriz de ganho G

(equação (2.7)) através desvios padrões fictícios iguais a 10^{-4} . Comparando-se os resultados apresentados nestas duas tabelas pode-se que concluir que a modelagem dos nós de injeções nulas via restrições de igualdade resultou uma melhoria significativa no condicionamento numérico da matriz de sensibilidade do sistema linearizado do estimador de estado. Esta melhoria é muito importante, pois em aplicações no sistema de potência, como a estimação de estado, o número de condicionamento deverá ser menor ou igual a 10^{12} (D.-García et al., 2011).

Tabela 3.1: Número de condicionamento segundo sistema (3.4).

Barras com medidores	p	$\kappa_p(G)$	λ_{max}	λ_{min}	$Cond(G)$
#1, #18 e #95	1	1,0470E+10	117,6881	2,7863E-08	4,2238E+09
	2	4,2240E+09			
	∞	1,0470E+10			
#1 e #18	1	7,2808E+10	117,6881	5,6080E-09	2,0985E+09
	2	2,0986E+09			
	∞	7,2808E+10			
#1 e #95	1	1,5170E+10	117,6881	2,3178E-08	5,0775E+09
	2	5,0780E+09			
	∞	1,5170E+10			

Tabela 3.2: Número de condicionamento segundo a equação (2.7).

Barras com medidores	p	$\kappa_p(G)$	λ_{max}	λ_{min}	$Cond(G)$
#1, #18 e #95	1	2,1483E+18	1,2143E+22	3,4196E+04	3,5510E+17
	2	1,0496E+18			
	∞	2,1962E+18			
#1 e #18	1	2,9324E+18	1,2143E+22	4,5764E+04	2,6534E+17
	2	7,0165E+18			
	∞	3,1484E+18			
#1 e #95	1	8,5140E+18	1,2143E+22	3,2277E+04	3,7621E+17
	2	1,0640E+18			
	∞	1,1284E+19			

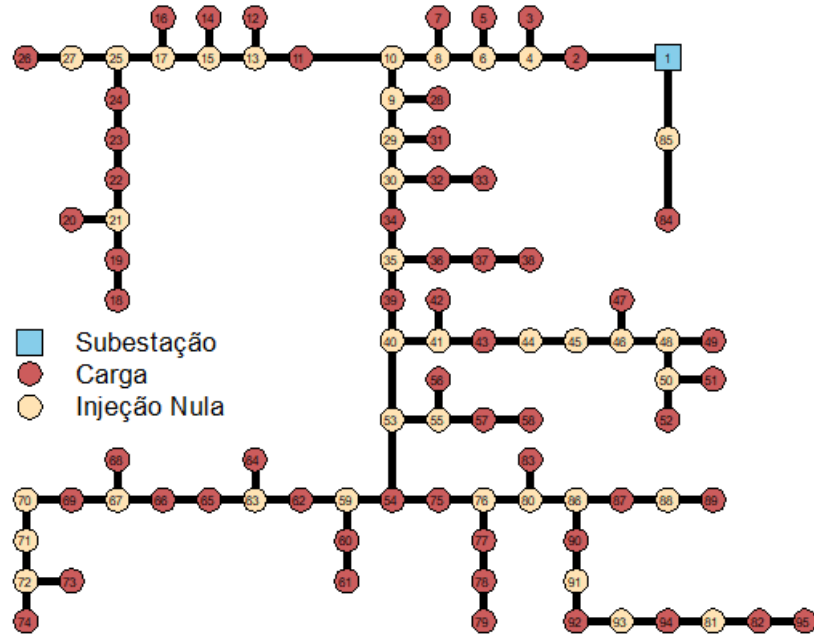


Figura 3.1: Diagrama unifilar do sistema de 95 nós.

3.3 Avaliação da Precisão do Estimador de Estado com Restrições de Igualdade e Medições Correlacionadas

O custo computacional da análise de acurácia do estimador, baseada na SMC, é elevado devido à necessidade de solucionar um MQP não linear para cada elemento da amostra de medições sorteadas. Uma maneira de contornar esta desvantagem é através da linearização do problema de otimização associado como estimador de estado. A partir deste processo, obtém-se uma relação de sensibilidade linear entre o estado estimado e os erros nas medições. O processo de linearização do problema de otimização associado com o estimador de estado, com restrição de igualdade e medições correlacionadas, é obtido a partir das condições de optimalidade de primeira ordem. Isto é, no ponto de mínimo \tilde{x} associado com a função objetivo definida em (3.1), tem-se:

$$\begin{aligned}
 \frac{\partial \mathcal{L}(\tilde{x}, \tilde{\lambda})}{\partial x} = 0 &\Rightarrow H^T(\tilde{x})W^{corr}[z - h(\tilde{x})] + C^T(\tilde{x})\tilde{\lambda} = 0 \\
 \frac{\partial \mathcal{L}(\tilde{x}, \tilde{\lambda})}{\partial \lambda} = 0 &\Rightarrow c(\tilde{x}) = 0
 \end{aligned} \tag{3.5}$$

Assumindo que $H^T(\tilde{x})$ é insensível a pequenas mudanças em \tilde{x} e linearizando $h(\tilde{x})$ em torno de x_{true} , tem-se (Debs, 1990):

$$h(\tilde{x}) \approx h(x_{true}) + H(x_{true})(\tilde{x} - x_{true}) \quad (3.6)$$

no qual x_{true} é o valor verdadeiro do vetor de estado. Por outro lado, $C^T(\tilde{x})$ também é insensível a pequenas mudanças em \tilde{x} e linearizando $c(\tilde{x})$ em torno de x_{true} , tem-se:

$$c(\tilde{x}) \approx c(x_{true}) + C(x_{true})(\tilde{x} - x_{true}) \quad (3.7)$$

Lembrando que $z = h(x) + e_z$, com $e_z \sim N(0, R_z^{corr})$ e substituindo (3.6) e (3.7) em (3.5), obtém-se:

$$\underbrace{\begin{bmatrix} H^T W^{corr} H & C^T \\ C & 0 \end{bmatrix}}_T \cdot \begin{bmatrix} \tilde{x} - x_{true} \\ -\tilde{\lambda} \end{bmatrix} = \begin{bmatrix} H^T W^{corr} e_z \\ -c(x_{true}) \end{bmatrix} \quad (3.8)$$

Isso implica que:

$$\begin{bmatrix} \tilde{x} - x_{true} \\ -\tilde{\lambda} \end{bmatrix} = \underbrace{\begin{bmatrix} K & L \\ M & N \end{bmatrix}}_{T^{-1}} \cdot \begin{bmatrix} H^T W^{corr} e_z \\ -c(x_{true}) \end{bmatrix} \quad (3.9)$$

Nas considerações acima usou-se a aproximação $C(\tilde{x}) \approx C(x_{true}) \approx C$ e $H(\tilde{x}) \approx H(x_{true}) \approx H$ (Debs, 1990).

Extraindo-se a partição superior de (3.9), pode-se obter uma expressão para o vetor de estado estimado \tilde{x} como se segue:

$$\begin{aligned} \tilde{x} - x_{true} &= K \cdot H^T W^{corr} e_z - L \cdot c(x_{true}) \Rightarrow \\ \tilde{x} &= \underbrace{KH^T W^{corr}}_A e_z + x_{true} - \underbrace{L c(x_{true})}_{=0} \Rightarrow \\ \tilde{x} &= A e_z + x_{true} \end{aligned} \quad (3.10)$$

É importante enfatizar dois pontos em relação a equação (3.10): (i) \tilde{x} é independente dos multiplicadores de Lagrange e a técnica proposta pode ser facilmente expandida para o método da matriz aumentada, isto é, a matriz de Hachtel; (ii) é

possível obter uma forma analítica fechada para a matriz K se, e somente se, $H^T W_z H$ for não singular e o complemento Schur de $H^T W_z H$ ($C(H^T W_z H)^{-1} C^T$) é invertível. Este resultado é válido apenas quando as matrizes C e H não possuem colunas nulas.

O principal objetivo da metodologia analítica para avaliar a precisão do estimador de estado, doravante denominada método ANEC2PDF, é gerar a função densidade de probabilidade (PDF – *Probability Density Function*) do vetor de estado estimado segundo (3.10). A partir desta função, pode-se estimar qualquer índice probabilístico associado com o estado estimado.

A equação (3.10) representa uma transformação linear de variáveis aleatórias correlacionadas (TLC), visto que as medições de injeção/fluxo de potência ativa e reativa têm correlação ($e_z \sim N(0, R_z^{corr})$). Há fórmulas para obter a média e o desvio padrão de combinações lineares de variáveis aleatórias descorrelacionadas. Na verdade, uma combinação linear de variáveis aleatórias gaussianas também possui distribuição gaussiana. Entretanto, estas fórmulas não podem ser diretamente aplicadas em (3.10) devido à presença de correlação no vetor de erros e_z . Uma maneira de contornar este problema é utilizar alguma técnica de conversão de uma TLC em uma transformação linear descorrelacionada equivalente (TLD).

Há dois métodos bastante utilizados para descorrelacionar variáveis aleatórias correlacionadas a partir de uma transformação linear: o método da decomposição de Cholesky da matriz de covariância e o método da decomposição ortogonal da matriz de covariância baseado em autovalores e autovetores (DOAA). Ambos os métodos fornecem os mesmos resultados e apresentam custo computacional similar, pois pode-se obter fórmulas analíticas fechadas para matrizes de ordem 1 e 2. A seguir serão apresentados os dois métodos para descorrelacionar variáveis aleatórias: o de Cholesky e o DOAA. Primeiramente, será mostrado o método Cholesky. Em seguida será explicado o método de DOAA que foi selecionado nesta proposta para se obter a média e o desvio padrão de \tilde{x} com base na equação (3.10).

Considera-se a TLC dada por:

$$Y = AX + B \tag{3.11}$$

em que $X \sim N(\bar{X}, C_{XX})$. A TLD equivalente associada a Y é obtida expressando-se o vetor X como uma função linear de um vetor gaussiano padronizado e descorrelacionado como segue (L.-Garcia, 2008; Miller e Childers, 2012):

$$X = DZ + \bar{X} \quad (3.12)$$

em que Z é um vetor de variáveis aleatórias gaussianas descorrelacionadas e padronizadas ($Z \sim N(0, I)$); D é a matriz triangular inferior da decomposição de Cholesky de C_{XX} ($C_{XX} = DD^T$). Substituindo-se (3.12) em (3.11), tem-se:

$$Y = \underbrace{AD}_{A'} \cdot Z + \underbrace{A\bar{X} + B}_{\bar{Y}'} \quad (3.13)$$

Desta forma, a média e a variância de cada componente de Y são dadas por:

$$E[Y_k] = \bar{Y}'_k = \sum_{j=1}^n A_{kj} \bar{X}_j + B_k = B_k + \sum_{j=1}^n A_{kj} E[X_j] \text{ para } k = 1, \dots, \dim(Y) \quad (3.14)$$

$$Var[Y_k] = \sum_{j=1}^n (A'_{kj})^2 \text{ para } k = 1, \dots, \dim(Y) \quad (3.15)$$

Aplicando-se a DOAA a fim de obter uma TLD para a equação (3.10), tem-se (L.-Garcia, 2008; Miller e Childers, 2012):

$$e_z = Q\sqrt{\Lambda} \cdot Z + \bar{X} = Q\sqrt{\Lambda}Z \quad (3.16)$$

em que Z é um vetor de variáveis aleatórias gaussianas descorrelacionadas e padronizadas ($Z \sim N(0, I)$); Q é a matriz ortogonal onde cada coluna está associada com um autovetor de R_z^{corr} ($R_z^{corr} = Q\sqrt{\Lambda}Q^T$, pois R_z^{corr} é simétrica), e $\sqrt{\Lambda}$ é uma matriz diagonal associada com os autovalores de R_z^{corr} , ou seja, $\sqrt{\Lambda}_{ii} = \lambda_i$ é o i -ésimo autovalor de R_z^{corr} . Substituindo-se (3.16) em (3.10), tem-se:

$$\tilde{x} = \underbrace{AQ\sqrt{\Lambda}}_{A''} \cdot Z + x_{true} - Lc(x_{true}) \quad (3.17)$$

Aplicando-se (3.14) e (3.15) em (3.17), a média e a variância de cada componente de \tilde{x} são dadas por:

$$E[\tilde{x}] = x_{true} - L \underbrace{c(x^{true})}_{=0} \Rightarrow \quad (3.18)$$

$$E[\tilde{x}] = x_{true}$$

$$Var[\tilde{x}_k] = \sum_{j=1}^{NM} (A''_{kj})^2 \text{ para } k \in \Omega_B^* \quad (3.19)$$

no qual NM é o número de medições disponíveis.

Visto que $Z \sim N(0, I)$, então a matriz de covariância do estado estimado, $C_{\tilde{x}}^{V\theta}$, segundo o método ANEC2PDF é dada por:

$$C_{\tilde{x}}^{V\theta} = A''(A'')^T \quad (3.20)$$

As equações (3.18) e (3.19) definem uma distribuição de probabilidade normal bivariada (para cada barra $k \in \Omega_B^*$) com média $x_{true}^{V_k\theta_k}$ e matriz de covariância $C_{\tilde{x}}^{V_k\theta_k}$, isto é, $\tilde{x}_k^{V\theta} \sim N(x_{true}^{V_k\theta_k}, C_{\tilde{x}}^{V_k\theta_k})$.

A última etapa do ANEC2PDF é obter a matriz de covariância associada ao erro de fluxo estimado de potência ativa e reativa. Esta matriz de covariância é obtida a partir da análise de sensibilidade da matriz $\partial\tilde{z}/\partial Z$, ou seja, a variação nos valores calculados dos fluxos com relação às perturbações associadas com os erros de medições. Considera-se que o estado estimado já foi calculado segundo (3.17). A análise de sensibilidade é inicialmente usada para determinar o impacto de uma variação no estado estimado sobre os valores estimados dos fluxos nos circuitos. Neste caso, a matriz de sensibilidade $\partial\tilde{z}/\partial\tilde{x}$ é dada por (Monticelli, 1999):

$$\frac{\partial\tilde{z}}{\partial\tilde{x}} = H^{PF} \Rightarrow \Delta\tilde{z} = H^{PF} \Delta\tilde{x} \quad (3.21)$$

em que H^{PF} é a partição da matriz H associada com os fluxos de potência.

A partir de (3.17), tem-se:

$$\begin{aligned}
\tilde{x} &= A''Z + x_{true} - Lc(x_{true}) \Rightarrow \\
\tilde{x} - x_{true} &= A''Z - Lc(x_{true}) \Rightarrow \\
\Delta\tilde{x} &= A''Z - \underbrace{Lc(x_{true})}_{=0} \Rightarrow \\
\Delta\tilde{x} &= A''Z
\end{aligned} \tag{3.22}$$

no qual $\Delta\tilde{x} = \tilde{x} - x_{true}$. Substituindo-se (3.22) em (3.21), tem-se:

$$\begin{aligned}
\Delta\tilde{z} &= H^{PF} \Delta\tilde{x} \Rightarrow \\
\Delta\tilde{z} &= (H^{PF} A'')Z - H^{PF} \underbrace{Lc(x_{true})}_{=0} \Rightarrow \\
\Delta\tilde{z} &= (H^{PF} A'')Z
\end{aligned} \tag{3.23}$$

Um resultado importante da teoria de probabilidade é que se $y = Fv$, com $Cov(v) = M$, então $Cov(y) = FMF^T$. Portanto, a matriz de covariância associada ao erro de fluxo estimado de potência ativa e reativa, C_{PQ}^{flow} , é dada por:

$$\begin{aligned}
Cov(\Delta\tilde{z}) &= C_{PQ}^{flow} = (H^{PF} A'')Cov(Z)(H^{PF} A'')^T \Rightarrow \\
C_{PQ}^{flow} &= (H^{PF} A'')I(H^{PF} A'')^T \Rightarrow \\
C_{PQ}^{flow} &= H^{PF}(A'')(A'')^T(H^{PF})^T
\end{aligned} \tag{3.24}$$

Como já foi dito, um dos objetivos principais do problema de alocação de medidores em redes de distribuição é aumentar a precisão do estimador. Uma das formas de se avaliar essa precisão é através do risco dos erros relativos entre os valores estimados e verdadeiros das variáveis de estado violarem limites especificados (Singh et al., 2009; Raposo et al., 2017). Estes riscos são calculados considerando-se que:

- i) É válida a hipótese de que a magnitude e o ângulo da tensão estimada para cada barra do sistema são variáveis aleatórias decorrelacionadas;
- ii) A precisão de um plano de medição para demanda variável é baseada no nível crítico de carga, isto é, o patamar de carga com o pior índice de precisão para o plano de medição com apenas um medidor na subestação (Raposo et al., 2017; Raposo et al., 2020).

A partir das considerações definidas nos itens (i) e (ii), o risco de violar valores especificados para um patamar de carga l e erro relativo entre os valores verdadeiros e estimados das variáveis de estado pode ser definido como:

$$R_{k,l} = P_{k,l}^V \cdot P_{k,l}^\theta \text{ para } k \in \Omega_B^* \quad (3.25)$$

em que:

$$\begin{aligned} P_{k,l}^V &= \Pr\left(\left|\frac{\tilde{V}_{k,l} - V_{k,l}^{true}}{V_{k,l}^{true}}\right| \geq \epsilon_V\right) \\ &= \Pr[\tilde{V}_{k,l} \leq V_{k,l}^{true}(1 - \epsilon_V) \text{ ou } \tilde{V}_{k,l} \geq V_{k,l}^{true}(1 + \epsilon_V)] \end{aligned} \quad (3.26)$$

$$\begin{aligned} P_{k,l}^\theta &= \Pr\left(\left|\frac{\tilde{\theta}_{k,l} - \theta_{k,l}^{true}}{\theta_{k,l}^{true}}\right| \geq \epsilon_\theta\right) \\ &= \Pr[\tilde{\theta}_{k,l} \leq \theta_{k,l}^{true} - \epsilon_\theta|\theta_{k,l}^{true}| \text{ ou } \tilde{\theta}_{k,l} \geq \theta_{k,l}^{true} + \epsilon_\theta|\theta_{k,l}^{true}|] \end{aligned} \quad (3.27)$$

$R_{k,l}$ é o risco de violação na k -ésima barra no patamar de carga l ; $\tilde{\theta}_{k,l}$ e $\tilde{V}_{k,l}$ são os valores estimados da fase e da magnitude da tensão na k -ésima barra e patamar de carga l , respectivamente; Ω_B^* é o conjunto de barras do sistema excluindo-se a barra slack; $V_{k,l}^{true}$ e $\theta_{k,l}^{true}$ são os valores verdadeiros do módulo e ângulo da tensão na k -ésima barra e patamar de carga l , respectivamente, e; ϵ_V e ϵ_θ são os valores especificados para o erro relativo de magnitude e fase das tensões, respectivamente.

O método ANEC2PDF, diferentemente de métodos que usam SMC, não exige que uma amostra de estados estimados seja gerada a fim de computar o índice de probabilidade bivariado $R_{k,l}$ usando-se o conceito de média amostral. A grande vantagem do ANEC2PDF é calcular o índice $R_{k,l}$ de forma direta observando-se que as distribuições de probabilidade das variáveis de estado estimadas são normalmente distribuídas com média e desvio padrão definidas de acordo com (3.18) e (3.19). Portanto, pode-se determinar $R_{k,l}$ usando a função densidade de probabilidade gaussiana.

3.4 Modelagem das Medições Associadas com as Cargas

Conforme definido nas seções anteriores, a principal fonte de incerteza no estado estimado são os erros nas medições. Os erros nas medições reais têm origem diversificada, por exemplo: classe de exatidão dos TCs e TPs, precisão dos

equipamentos de medição e ruídos na transmissão e conversão dos sinais das grandezas elétricas (tensão, corrente e potência).

Em redes de transmissão existem medições instaladas em todos os circuitos (linhas de transmissão e transformadores) e em todas as barras de carga e geração, pois a automação e monitoramento destas redes é bastante desenvolvida e avançada por questões de segurança e grandes montantes de energia não-fornecida durante blackouts do sistema. Desta forma, a observabilidade do estimador de estado para a condição de operação normal é geralmente assegurada. Por outro lado, o monitoramento da maioria das redes de distribuição atuais é mais limitado com relação as redes de transmissão. Por exemplo, em muitas concessionárias de distribuição, a única medição disponível em um alimentador está localizada no disjuntor principal (de saída) do alimentador. Além disso, as cargas conectadas no alimentador não são monitoradas em tempo real. Na verdade, a única informação disponível com relação as cargas é o seu consumo mensal de energia. Desta forma, deve-se modelar as cargas da rede de distribuição como pseudo-medições para garantir que a rede seja observável. As pseudo-medições são geralmente obtidas a partir de: campanhas de medição, estudos de previsão de carga, dados históricos da operação ou da AMI. A AMI engloba todos os componentes essenciais para a medição e comunicação entre as unidades consumidoras e a concessionária de distribuição. Geralmente, a AMI utiliza uma comunicação bidirecional entre o consumidor e a concessionária que possibilita novas aplicações comerciais, tais como: o envio da fatura de energia, religamento de consumidores, gerenciamento pelo lado da demanda e indicação de interrupções no fornecimento de energia (Bernardon e Garcia, 2018). É importante mencionar que a latência dos dados da AMI (de 15 minutos até 24 horas) é muito maior que aquela referente as medições obtidas a partir do sistema SCADA (de poucos segundos até minutos). Este problema é causado por restrições existentes na largura da banda para transmissão de dados (Expósito et al., 2015). Portanto, os dados das cargas provenientes da AMI podem estar desatualizados quando forem solicitados pela função de estimação de estado. Devido a isto, mesmo com a utilização da AMI, será necessário usar pseudo-medições para substituir as medições de carga, pois o SCADA e a AMI possuem escalas de tempo distintas. Em um futuro próximo, espera-se que o uso de pseudo-medições na estimação de estado em redes de distribuição seja reduzido devido a difusão da tecnologia 5G e ao surgimento de novas gerações de dispositivos digitais, tais como: unidades de medição

fasorial e IED. Estes dispositivos (projetados para medição, proteção e controle) são mais flexíveis que os equipamentos analógicos existentes e são capazes de trocar dados com o mundo exterior através da internet.

Infelizmente, não foi possível obter dados associados com AMI, históricos de operação, previsão de carga ou campanhas de medição durante o desenvolvimento da pesquisa desta tese. Devido, os valores médios das distribuições gaussianas que representam as pseudo-medições são iguais as potências ativas e reativas das cargas usadas no estudo de fluxo de potência. Os desvios padrões das distribuições gaussianas das pseudo-medições são obtidos de acordo com a equação (3.28) (Singh et al., 2009).

$$\sigma_{zmed} = \frac{\mu_{zmed} \times \epsilon_{\mu}^{max}}{3 \times 100} \quad (3.28)$$

em que μ_{zmed} é valor médio para as pseudo-medições associadas com as cargas, e; ϵ_{μ}^{max} é o erro percentual máximo associado com uma medição.

Os valores de ϵ_{μ}^{max} sugeridos por Singh et al. (2009) para se determinar os desvios padrões associados com medições reais e pseudo-medições são iguais a 1% e 50%, respectivamente. Estes valores também foram adotados nesta tese.

Se os dados das cargas são obtidos a partir das faturas mensais de energia dos consumidores via CIS (“Customer Information System”), então é possível alocar (calibrar) as cargas, baseado em fatores de participação, para considerar os efeitos de perdas técnicas e comerciais (Manito et al., 2019). Este procedimento fornecerá valores mais realistas das potências ativa e reativa nodais. Conseqüentemente, a avaliação da precisão do estimador de estado fornecerá resultados mais próximos da realidade operativa da rede de distribuição.

Neste ponto, é importante salientar a diferença entre pseudo-medições e medições virtuais. As medições virtuais estão associadas com nós de injeções nulas e são consideradas como medições de alta precisão (modelagem via desvios padrões muito pequenos ou como restrições de igualdade). Por outro lado, as pseudo-medições (geradas através da aplicação de métodos estatísticos a dados históricos) possuem baixa precisão com relação as medições convencionais e as medições virtuais.

Finalmente, deve-se enfatizar que o número de medições evidencia outra diferença importante entre a estimação de estado em redes de distribuição e transmissão. Nas redes de transmissão, nas quais há um grande número de medições, é possível realizar uma análise de criticalidade das medições. Isto é, identificar as medições que se removidas do sistema o tornam não-observável. Por outro lado, em redes de distribuições, nas quais a quantidade de medidores é muito pequena ou até mesmo insuficiente para a estimação de estado, a análise de observabilidade é geralmente muito limitada ou inactível. Esta dificuldade é devido ao fato de que é necessário adicionar pseudo-medições associadas com todas as barras de carga para tornar o sistema observável. Em outras palavras, em redes de distribuição a estimação de estado está associada com um sistema indeterminado, isto é, o número de equações é menor do que o número de variáveis (Al-Wakeel et al., 2016).

FORMULAÇÕES MONOBJETIVO DOS PROBLEMAS DE RRD E ALOCAÇÃO DE MEDIDORES

4.1 Introdução

Esta tese tem como objetivo apresentar uma metodologia para a solução simultânea dos problemas de RRD e alocação de medidores para minimizar a perda anual de energia e melhorar a precisão do estimador de estado. Desta forma, este capítulo apresenta a formulação matemática monobjetivo (convencional) dos problemas de RRD e alocação de medidores. As formulações destes dois problemas são definidas de forma isolada sem considerar a interferência da RRD na precisão do estimador de estado. A modelagem de cada um dos problemas será feita considerando-se a variação da demanda ao longo de um período de estudo. Em razão dos padrões que se repetem anualmente na demanda de energia ativa e reativa nos sistemas de distribuição, faz-se necessário, primeiramente, definir metodologias utilizadas para agrupamento de cargas. Em seguida, será definida a formulação do problema de alocação de medidores com as respectivas peculiaridades associadas com as restrições e função objetivo. Por fim, será apresentada a formulação do problema de RRD, isto é: a função objetivo e as restrições típicas. Nos capítulos subsequentes desta tese os problemas de otimização associados com a RRD e a alocação de medidores serão combinados em uma estrutura multiobjetivo.

4.2 Mapas Auto-Organizáveis de Kohonen para Agrupamento de Cargas

A metodologia proposta visa minimizar as perdas de energia, maximizar a precisão do estimador de estado e minimizar o número de medidores instalados na rede de distribuição. A precisão de um plano de medição para demanda variável é baseada no

patamar de carga crítico. Ou seja, o patamar de carga com o pior índice de precisão para o plano de medição com apenas um medidor na subestação. Assim, se um índice de precisão para um plano de medição for menor que um limite especificado no patamar de carga crítico, a precisão será garantida para todos os patamares da curva de carga (Raposo et al., 2017). Portanto, é necessário executar a avaliação de precisão apenas para o patamar de carga crítico. Por outro lado, a avaliação anual das perdas de energia requer uma solução de fluxo de potência para cada patamar de carga. Conseqüentemente, os perfis da curva de carga são agrupados em um número predefinido de grupos de dados, com o objetivo de reduzir o custo computacional da avaliação das perdas de energia (Tahboub et al., 2015; Raposo et al., 2020).

Existem na literatura diversas técnicas para agrupamento de dados, destacando-se os algoritmos *k*-means (MacQueen, 1967) e Fuzzy C-Means (FCM) (Dunn, 1973; Bezdek, 1981), bem como a rede neural (mapa) auto-organizável de Kohonen (SOM – *Self-Organizing Maps*) (Kohonen, 2001). O algoritmo *k*-means é um dos mais simples e conhecidos algoritmos de agrupamento de dados. A ideia principal é definir *k* centróides (um para cada grupo) e, em seguida, colocar cada ponto do banco de dados na classe do centroide mais próximo. O próximo passo é recalcular o centroide de cada grupo e redistribuir todos os objetos de acordo com o centroide mais próximo. O processo é repetido até que não haja mudança nos grupos de uma etapa para a próxima (MacQueen, 1967). Matematicamente, o algoritmo *k*-means objetiva minimizar a função erro quadrático de acordo com:

$$J_{k\text{-means}} = \sum_{j=1}^k \sum_{i=1}^N \|x_i^{(j)} - c_j\|^2 \quad (4.1)$$

em que $\|x_i^{(j)} - c_j\|^2$, uma medida da distância escolhida entre um vetor de dados $x_i^{(j)}$ e o centro do agrupamento c_j , representa um indicador da distância de *N* dados dos seus respectivos centros dos agrupamentos.

O algoritmo FCM permite que um dado pertença a dois ou mais grupos baseado em um determinado grau de pertinência, sendo bastante utilizado no reconhecimento de padrões. Este algoritmo tem como base a minimização da seguinte função objetivo (Dunn, 1973; Bezdek, 1981):

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (4.2)$$

em que m é um número real maior ou igual a 1; u_{ij}^m é o grau de pertinência de x_i no grupo de dados j ; x_i é o i -ésimo elemento do vetor de dados x ; c_j é o centro do agrupamento de dados j , com mesma dimensão de x , e; $\|*\|$ é qualquer norma que expressa a similaridade entre os dados disponíveis e os respectivos centros dos agrupamentos.

Por outro lado, as arquiteturas auto-organizáveis, como as propostas por Kohonen (2001), geram mapeamentos de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original. Estes mapeamentos são capazes de preservar as relações de vizinhança dos dados de entrada. Em outras palavras, o SOM é definido como uma transformação não-linear que mapeia uma entrada contínua em um espaço E , cuja topologia é definida pela relação métrica dos vetores de dados D ($D \in E$), para uma saída em um espaço discreto S , cuja topologia é definida por um conjunto de modelos M organizados em uma rede bidimensional, como ilustrado na Figura 4.1. Tipicamente, essa rede de neurônios é conectada por ligações (pesos) hexagonais (Kohonen, 2001).




Figura 4.1: Modelo de uma rede neural auto-organizável de Kohonen.

Considerando-se as três técnicas de agrupamento de dados descritas acima, realizou-se uma análise de desempenho destas técnicas a fim de agrupar os dados

históricos de demanda do sistema teste (Baran e Wu, 1989a; Savier e Das, 2007). A métrica utilizada para avaliar os algoritmos *k*-means, FCM e SOM foi o erro absoluto médio percentual (MAPE – *Mean Absolute Percentage Error*) associado com as perdas ativas para cada patamar de carga. A estatística MAPE é uma métrica importante para análise de modelos de similaridade de dados, isto é, o quanto uma técnica de agrupamentos de dados é mais precisa em relação às demais. Matematicamente, o MAPE expressa a acurácia do erro em percentagem. O MAPE associado com o agrupamento da curva de carga é definido conforme:

$$MAPE(\%) = 100 \times \frac{1}{T} \sum_{t=1}^T \left| \frac{P_{mt}^{loss} - P_{pt}^{loss}}{P_{mt}^{loss}} \right| \text{ para } P_{mt}^{loss} \neq 0 \quad (4.3)$$

em que T representa o número de patamares de carga; P_{mt}^{loss} são as perdas ativas associadas com os dados históricos no instante de tempo t , e; P_{pt}^{loss} são as perdas ativas com o agrupamento de dados no instante de tempo t .

Os algoritmos de agrupamento foram testados aplicando-se os dados históricos de carga do sistema de 95 nós (Singh et al., 2009) utilizada no sistema teste (Baran e Wu, 1989a; Savier e Das, 2007). As curvas de carga ativa e reativa utilizadas são mostradas na Figura 4.2, em quatro grupos, de modo que cada grupo representa uma estação do ano. Considerando 1000 simulações realizadas para os quatro agrupamentos de cargas, o mínimo MAPE para os algoritmos *k*-means, FCM com $m = 2,0$ e $m = 1,2$, e SOM são, respectivamente, 5,4326%, 7,5848%, 6,4583% e 5,0660%. Desta forma, o SOM apresentou o menor MAPE para as 1000 simulações, sendo estes quatro agrupamentos de cargas utilizados para representar demanda ao longo de um ano. A Figura 4.3 ilustra o comportamento do MAPE para cada técnica de agrupamento em função do número de simulações. A partir desta figura é possível notar o comportamento praticamente constante do MAPE para os algoritmos *k*-means e FCM com relação as simulações. Entretanto, na mesma figura, nota-se o comportamento randômico da rede neural de Kohonen. Este comportamento está relacionado com a atualização taxa de aprendizagem da rede, bem como do raio de vizinhança entre neurônios próximos entre si (Kohonen, 2001). A Figura 4.4 mostra o número de patamares de carga, para cada estação do ano, obtidos através do SOM com mínimo MAPE.

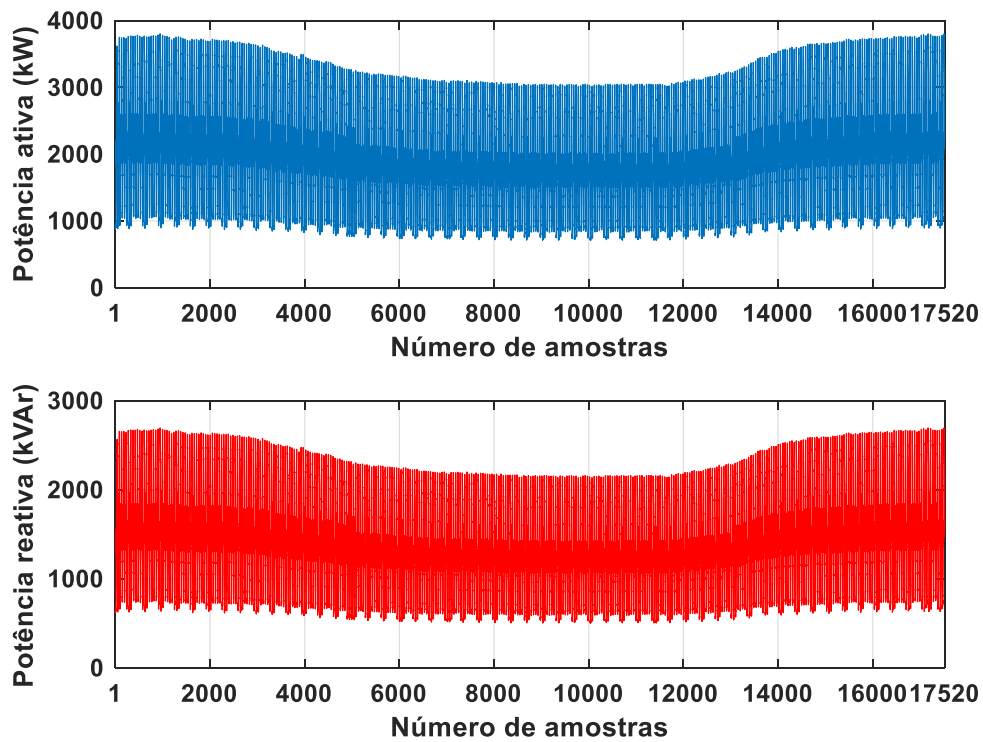


Figura 4.2: Curva de carga utilizada para agrupamento de demanda de energia.

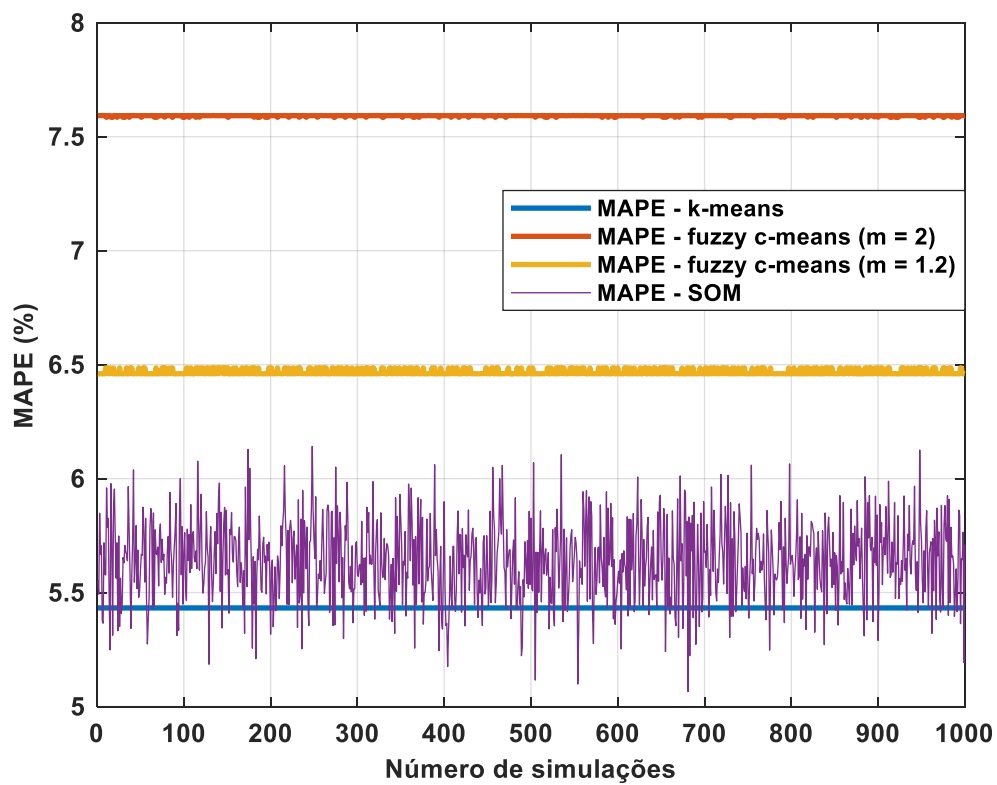


Figura 4.3: Índices MAPE para as técnicas de agrupamento de cargas.




Figura 4.4: Número de patamares de carga obtido através do SOM para o mínimo MAPE.

4.3 Formulação Monobjetivo do Problema de Alocação de Medidores em Redes de Distribuição

Os dispositivos de medição instalados na rede de distribuição permitem o monitoramento de uma gama de índices de qualidade de energia. Além disso, é possível usar os dados dos medidores disponíveis para se estimar os indicadores de qualidade de energia em locais onde não há medidores instalados, por exemplo, a estimação de afundamentos de tensão de curta duração (Juárez e Espinosa, 2007) e de harmônicos (Madtharad et al., 2005). A estimação do módulo e da fase das tensões nodais a partir dos dados das medições é denominada de estimação de estado. A função de estimação de estado está presente nos centros de controle e operação dos sistemas de transmissão. Nestes centros ela é um pré-requisito para diversas outras funções, por exemplo: análise de segurança, despacho econômico, equivalentes externos, etc. Atualmente, a função de estimação de estados também está sendo incorporada nos centros de operação das empresas de distribuição para atender as exigências da implantação de programas de redes elétricas inteligentes.

A qualidade das estimativas das tensões fornecidas pelo estimador de estado é dependente de diversos fatores, tais como:

- i) Sistema de telecomunicações (WAN – *Wide Area Network*, NAN – *Neighborhood Area Network*, etc.);

- ii) Método usado para obter as pseudo-medidas: estatístico (regressão linear) ou inteligência artificial (aprendizagem de máquina);
- iii) Tipo de medição: SCADA, AMI ou PMU,
- iv) Funcionalidade dos medidores: medição dedicada de uma única grandeza (corrente, tensão ou a potência) ou multifuncional (medição de várias grandezas simultaneamente);
- v) Plano de medição existente na rede elétrica: a localização dos medidores nos nós e nos ramos.

Portanto, deve-se definir índices para avaliar a acurácia do estimador. Nesta tese, considera-se que a precisão do estimador é afetada somente pelo plano de medição que é composto apenas por medidores multifuncionais.

Um índice bastante usado para esta avaliação é o risco de violação do erro relativo entre os valores estimados e verdadeiros das tensões nodais (Singh et al., 2009). A definição deste índice é baseada no risco em razão das incertezas associadas com os erros nas medições. Além disso, a determinação de plano de medição deve considerar diversos fatores, como alterações na topologia devido a RRD, variações na carga, falhas nos medidores e a capacidade para identificar erros grosseiros.

É importante enfatizar que a determinação do plano de medição é um problema de otimização combinatória, não-linear e estocástico devido a: natureza discreta dos locais de instalação, não linearidade das funções de medição e incertezas nos valores das medições, respectivamente. Também deve-se considerar os tipos de medidores usados para definir o plano de medição. Por exemplo, Singh et al. (2009) consideram a alocação de medidores convencionais. Estes medidores são equipamentos dedicados para medição de apenas uma grandeza elétrica: tensão, corrente ou potência (ativa e reativa). Esta suposição não é coerente com a tecnologia atual dos equipamentos de medição, porque os medidores usados atualmente pelas concessionárias são multifuncionais. Um medidor multifuncional é composto por um conjunto de transformadores de tensão e corrente que fornecem sinais analógicos destas grandezas (medições cruas) para serem digitalizados e processados por meio de rotinas de software embarcadas no medidor para gerar dados de saída digitais (medições processadas). As duas configurações mais usadas para a conexão do grupo de medições são (Caro et al., 2010): a bifásica (Figura 4.5 (a)) e a trifásica (Figura 4.5 (b)). A configuração mais

usada na prática é a trifásica. A Figura 4.6 mostra em detalhes as conexões dos grupos de medições para a configuração trifásica.




Figura 4.5: Configurações de conexão das medições. (a) bifásica. (b) trifásica (Adaptada de Caro et al. (2010)).

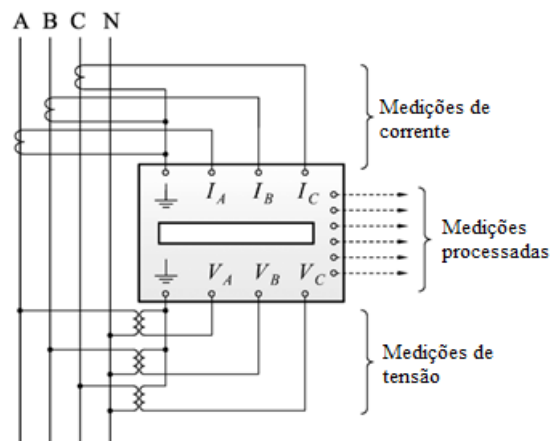


Figura 4.6: Medições de tensão/corrente e medições processadas para a configuração trifásica (Adaptada de Caro et al. (2010)).

As rotinas de software internas de um medidor multifuncional, que calculam os valores das medições processadas, são implementadas de tal forma que a possível presença de harmônicos, desequilíbrios e assimetrias no estado da rede são consideradas (Caro et al., 2010). Entretanto, em estudos de estimação de estado com medidores multifuncionais assume-se que nenhuma harmônica, exceto a harmônica fundamental, é considerada na análise (Caro et al., 2010; Caro et al., 2011).

Geralmente, as medições processadas são: a tensão em uma barra de interesse; correntes e potências ativa/reactiva nos ramos ou geradores/cargas conectados a barra. As rotinas de software internas usadas para calcular este conjunto de medições processadas são baseadas nas seguintes equações (Caro et al., 2010; Caro et al., 2011):

$$V_i = (V_i^A + V_i^B + V_i^C)/3 \quad (4.4)$$

$$I_{ij} = (I_{ij}^A + I_{ij}^B + I_{ij}^C)/3 \quad (4.5)$$

$$P_{ij} = \sum_{f \in \Phi} V_i^\phi I_{ij}^\phi \cos(\psi_{ij}^\phi) \quad (4.6)$$

$$Q_{ij} = \sum_{f \in \Phi} V_i^\phi I_{ij}^\phi \sen(\psi_{ij}^\phi) \quad (4.7)$$

$$P_i = \sum_{f \in \Phi} V_i^\phi I_i^\phi \cos(\psi_i^\phi) \quad (4.8)$$

$$Q_i = \sum_{f \in \Phi} V_i^\phi I_i^\phi \sen(\psi_i^\phi) \quad (4.9)$$

em que:

$\Phi = \{A, B, C\}$ é o conjunto de fases para uma rede de distribuição trifásica;

V_i é a magnitude da tensão na barra de interesse i ;

V_i^f é o sinal da magnitude da tensão na fase f ;

I_{ij}^f e ψ_{ij}^f são os sinais da magnitude da corrente e do ângulo de fase tensão-corrente para a fase f na linha ij , respectivamente.

I_i^f e ψ_i^f são os sinais da magnitude e do ângulo de fase tensão-corrente para fase f pertencente ao gerador/carga conectado na barra de interesse i , respectivamente.

Nesta tese foi usado um modelo balanceado de sequência positiva para a rede de distribuição (ver subseção 1.5). Portanto, as medições resultantes definidas em (4.4)-(4.9) foram obtidas adicionando-se ruídos gaussianos as variáveis do fluxo de potência balanceado (magnitude da tensão, fluxos de potência nos circuitos, injeções de potência, etc.) que correspondem as medições disponíveis. Desta forma, as equações (4.4)-(4.9) têm somente o objetivo de explicar como as medições resultantes são obtidas a partir das configurações típicas de medidores multifuncionais.

Adicionalmente, os medidores multifuncionais são dotados de múltiplos canais que coletam grandezas elétricas em diferentes ramos conectados a um mesmo nó simultaneamente (Muscas et al., 2009). A escolha de medidores multifuncionais e multicanais representa uma opção mais econômica para a obtenção do plano de medição, pois pode-se obter um maior número de medições de diversas grandezas com um número reduzido de equipamentos. Esta característica é importante no processo de planejamento, pois deseja-se minimizar os custos de instalação e compra de equipamentos. Devido a isso, a metodologia introduzida nesta tese assumirá que o plano de medição é obtido com medidores multifuncionais/multicanais instalados em um nó da rede de distribuição que são capazes de medir a magnitude de tensão e os fluxos de potência ativa e reativa dos ramos conectados a este nó.

A partir das considerações acima, pode-se observar que o principal objetivo da alocação de medidores é assegurar que o estado seja estimado de forma precisa. Portanto, pode-se usar a minimização do risco máximo de violação dos limites para os erros relativos como uma meta para a definição da alocação dos medidores. Além disso, é possível impor restrições para os riscos individuais visando evitar que após a alocação os níveis de risco fiquem acima de valores toleráveis. Por outro lado, como já mencionado nesta tese, a precisão de um plano de medição para demanda variável é baseada no nível crítico de carga, isto é, o patamar de carga com o pior índice de precisão para o plano de medição com apenas um medidor na subestação. Assim, em um planejamento a médio ou longo prazo (anual ou sazonal), faz-se necessário determinar em qual patamar de carga encontra-se o patamar crítico. Desta forma, tem-se a seguinte formulação para o problema de alocação de medidores em redes de distribuição (definição do plano de medição) para o patamar de carga crítico l :

$$\min F_1(X) := R^{max} = 100 \times \max_{k \in \Omega_B^*} \{R_{k,l}(X)\} \quad (4.10)$$

$$\text{sujeito a: } R^{max} \leq \bar{R} \quad (4.11)$$

no qual:

X é um vetor binário de variáveis de decisão associado com as barras (locais) nos quais os medidores podem ser instalados. A dimensão de X é igual ao número de barras da

rede (NB) com seus elementos dados por: $X_b = 1$ ($X_b = 0$) se existe (se não existe) um medidor instalado na barra b ;

$R^{max} = \max\{R_{k,l}(X) \forall k \in \Omega_B^*\}$ é o máximo risco nodal no patamar de carga crítico l associado a um plano de medição representado pelo vetor de variáveis de decisão X ;

$R_{k,l}(X) = P_{k,l}^V \cdot P_{k,l}^\theta$ para $k \in \Omega_B^*$ é o risco nodal associado com a barra k no patamar de carga crítico l (equação (3.25));

$P_{k,l}^V = \Pr[\tilde{V}_{k,l} \leq V_{k,l}^{true}(1 - \epsilon_V) \text{ ou } \tilde{V}_{k,l} \geq V_{k,l}^{true}(1 + \epsilon_V)]$ é a probabilidade do erro relativo associado com a magnitude da tensão na barra k , para o patamar de carga crítico l , ser maior do que uma tolerância especificada (equação (3.26));

$P_{k,l}^\theta = \Pr[\tilde{\theta}_{k,l} \leq \theta_{k,l}^{true} - \epsilon_\theta |\theta_{k,l}^{true}| \text{ ou } \tilde{\theta}_{k,l} \geq \theta_{k,l}^{true} + \epsilon_\theta |\theta_{k,l}^{true}|]$ é a probabilidade do erro relativo associado com a fase da tensão na barra k , para o patamar de carga crítico l , ser maior do que uma tolerância especificada (equação (3.27));

Ω_B^* é o conjunto de barras do sistema excluindo-se a barra slack;

$\tilde{\theta}_{k,l}$ e $\tilde{V}_{k,l}$ são os valores estimados da fase e da magnitude da tensão na barra k -ésima no patamar de carga crítico l , respectivamente;

$V_{k,l}^{true}$ e $\theta_{k,l}^{true}$ são os valores verdadeiros do módulo e ângulo da tensão na k -ésima barra no patamar de carga crítico l , respectivamente, e;

ϵ_V e ϵ_θ são os valores especificados para o erro relativo de magnitude e fase das tensões, respectivamente.

Sabe-se que as variáveis estimadas $\tilde{\theta}_{k,l}$ e $\tilde{V}_{k,l}$ são normalmente distribuídas com média e desvio padrão dados por (3.18) e (3.19), respectivamente. Portanto, as probabilidades $P_{k,l}^V$ e $P_{k,l}^\theta$ podem ser calculadas através das seguintes integrais:

$$\Pr[\tilde{\theta}_{k,l} \leq \tilde{\theta}_{k,l}^{min} \text{ ou } \tilde{\theta}_{k,l} \geq \tilde{\theta}_{k,l}^{max}] = 1 - \frac{1}{\sqrt{2\pi Var[\tilde{\theta}_{k,l}]}} \int_{\tilde{\theta}_{k,l}^{min}}^{\tilde{\theta}_{k,l}^{max}} e^{-\frac{(\tilde{\theta} - E[\tilde{\theta}_{k,l}])^2}{2 Var[\tilde{\theta}_{k,l}]}} d\tilde{\theta}_{k,l} \quad (4.12)$$

$$\Pr[\tilde{V}_{k,l} \leq \tilde{V}_{k,l}^{min} \text{ ou } \tilde{V}_{k,l} \geq \tilde{V}_{k,l}^{max}] = 1 - \frac{1}{\sqrt{2\pi Var[\tilde{V}_{k,l}]}} \int_{\tilde{V}_{k,l}^{min}}^{\tilde{V}_{k,l}^{max}} e^{-\frac{(\tilde{V} - E[\tilde{V}_{k,l}])^2}{2 Var[\tilde{V}_{k,l}]}} d\tilde{V}_{k,l} \quad (4.13)$$

em que:

$\tilde{\theta}_{k,l}^{max} = \theta_{k,l}^{true} + \epsilon_{\theta} |\theta_{k,l}^{true}|$ e $\tilde{\theta}_{k,l}^{min} = \theta_{k,l}^{true} - \epsilon_{\theta} |\theta_{k,l}^{true}|$ o valor máximo e mínimo de $\tilde{\theta}_{k,l}$, respectivamente.

$\tilde{V}_{k,l}^{max} = V_{k,l}^{true} + \epsilon_V |V_{k,l}^{true}|$ e $\tilde{V}_{k,l}^{min} = V_{k,l}^{true} - \epsilon_V |V_{k,l}^{true}|$ o valor máximo e mínimo de $\tilde{V}_{k,l}$, respectivamente.

$E[\tilde{\theta}_{k,l}]$ e $E[\tilde{V}_{k,l}]$ são os valores médios de $\tilde{\theta}_{k,l}$ e $\tilde{V}_{k,l}$, respectivamente (equação (3.18)).

$Var[\tilde{\theta}_{k,l}]$ e $Var[\tilde{V}_{k,l}]$ são as variâncias de $\tilde{\theta}_{k,l}$ e $\tilde{V}_{k,l}$, respectivamente (equação (3.19)).

É importante lembrar que a média $\hat{\mu}$ e o desvio padrão $\hat{\sigma}$ das variáveis de estado estimadas são funções das seguintes variáveis (ver equação (3.10)): matriz de sensibilidade H (que contém as derivadas parciais das funções de medição com relação as variáveis de estado), inversa da matriz de covariância W^{corr} e de uma partição K da inversa do sistema aumentado para modelagem dos nós de injeções nulas. Por sua vez, estas matrizes são funções do tipo e do número de medições instaladas na rede. Portanto, a média $\hat{\mu}$ e o desvio padrão $\hat{\sigma}$ das variáveis de estado estimadas são funções implícitas do vetor de variáveis de decisão X , pois este vetor define os locais onde os medidores são instalados. Em outras palavras, as dimensões e os elementos de H e W^{corr} são modificados para cada plano de medição candidato que por sua vez alteram também a média $\hat{\mu}$ e o desvio padrão $\hat{\sigma}$. Desta forma, é caracterizada uma dificuldade para obter uma formulação matemática fechada para definir os riscos como funções explícitas do vetor de variáveis de decisão X . Esta dificuldade será decisiva na escolha da técnica de solução do problema de alocação de medidores. Um esquema sintetizando o cálculo do risco definido na equação (4.10) a partir das probabilidades $P_{k,l}^V$ e $P_{k,l}^{\theta}$ é mostrado na Figura 4.7.

A partir das equações (4.10) e (4.11), pode-se notar que tanto a função objetivo como as restrições do problema de alocação de medidores são funções de integrais definidas (equações (4.12) e (4.13)) cujos parâmetros (por exemplo, os limites inferior e superior) são dependentes de matrizes inversas e jacobianas que são modificadas para cada solução candidata definida pelo vetor X . Este fato ratifica a complexidade do problema de alocação de medidores orientado a melhoria da precisão do estimador de estado. Portanto, métodos de programação não-linear inteira mista são inadequados para a alocação de medidores, pois eles exigem a definição de fórmulas analíticas fechadas

para a função objetivo e para as restrições assim como para as suas respectivas derivadas parciais. Embora estes métodos tenham sido aplicados de forma bem sucedida na solução de problemas de FPO, sua utilização é restrita a otimização com variáveis e restrições intrínsecas do problema de fluxo de potência (um subproblema do FPO), por exemplo: taps de transformadores, status de ramos (ligado ou desligado), potência de saída de geradores, etc. Evidentemente, a acurácia do estimador de estado não é uma função objetivo ou restrição inerente ao FPO. Portanto, a melhor alternativa para a solução do problema de alocação de medidores é a aplicação de técnicas de otimização baseadas em meta-heurísticas. Estes métodos não exigem o cálculo de derivadas parciais da função objetivo nem das restrições. Além disso, eles não requerem que a função objetivo e as restrições sejam definidas de forma explícita em função das variáveis de decisão. As meta-heurísticas são capazes de solucionar de forma eficiente problemas de otimização contendo variáveis discretas e contínuas.

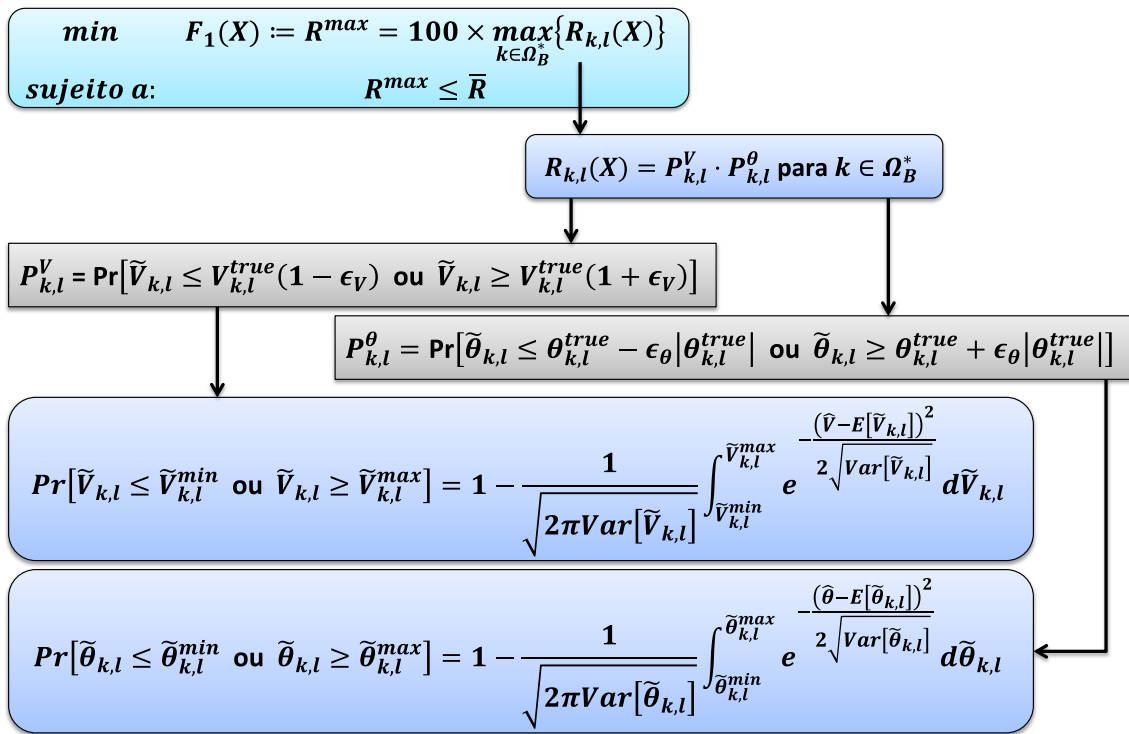


Figura 4.7: Fluxograma para o cálculo de R^{max} a partir das probabilidades $P_{k,l}^V$ e $P_{k,l}^\theta$.

A minimização de (4.10) garante que os medidores serão alocados até que o risco de violar os limites de erro relativo esteja abaixo de um limiar estabelecido.

Todavia, o número de medidores exigido para obter um nível de precisão especificado pode se tornar elevado. Devido a isto, as concessionárias consideram os custos de instalação dos medidores na definição do plano de medição orientado a precisão do estimador de estado. Desta forma, uma formulação alternativa para o problema de alocação de medidores é garantir que a restrição de precisão (4.11) seja satisfeita com o mínimo número de medidores multifuncionais. Esta formulação é matematicamente definida como:

$$\min F_2(X) := N^{meter} = \sum_{k=1}^{NB} X_k \quad (4.14)$$

$$\text{sujeito a: } R^{max} \leq \bar{R} \quad (4.15)$$

em que N^{meter} é a função objetivo correspondente ao número de medidores multifuncionais, calculada para um dado plano de medição representado pelo vetor de variáveis de decisão X , e NB é o número de barras do sistema.

Finalmente, deve-se enfatizar que há uma ambivalência entre as formulações (4.10)-(4.11) e (4.14)-(4.15), pois quanto maior (menor) é número de medidores melhor (pior) será a precisão do estimador de estado. Este fato revela que deve-se estabelecer um compromisso aceitável entre a precisão e o custo de instalação na especificação do plano de medição. No capítulo 6 desta tese, será mostrado como este compromisso é estabelecido usando-se técnicas de otimização multiobjetivo.

A solução do problema (4.10)-(4.11) para um conjunto de N^{cl} topologias ótimas que minimiza as perdas anuais de energia é equivalente à alocação pós-reconfiguração. Por outro lado, se os problemas de alocação de medidores e RRD forem resolvidos de forma simultânea, a avaliação da acurácia do estimador de estado deve considerar as variações na topologia (várias configurações da rede em um período anual) e na demanda. A inclusão dessas duas variações na avaliação da precisão do estimador de estado exige um grande esforço computacional, apesar da capacidade de processamento dos computadores atuais. No entanto, o tempo de computação para a RRD e alocação de medidor com uma única topologia é factível. Neste caso, é necessário considerar apenas as variações de demanda na avaliação da acurácia do estimador, porque a topologia não

é alterada para todos os patamares de carga. Consequentemente, uma função objetivo que pode ser usada na alocação de medidor com RRD é definida como:

$$\min F_3(X) := R_{N^{cl}}^{max} = 100 \times \sum_{c=1}^{N^{cl}} \mathbb{P}_c \cdot \max_{k \in \Omega_B^*} \{R_{k,l}(X), \forall l \in c\} \quad (4.16)$$

$$\text{sujeito a: } R^{max} \leq \bar{R} \quad (4.17)$$

em que \mathbb{P}_c é a probabilidade de ocorrência do agrupamento de carga c (número de patamares de carga dentro do agrupamento de carga c dividido pelo número total de patamares na curva de demanda) e $l \in c$ denota o patamar de carga crítico pertencente ao agrupamento de carga c .

A função objetivo definida em (4.16) corresponde a média ponderada do índice de precisão do estimador de estado para os agrupamentos de carga. A definição da função objetivo apresentada em (4.16) é análoga a estimativa de índices de confiabilidade para modelos de carga em várias etapas (Billinton e Li, 1994).

4.4 Formulação Monobjetivo do Problema de RRD sob Demanda Variável

Conforme mencionado nos capítulos precedentes, a RRD consiste em modificar a topologia da rede de distribuição para maximizar índices de desempenho através da manobra (abertura e fechamento) de dispositivos de seccionamento. Na programação de curto prazo da RRD (diária ou semanal) geralmente os dispositivos de seccionamento são as chaves remotamente controladas. No entanto, no planejamento de longo prazo (anual ou sazonal) pode-se modificar a topologia da rede através de outros dispositivos de seccionamento, por exemplo: as chaves manuais, caixas de conexão de alimentadores subterrâneos e “jumpers” em postes com duplas terminações (Gers, 2013). Na Figura 4.8 são destacados os potenciais pontos de abertura para a RRD em um sistema com dois alimentadores.

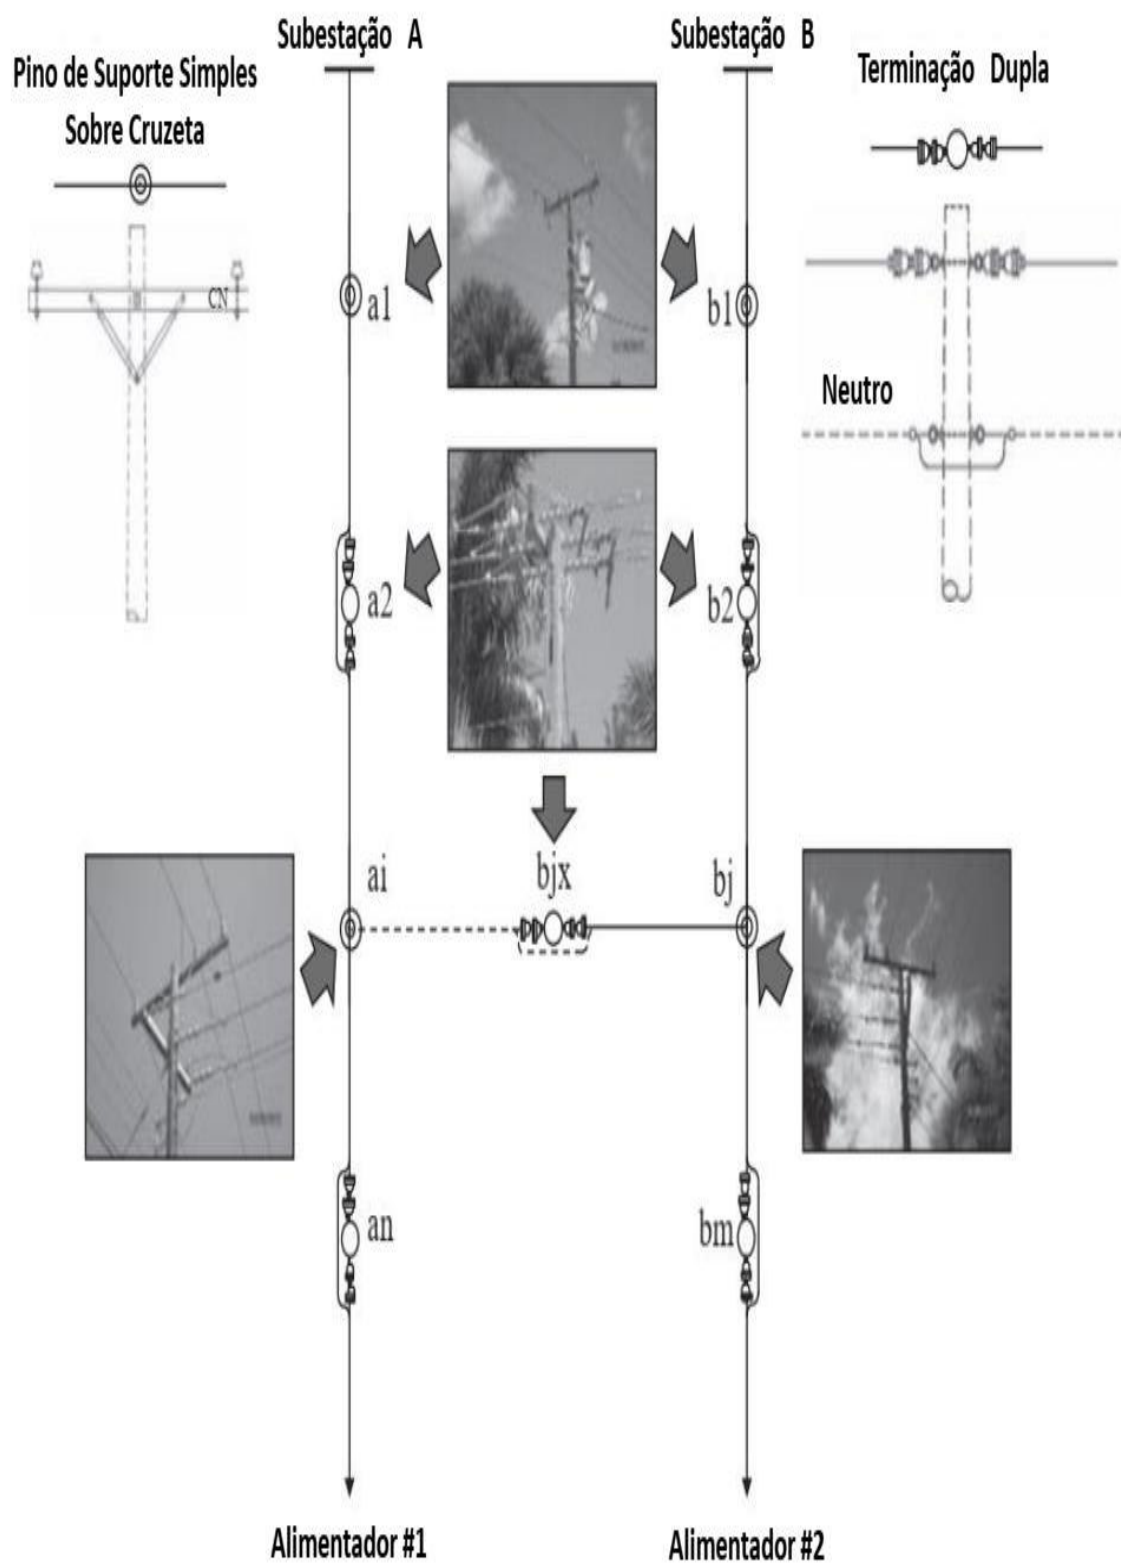


Figura 4.8: Potenciais pontos de abertura para a RRD da rede de distribuição (Adaptado de Gers (2013)).

Geralmente, o principal objetivo da RRD é a minimização das perdas resistivas. A preferência dos engenheiros de planejamento das empresas de distribuição por este critério é devido ao fato de que a redução nas perdas causa um aumento na receita (lucros) das empresas de distribuição. Portanto, indiretamente, a minimização nas perdas está relacionada com aspectos econômicos e financeiros.

Normalmente, a minimização das perdas na RRD é realizada sujeito as seguintes restrições técnicas:

- i) Equações de balanço de potência ativa e reativa nas barras do sistema, isto é, o sistema de equações não-lineares do fluxo de potência;
- ii) Faixa de operação permissível para as magnitudes das tensões nodais;
- iii) Limite de carregamento nos circuitos;
- iv) Radialidade, ou seja, o número de ramos fechados deve ser igual ao número de nós menos um.

Usualmente, as pesquisas sobre a RRD consideram que as perdas ativas são realizadas sob um cenário de carga constante, sendo baseadas no pico ou na demanda média de potências ativa e reativa (Tahboub et al., 2015). Estes resultados, em geral, implicam na obtenção de uma configuração que minimiza as perdas de energia em apenas um instante de tempo. Por outro lado, Yin e Lu (2009) demonstraram que ignorar os efeitos da demanda variável poderia subestimar as perdas totais de energia para a concessionária de energia. Estas considerações fundamentam a estratégia utilizada para obtenção de soluções de alta qualidade com a resolução simultânea dos problemas de RRD e alocação de medidores sob demanda variável (Raposo et al., 2020).

A redução das perdas de energia pode ser formulada como o problema de minimizar a soma das perdas de potência ativa para cada intervalo de tempo na curva de carga. Como os dados de carga são agrupados por meio do SOM, as perdas de energia devem ser definidas com base nos centroides dos agrupamentos de carga. Assim, o problema do RRD é formulado em termos dos centroides de carga de acordo com:

$$\min F_4(Y) := E^{loss} = \sum_{c=1}^{N^{cl}} \mathbb{D}_c \sum_{i=1}^{NR} Y_{i,c} \cdot g_{km}(V_{k,c}^2 + V_{m,c}^2 - 2V_{k,c}V_{m,c}\cos\theta_{km,c}) \quad (4.18)$$

para $(k,m) = \mathcal{L}_i$

sujeito a:

$$P_{j,c}^{sub} + P_{j,c}^{ger} - P_{j,c}^{car} - \sum_{i \in \Omega_j^{inc}} Y_{i,c} P_{km,c} = 0 \quad (4.19)$$

para $j = 1, \dots, NB$, para $c = 1, \dots, N^{cl}$ e $(k,m) = \mathcal{L}_i$

$$Q_{j,c}^{sub} + Q_{j,c}^{ger} - Q_{j,c}^{car} - \sum_{i \in \Omega_j^{inc}} Y_{i,c} Q_{km,c} = 0 \quad (4.20)$$

para $j = 1, \dots, NB$, para $c = 1, \dots, N^{cl}$ e $(k,m) = \mathcal{L}_i$

$$V_{min} \leq V_{j,c} \leq V_{max} \text{ para } j = 1, \dots, NB \text{ e } c = 1, \dots, N^{cl} \quad (4.21)$$

$$I_{i,c} \leq I_i^{max} \text{ para } i = 1, \dots, NR \text{ e } c = 1, \dots, N^{cl} \quad (4.22)$$

$$Y_{i,c} \in \{0,1\} \text{ para } i = 1, \dots, NR \text{ e } c = 1, \dots, N^{cl} \quad (4.23)$$

$$\sum_{i=1}^{NR} Y_{i,c} = NB - 1 \text{ para } c = 1, \dots, N^{cl} \quad (4.24)$$

no qual:

E^{loss} é a perda de energia total em para todos os N^{cl} agrupamentos de carga;

NR é o número de ramos da rede de distribuição;

NB é o número de barras da rede de distribuição;

$Y_{i,c}$ é uma variável de decisão (matriz de estado dos ramos) usada para definir o status dos ramos como:

$$Y_{i,c} = \begin{cases} 1, & \text{se o ramo } i \text{ está fechado para o agrupamento de carga } c \\ 0, & \text{se o ramo } i \text{ está aberto para o agrupamento de carga } c \end{cases}$$

\mathcal{L} é o vetor de pares ordenados referentes aos nós terminais dos ramos. Consequentemente, o elemento \mathcal{L}_i contém o par ordenado (k,m) associado com o nó inicial k e o nó final m do ramo i ;

g_{km} é a condutância série do ramo do nó k para o nó m ;

b_{km} é a susceptância série do ramo do nó k para o nó m ;

V_{min} e V_{max} são os limites mínimo e máximo de tensão para as barras da rede de distribuição, respectivamente;

$V_{k,c}$ é a magnitude da tensão na barra k para o agrupamento de carga c ;

$\theta_{k,c}$ é o ângulo da tensão na barra k para o agrupamento de carga c ;

$$\theta_{km,c} = \theta_{k,c} - \theta_{m,c};$$

$P_{j,c}^{sub}$ é a potência injetada pela subestação na barra j para o agrupamento de carga c ;

$P_{j,c}^{ger}$ é a potência ativa gerada na barra j para o agrupamento de carga c ;

$P_{j,c}^{car}$ é a potência ativa da carga conectada na barra j para o agrupamento de carga c ;

Ω_j^{inc} é conjunto de ramos incidentes na barra j ;

I_i^{max} é o fluxo máximo de corrente no ramo i ;

\mathbb{D}_c é o número de patamares de carga que pertencem ao agrupamento de carga c , isto é,

\mathbb{D}_c corresponde a duração do agrupamento de carga c ;

$I_{i,c}$ é a corrente no ramo i do agrupamento de carga c definida como:

$$I_{i,c} = \left(\sqrt{P_{km,c}^2 + Q_{km,c}^2} \right) / V_{k,c} \text{ para } (k,m) = \mathcal{L}_i, c = 1, \dots, N^{cl} \text{ e } i = 1, \dots, NR \quad (4.25)$$

$P_{km,c}$ e $Q_{km,c}$ são os fluxos de potência ativa e reativa, respectivamente, no ramo i que sai do nó k para o nó m no agrupamento de carga c . As expressões de $P_{km,c}$ e $Q_{km,c}$ são redefinidas, por comodidade, a seguir:

$$P_{km,c} = g_{km} V_{k,c}^2 - V_{k,c} V_{m,c} (g_{km} \cos \theta_{km,c} + b_{km} \sin \theta_{km,c}) \quad (4.26)$$

$$Q_{km,c} = -b_{km} V_{k,c}^2 - V_{k,c} V_{m,c} (g_{km} \sin \theta_{km,c} - b_{km} \cos \theta_{km,c}) \quad (4.27)$$

É importante comentar os seguintes aspectos associados com o problema de otimização (4.18)-(4.24):

- i) A função objetivo (4.18), as restrições de igualdade (4.19) e (4.20) (equações de fluxo de potência) e a restrição (4.22) (carregamento nos circuitos) são não-lineares;
- ii) A restrição de canalização (4.21) define os limites permissíveis para as tensões nodais;
- iii) A restrição (4.24) assegura que a topologia ótima da rede é radial;
- iv) A matriz Y é composta por variáveis binárias que definem a topologia da rede;
- v) Os módulos e as fases das tensões são incógnitas no problema (4.18)-(4.24), mas estas grandezas não são variáveis de decisão no modelo de otimização, pois elas são determinadas uma vez que a topologia é definida pela matriz Y ;

vi) As funções não-lineares definidas em (4.18), (4.19), (4.20) e (4.22) e a matriz de variáveis de decisão binária Y tornam o modelo proposto em (4.18)-(4.24) um problema de otimização não-linear inteira mista.

Os agrupamentos de carga são uma aproximação da curva de carga original usada para reduzir o custo computacional da RRD. Dessa forma, após obter uma topologia ideal por meio da RRD, é necessário validar essa topologia para todos os patamares de carga na curva de carga original. Esta validação é realizada usando a curva de carga histórica para calcular as perdas de energia anuais de acordo com:

$$E_{loss}^{annual} = \Delta t \sum_{t=1}^T \sum_{i=1}^{NR} Y_{i,C_t} \cdot g_{km}(V_{k,t}^2 + V_{m,t}^2 - 2V_{k,t}V_{m,t}\cos\theta_{km,t}) \quad (4.28)$$

para $(k,m) = \mathcal{L}_i$

em que Δt é a duração dos patamares de carga; T é o número de patamares de carga para um período anual; \mathcal{C}_t é o agrupamento de carga associado com o patamar de carga do intervalo de tempo t ; Y_{i,C_t} é o status do ramo i na topologia ótima relacionada ao agrupamento \mathcal{C}_t .

Em outras palavras, após uma topologia ótima ser gerada a partir dos agrupamentos de carga, as perdas de energia anuais exatas são calculadas por (4.28) para avaliar a eficiência da reconfiguração. Finalmente, a validação de um plano de medição é realizada verificando se este plano satisfaz (4.11) para todos os patamares de carga com uma ou mais topologias.

ALGORITMO GENÉTICO DE CHAVES ALEATÓRIAS VICIADAS PARA SOLUÇÃO DO PROBLEMA DE RECONFIGURAÇÃO MONOBJETIVO

5.1 Introdução

A geração de uma configuração radial e a codificação de uma solução consiste de um importante passo para o bom desempenho de um algoritmo evolutivo a ser usado na RRD, bem como no processo de alocação de medidores. Este capítulo aborda a modelagem da restrição de radialidade da rede, item fundamental para gerar soluções factíveis para o problema de RRD. Além disso, descreve-se a meta-heurística BRKGA que servirá de base para a solução do problema de alocação de medidores multifuncionais simultaneamente à RRD.

5.2 Descrição do BRKGA

O BRKGA, proposto por Gonçalves e Resende (2011), é uma meta-heurística evolutiva para problemas de otimização combinatória discreta e global baseada no algoritmo de chaves aleatórias de Bean (1994). Cada solução do BRKGA é representada por um vetor de n chaves aleatórias, onde uma chave aleatória é um número real, gerado aleatoriamente, no intervalo contínuo $[0,1]$. Um decodificador mapeia um vetor de chaves aleatórias em uma solução do problema de otimização e calcula o valor da função objetivo desta solução (Gonçalves e Resende, 2011).

O BRKGA começa com uma população \mathcal{P} de vetores de chaves aleatórias. A inicialização de cada indivíduo desta população se baseia na seguinte regra: *Para cada posição j de cada indivíduo deverá ser atribuído um número aleatório $u \in [0,1]$* . A cada geração, os vetores são particionados em um pequeno conjunto com os melhores

indivíduos, chamado de conjunto *Elite*, composto de \mathcal{P}_e indivíduos, e o restante é alocado em um conjunto denominado *Não-Elite*, composto de $\mathcal{P} - \mathcal{P}_e$ indivíduos. Todos os elementos do conjunto *Elite* são copiados sem alteração para a população da próxima geração. Um número pequeno de vetores de chaves aleatórias sofre mutação e também são adicionados à população da próxima geração. O restante da população da próxima geração é composto de soluções geradas pela combinação uniforme parametrizada de Spears e DeJong (1991) de pares de soluções, onde uma solução é elite e a outra não-elite (Gonçalves e Resende, 2011).

No processo de composição do restante da população da próxima geração do BRKGA, cada indivíduo é obtido a partir da população atual combinando-se um indivíduo selecionado aleatoriamente da partição chamada *Elite* e um da partição denominada *Não-Elite*. Em alguns casos, o segundo indivíduo é selecionado a partir da geração anterior completa. Além disso, a repetição na seleção de um indivíduo é permitida e, portanto, um indivíduo pode produzir mais de um filho. Como é exigido que $\mathcal{P}_e < \mathcal{P}/2$, a probabilidade de um determinado indivíduo do conjunto *Elite* ser selecionado para o *crossover* ($1/\mathcal{P}_e$) é maior do que a de um indivíduo pertencente ao conjunto *Não-Elite* ($1/(\mathcal{P} - \mathcal{P}_e)$) e, portanto, o indivíduo de *Elite* tem maior probabilidade de transmitir suas características às gerações futuras do que um indivíduo *Não-Elite*. A Figura 5.1 ilustra todo mecanismo de composição da próxima geração no BRKGA.

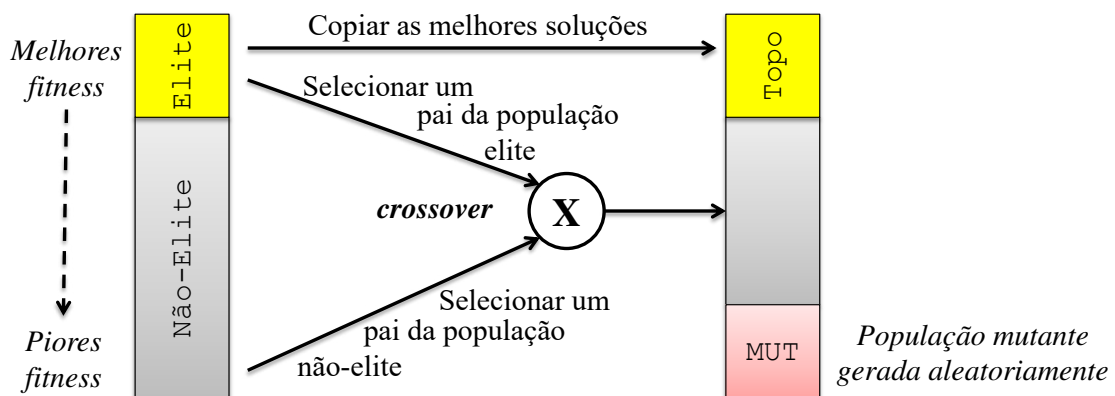


Figura 5.1: Composição da próxima geração no BRKGA (Adaptado de Gonçalves e Resende (2011)).

O processo de *crossover* é baseado na combinação uniforme parametrizada de Spears e DeJong (1991) de pares de soluções, onde uma solução pertence ao conjunto *Elite* e a outra ao conjunto *Não-Elite*. Como exemplo, considerando que a probabilidade de *crossover* (p_{cross}) é de 0,7 e que os indivíduos da população elite e não-elite são representados através dos seguintes vetores de chaves aleatórias $Cr1 = [0,32 \ 0,77 \ 0,53 \ 0,85]$ e $Cr2 = [0,26 \ 0,15 \ 0,91 \ 0,44]$, respectivamente. Então o indivíduo resultante (cromossomo filho) do cruzamento de $Cr1$ com $Cr2$ herdará as características de cada pai de acordo com a seguinte regra: *Para cada posição j do cromossomo filho deverá ser sorteado um número aleatório $u \in [0,1]$. Se $u \geq p_{cross}$, então a chave aleatória da posição j de $Cr1$ deve ser copiada para a posição j do cromossomo filho. Caso contrário, a chave aleatória da posição j de $Cr2$ deve ser copiada para a posição j do cromossomo filho.* A Figura 5.2 demonstra a técnica de *crossover* do BRKGA utilizando o exemplo descrito anteriormente.



Figura 5.2: Demonstração do operador de *crossover* no BRKGA (Adaptado de Gonçalves e Resende (2011)).

Um indivíduo da população mutante é gerado de maneira análoga ao procedimento de inicialização da população. Entretanto, cada posição j do indivíduo mutante receberá uma nova chave aleatória se a probabilidade de mutação (p_{mut}) for maior ou igual a um dado número aleatório $u \in [0,1]$.

O Algoritmo 5.1 apresenta o pseudocódigo do BRKGA (Gonçalves e Resende, 2011).

Algoritmo 5.1: Pseudocódigo do BRKGA

1. Determinar o tamanho da população (p_t); o tamanho da população elite (p_e); o tamanho da população mutante (p_m); a probabilidade de crossover (p_{cross}), e a probabilidade de mutação (p_{mut}). Ir ao passo 2.
 2. Inicializar a população \mathcal{P} . Ir ao passo 3.
 3. Decodificar cada cromossomo de \mathcal{P} e extrair sua solução e *fitness*. Ir ao passo 4.
 4. Ordenar a população \mathcal{P} da melhor para a pior *fitness*. Ir ao passo 5.
 5. Armazenar no conjunto elite \mathcal{E} os primeiros p_e indivíduos de \mathcal{P} . Ir ao passo 6.
 6. Copiar \mathcal{E} para a próxima geração \mathcal{Q} . Ir ao passo 7.
 7. Adicionar p_m indivíduos a \mathcal{Q} gerados por mutação de p_m indivíduos de \mathcal{P} . Ir ao passo 8.
 8. Completar \mathcal{Q} com $p_t - p_e - p_m$ indivíduos gerados por *crossover* entre elementos de \mathcal{E} e $\mathcal{P} \setminus \mathcal{E}$. Ir ao passo 9.
 9. Faça $\mathcal{P} \leftarrow \mathcal{Q}$. Se algum critério de parada é satisfeito, PARAR. Caso contrário, repetir os passos 3 – 8.
-

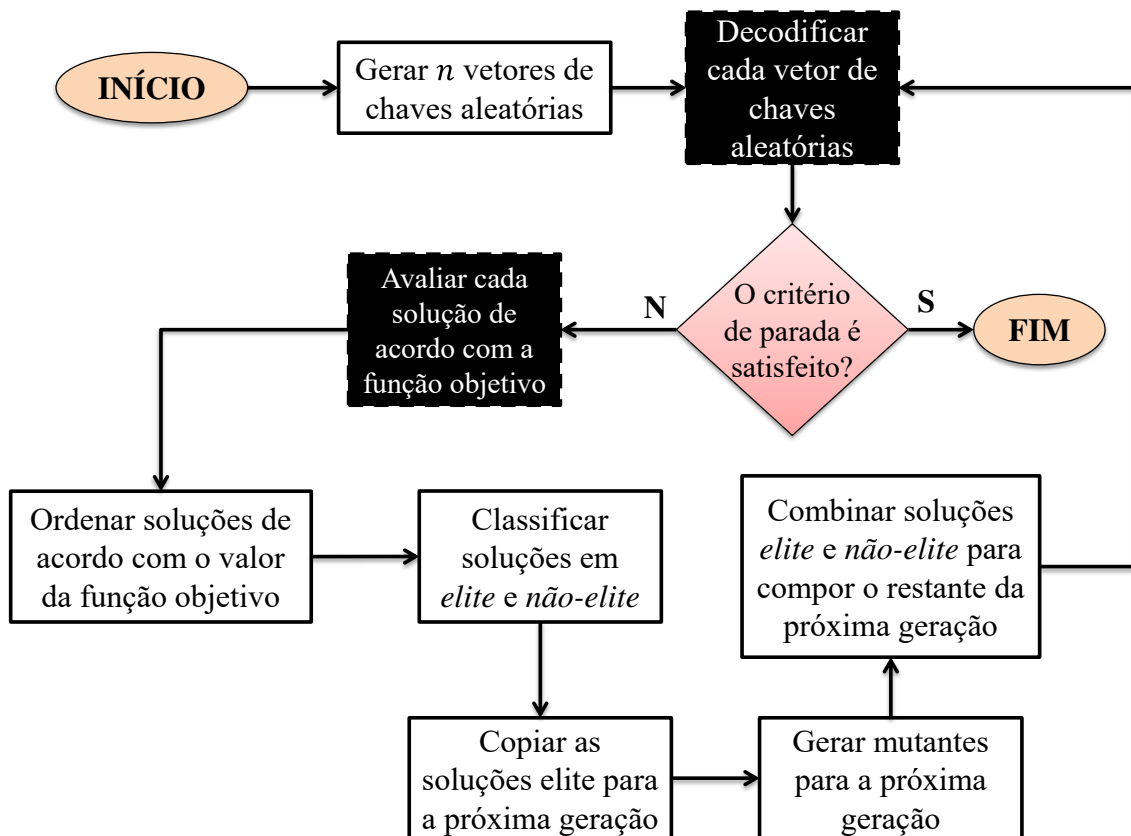


Figura 5.3: Fluxograma do BRKGA (Adaptado de Gonçalves e Resende (2011)).

É importante destacar que nenhuma tarefa do BRKGA depende do problema de otimização para o qual uma solução está sendo procurada. De fato, a única conexão entre esta meta-heurística e o problema em si ocorre quando um cromossomo é decodificado, isto é, quando uma solução para o problema é construída a partir de um cromossomo e sua função objetivo é calculada. Este detalhe é ilustrado na Figura 5.3, em que pode-se perceber a clara divisão entre as partes dependente e independente do algoritmo BRKGA para um dado problema de otimização.

A seção seguinte descreve como o problema de RRD aplicado a redução das perdas ativas é adaptado ao BRKGA. O processo de inicialização, com soluções estritamente factíveis, bem como os operadores de *crossover* e mutação foram desenvolvidos de maneira especial, a fim de garantir maior diversidade e melhor desempenho computacional.

5.3 Modelagem da Restrição de Radialidade da Rede no BRKGA

As redes de distribuição com topologia radial estão associadas com um tipo especial de grafo denominado árvore. Uma árvore é um grafo que não possui nenhum caminho fechado ou laço, isto é, numa árvore só existe um caminho entre dois vértices do grafo.

Outro conceito importante da teoria de grafos associado à RRD é o de árvore de expansão (geradora) mínima (MST – *Minimum Spanning Tree*). Considere um grafo não-direcionado, em que cada aresta está associada a uma distância ou peso e é representada por um número real não-negativo. Este número pode representar o custo de uma rota, tempo para realizar um trajeto, etc. O objetivo de se obter uma MST é encontrar o menor percurso de tal maneira que as arestas forneçam um caminho entre todos os pares de vértices com menor distância possível. A Figura 5.4 ilustra o conceito de MST. A partir desta figura é possível observar que o grafo G é composto de 8 nós e 16 arestas. A MST para este grafo é representada através da *Árvore 1*, pois é a árvore que apresenta a menor distância dentre todos os possíveis caminhos que conectam os nós de G sem formar laços, isto é, a distância total da *Árvore 1* é 28, enquanto que a distância total da *Árvore 2* é 39.

Existem na literatura diversas técnicas para se obter uma MST, destacando-se os algoritmos de Boruvka, Prim e Kruskal (Kruskal, 1956; Prim, 1957; Nešetřil e Nešetřilová, 2012). Devido a sua estrutura matroide, uma MST pode ser obtida através do algoritmo de Prim. Este algoritmo tem tempo polinomial e só pode ser aplicado em um grafo conectado, ponderado e não-direcionado (Prim, 1957). A técnica proposta por Kruskal é aplicada a grafos conexos e ponderados. Entretanto, se o grafo é não-conexo, o algoritmo encontra uma floresta de expansão (geradora) mínima (MSF – *Minimum Spanning Forest*) para cada subgrafo (componente conexo do grafo). Além disso, o algoritmo de Kruskal possui tempo polinomial e faz uso de uma estratégia gulosa devido à fila de prioridades (Kruskal, 1956). O algoritmo de Borůvka/Barůvka foi desenvolvido em 1926 pelo matemático tcheco Otakar Borůvka, quando ele estava tentando encontrar uma rota ótima para as redes elétricas da Morávia, atualmente leste da República Tcheca. O algoritmo de Borůvka contém características dos algoritmos de Kruskal e Prim e é aplicado a grafos conexos ou não-conexos nos quais os pesos das

arestas devem ser distintos. Este algoritmo não utiliza fila de prioridade, a sua velocidade de convergência é alta e pode ser implementado em computadores com arquitetura paralela (Nešetřil e Nešetřilová, 2012).

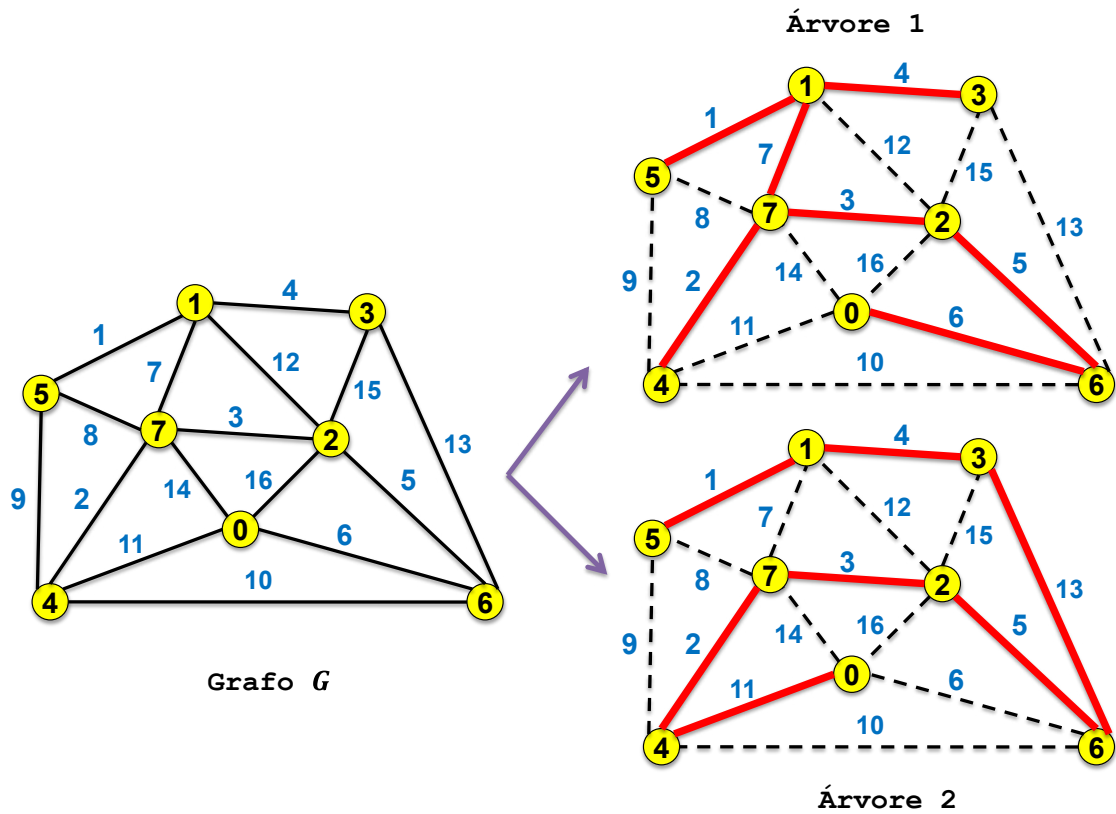


Figura 5.4: Árvores geradas a partir de um grafo.

De posse dessas informações, foi desenvolvida uma técnica, fundamentada no algoritmo evolucionário para o problema de MST com restrição de grau (número de ramos incidentes em um nó) nos vértices proposto por Raidl (2000), a fim de solucionar o problema de RRD. A metodologia proposta em (Raidl, 2000) é baseada no algoritmo genético. Desta forma, a adaptação para o BRKGA ocorre de maneira natural. Além disso, como a restrição de grau não faz sentido no contexto da RRD, eliminou-se esta restrição dos algoritmos de inicialização, *crossover* e mutação no BRKGA.

Para o problema de RRD aplicado a redução das perdas, um cromossomo C_i e uma solução $(Y_{i,c})$ no BRKGA são definidos como sendo $C_i = [c_{i1}, \dots, c_{iD}]$ e $(Y_{i,c}) = [y_{i1,c}, \dots, y_{iNR,c}]$, respectivamente. Em que $D = NR$ é a dimensão do espaço de busca.

Assim, cada chave aleatória ou alelo de C_i representa uma possível conexão entre duas barras da rede de distribuição, isto é, cada posição de C_i representa um ramo da rede com status de: conectado ou não-conectado. O decodificador tem a função de transformar essas informações contidas em C_i em uma solução ou topologia $Y_{i,c}$ a fim de que a função objetivo (4.18) seja avaliada.

A decodificação de uma solução para o problema de RRD no BRKGA é a seguinte: um ramo j de um cromossomo i está conectado à rede se $c_{ij} \geq P_{CR}$ para $j = 1, \dots, D$, onde: $P_{CR} = (NR - NB + 1)/NR$ é a probabilidade de conectividade de um ramo da rede de distribuição. Se $c_{ij} < P_{CR}$, então este ramo encontra-se desconectado. Dessa forma, se $c_{ij} \geq P_{CR}$, então $y_{ij,c} \leftarrow 1$. Caso contrário, $y_{ij,c} \leftarrow 0$.

A topologia da rede de distribuição é representada segundo o grafo $G(NB, NR)$ com NB vértices e NR ramos. Desta forma, as configurações iniciais podem ser obtidas de acordo com os Algoritmos 5.2 e 5.3.

Algoritmo 5.2: Pseudocódigo de inicialização do BRKGA – RRD

#Especificar:

O tamanho da população p_t ;

O número aleatório distribuído uniformemente no intervalo $[0,1]$ u .

para k de 1 até p_t **faça**

1. Gerar uma árvore C_k de acordo com o Algoritmo 5.3;

fim para

retornar C

O Algoritmo 5.2 produz apenas soluções factíveis para a população inicial do BRKGA associada às configurações, isto é, este algoritmo constrói as topologias radiais e todas as topologias contendo malhas ou ilhamento são eliminadas da população. O Algoritmo 5.3 é baseado no algoritmo de MST de Kruskal. Outra observação está relacionada a inicialização de cada árvore com o conjunto de ramos raiz. Um ramo é dito ser raiz se, e somente se, ele está associado com o ponto de fornecimento da rede de distribuição, ou seja, é o início da árvore que representa a rede.

Algoritmo 5.3: Pseudocódigo para obter uma árvore no BRKGA – RRD

#Especificar:

- O grafo $G(NB, NR)$ com NB vértices e NR ramos;
- Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado $(s, r) SR[j]$;
- O i -ésimo cromossomo C_i ;
- O número de ramos raiz $|R|$;
- O número aleatório distribuído uniformemente no intervalo $[0,1]$ u .

$T \leftarrow \emptyset$;

#Inicialização da árvore T com o conjunto de ramos raiz.

para j de 1 até $|R|$ **faça**

$(u, v) \leftarrow SR[j]$;

$T \leftarrow T \cup \{(u, v)\}$;

$c_{ij} \leftarrow 1$;

fim para

#Construção da árvore T de forma aleatória.

enquanto $|T| < NB - 1$ **faça**

 1. Aleatoriamente escolha um ramo $p \in G$ e faça $(u, v) \leftarrow SR[p]$;

se $p \notin T$ **então**

se p não forma uma malha em T e p está conectado com alguma barra em T **então**

$T \leftarrow T \cup \{(u, v)\}$;

$u \leftarrow rand(0,1)$;

$c_{ij} \leftarrow P_{CR} + u \cdot (1 - P_{CR})$;

fim se

fim se

fim enquanto

retornar C_i

Assim como na fase de inicialização, as operações de *crossover* e mutação para gerar novas configurações radiais baseiam-se nos algoritmos propostos em (Raidl, 2000). Os Algoritmos 5.4 e 5.5 descrevem os operadores de mutação e *crossover*, respectivamente.

Algoritmo 5.4: Pseudocódigo de mutação no BRKGA – RRD

#Especificar:

- Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado $(s, r) SR[j]$;
- O k -ésimo cromossomo C_k ;
- O cromossomo com mutação C^{mut} ;
- O número aleatório distribuído uniformemente no intervalo $[0,1]$ u .

```

 $T \leftarrow \emptyset;$ 
para  $j$  de 1 até  $D$  faça
   $C_j^{mut} \leftarrow c_{kj};$ 
   $(s, t) \leftarrow SR[j];$ 
  se  $c_{kj} \geq P_{CR}$  então
     $T \leftarrow T \cup \{(s, t)\};$ 
  fim se
fim para
1. Aleatoriamente selecione um ramo  $p \in G$  tal que  $p \notin T$ ;
 $(a, b) \leftarrow SR[p];$ 
2. Obter o conjunto  $L$  de todos os ramos em  $T$  que formam um caminho fechado entre os nós  $a$  e  $b$ , isto é,  $L \leftarrow \{(k, l) \mid (k, l) \text{ formam um caminho fechado entre } a \text{ e } b\};$ 
3. Aleatoriamente selecione um ramo  $q$  tal que  $q \in L - \{(a, b)\};$ 
 $(u, v) \leftarrow SR[q];$ 
 $T \leftarrow T \cup \{(a, b) \setminus (u, v)\};$ 
 $u \leftarrow rand(0,1);$ 
 $C_p^{mut} \leftarrow P_{CR} + u \cdot (1 - P_{CM});$ 
 $C_q^{mut} \leftarrow P_{CR} \cdot u;$ 
retornar  $C^{mut}$ 

```

O processo de mutação de uma árvore no BRKGA é ilustrado na Figura 5.5. Observa-se, a partir desta figura, que o ramo $p = (3,6)$ não pertencente a árvore T foi escolhido aleatoriamente para o processo de mutação. Em seguida, identifica-se o caminho fechado, L , que a inclusão de p produzirá na árvore T . O próximo passo é escolher, de forma randômica, um ramo $q \in L$ que será retirado de T para que a ação de incluir p em T continue a gerar uma árvore, ou seja, uma topologia radial para a rede de distribuição. O grafo resultante contendo a árvore mutante foi codificado, de forma simples, num cromossomo de zeros e uns, em que 0 representa um ramo não pertencente à árvore mutante e 1 a um ramo da mesma. É importante enfatizar que esta codificação é apenas ilustrativa, isto é, para que se possa compreender a estrutura de codificação de uma rede radial como indivíduo no BRKGA. Como efeito, os bits 0 e 1 seriam substituídos por chaves aleatórias, com uma posição j de um cromossomo i representando um ramo da árvore se $c_{ij} \geq P_{CR}$.




Figura 5.5: Mutação no BRKGA aplicado a RRD.

Algoritmo 5.5: Pseudocódigo de *crossover* no BRKGA – RRD

#Especificar:

- Os k -ésimo e m -ésimo cromossomos C_k e C_m ;
- Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- O cromossomo com crossover C^{cross} ;
- O índice p com $p \in \{k, m\}$;
- Árvores $T_p(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- O número aleatório distribuído uniformemente no intervalo $[0,1]$ u ;
- A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado (s, r) $SR[j]$.

$T_p \leftarrow \emptyset$;

para j de 1 até D **faça**

$(u, v) \leftarrow SR[j]$;

se $c_{pq} \geq P_{CR}$ **então**

$T_p \leftarrow T_p \cup \{(u, v)\}$;

fim se

fim para

$T^{out} \leftarrow T_k \cap T_m$;

$F_{km} \leftarrow (T_k \cup T_m) \setminus T^{out}$;

enquanto $|T^{out}| < NB - 1$ **faça**

1. Aleatoriamente selecione um ramo $p \in F_{km}$ e faça $(u, v) \leftarrow SR[p]$;

```

se  $p$  não forma uma malha em  $T^{out}$  e  $p$  está conectado com alguma barra em  $T^{out}$ 
então
     $T^{out} \leftarrow T^{out} \cup \{(u, v)\};$ 
fim se
fim enquanto
para  $j$  de 1 até  $D$  faça
     $u \leftarrow rand(0,1);$ 
     $C_j^{cross} \leftarrow P_{CR} \cdot u;$ 
     $(s, t) \leftarrow SR[j];$ 
    se  $(s, t) \in T^{out}$  então
         $C_j^{cross} \leftarrow P_{CR} \cdot (1 + u);$ 
    fim se
fim para
retornar  $C^{cross}$ 

```

O processo de *crossover* entre duas árvores T_k e T_m no BRKGA é ilustrado na Figura 5.6. É possível verificar, a partir desta figura que inicialmente, a árvore resultante do cruzamento entre as árvores T_k e T_m , T^{out} , possui ramos que pertencem simultaneamente a estas duas árvores. Em seguida, T^{out} é completada aleatoriamente com o conjunto de todos os ramos gerados através da união entre T_k e T_m . O grafo resultante contendo a árvore mutante foi codificado, de forma simples, num cromossomo de zeros e uns, em que 0 representa um ramo não pertencente a árvore mutante e 1, a um ramo da mesma. Como ocorre na mutação, esta codificação é apenas ilustrativa, isto é, para que se possa compreender a estrutura de codificação de uma rede radial como indivíduo no BRKGA.

Os Algoritmos 5.3, 5.4 e 5.5 são fundamentais para garantir que a restrição de radialidade da rede de distribuição seja satisfeita. Em outras palavras, para que o BRKGA possa ser aplicado ao problema de RRD foram desenvolvidos operadores especiais de *crossover* e mutação, além de um processo de inicialização baseado no algoritmo para MST de Kruskal. Outro ponto a ser destacado é o fato dos operadores dispensarem as probabilidades de *crossover* e mutação. Assim, para a etapa de mutação, assume-se que um indivíduo (árvore/topologia) sofrerá mutação somente uma vez a partir da escolha aleatória de um ramo da rede. Esta escolha evita que uma mesma topologia sofra, no pior caso, NR processos de mutação para uma dada geração, diminuindo consideravelmente o custo computacional. Para o operador de *crossover*, assume-se que sempre haverá cruzamento entre as topologias pertencentes aos

conjuntos elite e não-elite. Esta escolha tem como objetivo aumentar a diversidade da próxima geração.

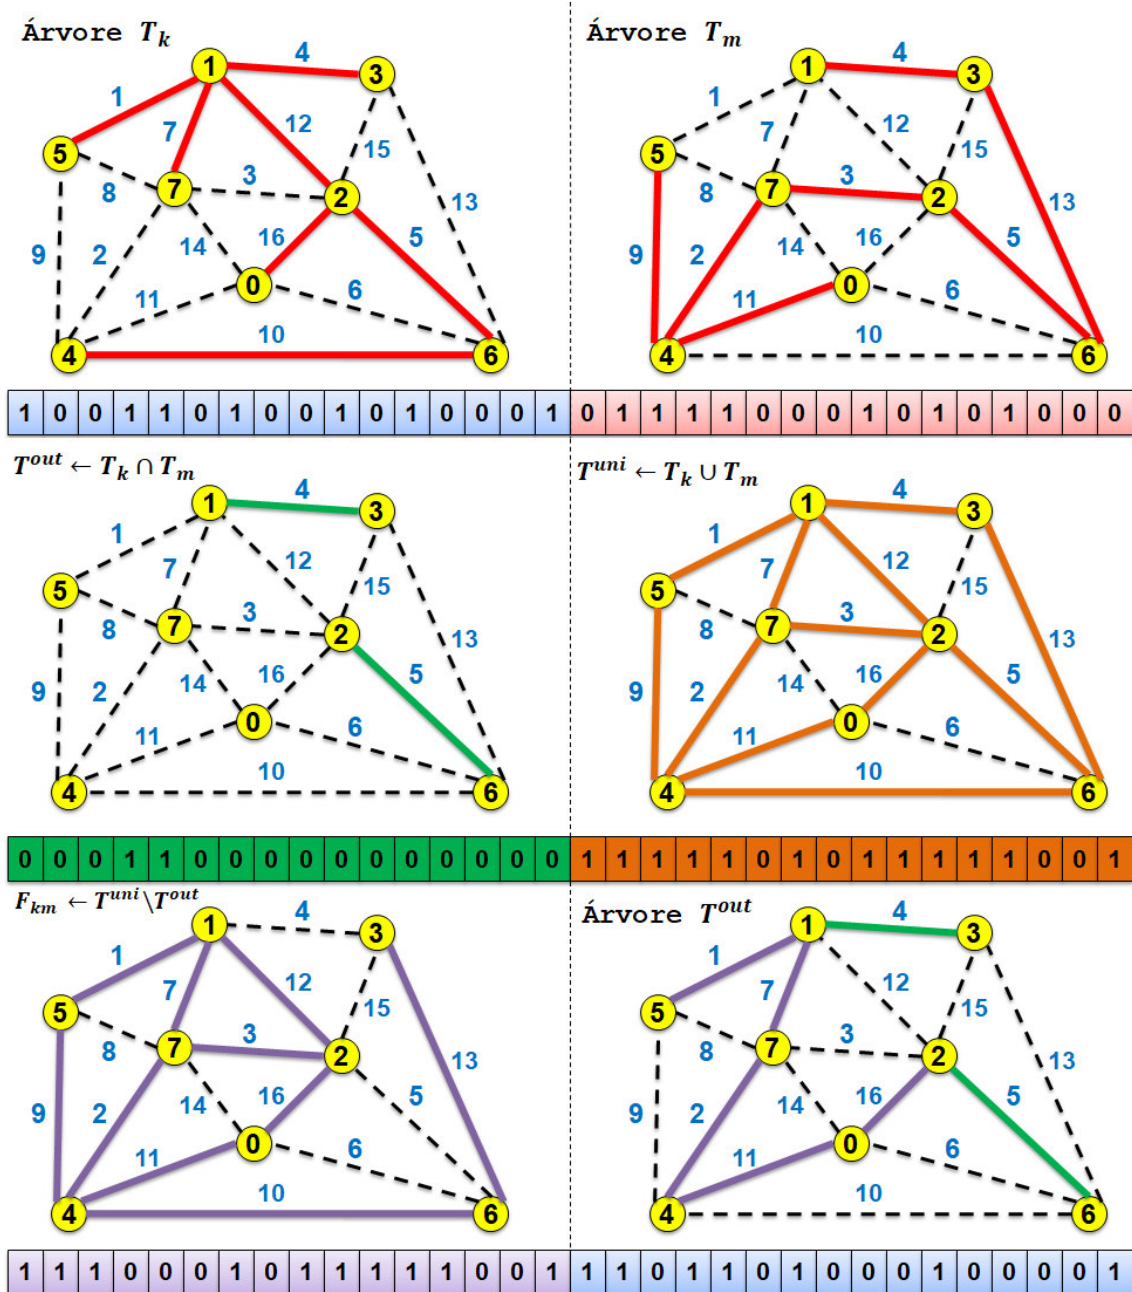


Figura 5.6: Crossover no BRKGA aplicado a RRD.

A partir dos Algoritmos 5.2, 5.3, 5.4 e 5.5 tem-se o algoritmo conceitual 5.6, do BRKGA aplicado ao problema de RRD visando a minimização das perdas ativas:

Algoritmo 5.6: Pseudocódigo do BRKGA aplicado a RRD

1. Obtendo dados.

1.1. Determinar o agrupamento de carga (\mathbf{c}); o tamanho da população (p_t); o tamanho da população elite (p_e); o tamanho da população mutante (p_m), e; o máximo número de gerações (g^{max}); Inicializar o contador de gerações $g \leftarrow 1$. Ir ao passo 2.

2. Inicialização do BRKGA.

2.1. Inicialize a população \mathcal{P} de cromossomos $C_k^g = [c_{k1}^g, \dots, c_{kD}^g]$, para $k = 1, \dots, p_t$, de acordo com o Algoritmo 5.2, em que $D = NR$. Ir ao passo 3.

3. Decodificação do BRKGA.

3.1. Decodificar cada cromossomo C_k^g de \mathcal{P} em uma solução $Y_{k,c}^g$, para $k = 1, \dots, p_t$.

3.2. Avaliar a função monobjetivo de acordo com (4.18) para cada solução gerada. Ir ao passo 4.

4. Ordenar a população da melhor para a pior *fitness*. Ir ao passo 5.

5. Obtendo conjunto elite do BRKGA.

5.1. Armazenar no conjunto elite \mathcal{E} os primeiros p_e indivíduos da população.

5.2. Armazenar no conjunto não-elite $\bar{\mathcal{E}}$ os demais $p_t - p_e$ indivíduos da população. Ir ao passo 6.

6. Copiar \mathcal{E} para a próxima geração \mathcal{Q} . Ir ao passo 7.

7. Operação de mutação no BRKGA.

7.1. Para $i = p_e + 1, \dots, p_e + p_m$, obtenha um cromossomo $k \in \mathcal{E}$, de forma aleatória, e produza um novo indivíduo em \mathcal{Q} , $Q_i = [q_{i1}, \dots, q_{iD}]$, através do Algoritmo 5.4, de acordo com (5.1). Ir ao passo 8.

$$q_{ij} \leftarrow C^{mut} \text{ para } j = 1, \dots, D \quad (5.1)$$

8. Operação de crossover no BRKGA.

8.1. Para $i = p_e + p_m, \dots, p_t$, obtenha um cromossomo $k \in \mathcal{E}$ e um cromossomo $m \in \bar{\mathcal{E}}$, de forma aleatória, e produza um novo indivíduo em \mathcal{Q} , $Q_i = [q_{i1}, \dots, q_{iD}]$, através do Algoritmo 5.5, de acordo com (5.2). Ir ao passo 9.

$$q_{ij} \leftarrow C^{cross} \text{ para } j = 1, \dots, D \quad (5.2)$$

9. Faça $\mathcal{P} \leftarrow \mathcal{Q}$. Se algum critério de parada é satisfeito, PARAR. Caso contrário, repetir os passos 3 – 8.

O cálculo das perdas de energia (função objetivo $F_4(Y)$ definida em (4.18)) requer a determinação das tensões nodais na rede de distribuição. Estas tensões nodais são determinadas através do cálculo do fluxo de potência. Os três principais métodos disponíveis para a realização de estudos de fluxo de potência em redes de distribuição são: o método de Newton-Raphson (Monticelli, 1983), e suas versões desacopladas; o Método de Gauss-Zbus (Chen et al., 1991) e; os métodos de varredura regressiva/progressiva (Shirmohammadi et al., 1988; Baran e Wu, 1989b; Rajičić e

Taleski, 1998). Os dois primeiros métodos podem ser usados tanto para redes radiais como para redes malhadas. No entanto, estes métodos têm custo computacional elevado devido a necessidade de solução de sistemas lineares de grande porte. Por outro lado, os métodos de varredura regressiva/progressiva exploram a topologia radial da rede de distribuição para calcular as tensões nodais. Em cada iteração destes métodos uma grandeza é acumulada na varredura regressiva (da carga para fonte), por exemplo: corrente, potência ou admitância. A acumulação destas grandezas é realizada usando-se princípios de circuitos elétricos, tais como: Lei de Kirchhoff das correntes, admitância equivalente e balanço de potência. A grandeza usada na acumulação da varredura regressiva determina a denominação do método de varredura. Desta forma, têm-se as três principais variantes do método de varredura regressiva/progressiva: soma de correntes (Shirmohammadi et al., 1988), soma de potências (Baran e Wu, 1989b) e soma de admitâncias (Rajičić e Taleski, 1998). Na varredura progressiva (da fonte para as cargas) as tensões nodais em cada iteração são calculadas usando-se a Lei de Kirchhoff das tensões para todas as variantes. O processo iterativo é repetido até que um critério de convergência seja satisfeito, por exemplo, quando o desvio máximo entre as magnitudes das tensões nodais entre iterações consecutivas é menor do que uma tolerância especificada. Os métodos de varredura tem baixo custo computacional com relação aos métodos de Newton-Raphson e de Gauss-Zbus, pois eles não exigem a solução de sistemas lineares de grande porte. O único pré-requisito para os métodos de varredura é a ordenação dos ramos em ordem crescente de camada. Uma camada é o número de ramos entre o nó final de um ramo e o nó fonte (barra da subestação). Esta ordenação pode ser facilmente realizada usando-se algoritmos de busca em grafos. Devido a isso, o método de soma de correntes é usado nesta proposta de tese para calcular as perdas resistivas e avaliar as restrições de tensão e carregamento. Esta escolha é também devido ao fato de que o equacionamento do método de soma de correntes nas varreduras regressiva/progressiva é muito mais simples do que os dos métodos de soma de admitâncias e de potências.

O cálculo do fluxo de potência também permite identificar se as restrições de tensão (intervalo definido em (4.21)) e de carregamento (desigualdade definida em (4.22)) foram violadas. As técnicas usadas para a modelagem de restrições são dependentes do tipo de paradigma usado para solucionar o problema de otimização multiobjectivo como, por exemplo, conjuntos nebulosos (Raposo et al., 2018) ou teoria

Pareto (Raposo et al., [2019a](#); Raposo et al., [2020](#)). O detalhamento da técnica de modelagem das restrições será apresentado no próximo capítulo, no qual cada um destes paradigmas será explicado.

METODOLOGIA MULTI OBJETIVO PARA A SOLUÇÃO CONJUNTA DOS PROBLEMAS DE RECONFIGURAÇÃO E ALOCAÇÃO DE MEDIDORES VIA BRKGA

6.1 Introdução

Este capítulo tem como objetivo apresentar uma metodologia para a solução simultânea dos problemas de RRD e alocação de medidores para minimizar as perdas de energia e melhorar a precisão do estimador de estado. É apresentada a formulação matemática multiobjetivo para solução conjunta desses problemas. Há inúmeros métodos que podem ser empregados para resolver problemas de otimização multiobjetivo (POMs), como o que esta tese aborda. O problema de otimização definido acima foi solucionado usando-se uma formulação multiobjetivo baseada no BRKGA combinado com a modelagem de múltiplos critérios fundamentada na teoria Pareto. As soluções contidas na fronteira de Pareto com menor custo de instalação de medidores serão selecionadas para todos os patamares de carga. No caso de haver uma topologia ótima para cada agrupamento de carga, a alocação ótima de medidores para o período anual é definido a partir de um SEN que seleciona o plano de medição com base em dois critérios: número mínimo de medidores e o menor risco de violação os limites para os erros relativos de magnitude e fase da tensão.

6.2 Conceitos da Teoria de Conjuntos Nebulosos

A lógica convencional ou clássica utiliza regras bem estruturadas para separar conjuntos. Entretanto, a teoria de conjuntos clássica não satisfaz problemas que apresentam alguma imprecisão, redundância, inconsistência ou informação inexata. Como exemplo, uma pessoa com 1,75 m pode ser considerada alta ou mediana, mas nunca os dois. Deste modo, deve-se elaborar relações/regras que diferenciem membros

de determinada classe a partir de suas características. Este processo de elaboração, geralmente, é complicado e não reflete a realidade do problema. Com base em tais fatos surgiu a teoria de conjuntos *fuzzy*. O termo *fuzzy*, do inglês, varia de acordo com o contexto, porém o conceito básico está associado aos termos vago, indistinto, incerto, difuso ou nebuloso.

A teoria de conjuntos nebulosos foi proposta por Lotfi A. Zadeh (1965) e difere da lógica clássica em suas características e detalhes. Nesta teoria, pode-se afirmar que o valor verdade de uma proposição é um subconjunto nebuloso de qualquer conjunto parcialmente ordenado. Em contra partida, nos sistemas convencionais, só existem duas possibilidades: verdadeiro ou falso. Em outras palavras, na lógica clássica os predicados são exatos, como *ímpar*, *par*, *maior que* e *menor que*, à medida que na lógica nebulosa os predicados são vagos, como *quente*, *frio*, *alto* e *baixo*. Além disso, nos sistemas convencionais, o modificador mais utilizado é a negação e há somente dois quantificadores: o existencial (\exists) e o universal (\forall). Por outro lado, na lógica nebulosa uma variedade de quantificadores são possíveis, como *pouco*, *muito*, *vários*, *frequentemente*, *usualmente*, *em torno de*, *menos* e *mais*. Nos sistemas multivalores, o valor verdade de uma proposição pode ser ou um elemento ou um conjunto finito, em um intervalo, ou uma álgebra booleana. Na lógica nebulosa, os valores verdade são expressos, linguisticamente, como *verdade*, *muito verdade*, *não verdade*, *falso*, *pouco falso*, em que cada termo linguístico é gerado através dos quantificadores e interpretado como um subconjunto nebuloso do intervalo unitário.

6.2.1 Representação de conjuntos nebulosos

Na clássica teoria de conjuntos, um elemento pertence ou não a um dado conjunto. Pode-se definir esta relação de pertencimento de um elemento x a um universo U como o grau de pertinência $\mu_A(x)$ com respeito a um conjunto $A \subseteq U$:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (6.1)$$

A função $\mu_A(x) : U \rightarrow \{0,1\}$ é chamada de função característica na teoria clássica de conjuntos.

Zadeh (1965) propôs uma generalização desta ideia, a fim de dar um tratamento matemático a conceitos vagos e imprecisos, sugerindo que alguns elementos pertencem ou são mais membros de um conjunto que outros. Deste modo, a função de pertinência pode assumir qualquer valor entre 0 e 1, de modo que 0 indica a exclusão completa do elemento e 1 representa a completa pertinência. Esta generalização expande a definição de função característica (Zadeh, 1988). Por exemplo, todos os números dentro de um intervalo de interesse terão um grau de pertinência 1, sendo 0 para todos os demais, como pode ser visto na Figura 6.1. Outro exemplo, é expressar a ideia de que a velocidade de um avião tem seu valor em torno de 865 km/h. Para isto, pode-se empregar uma função de pertinência triangular, com pico em 865 km/h, sugerindo a ideia de quanto mais próximo do pico, mais a velocidade se identifica com o conceito linguístico *em torno de 865 km/h*, como ilustrado na Figura 6.2.




Figura 6.1: Função de pertinência em que $\mu_A(x) = 1$ se, e somente se, $2 \leq x \leq 8$.




Figura 6.2: Função de pertinência que expressa a ideia de que a velocidade de um avião tem seu valor em torno de 865 km/h.

Seja U um conjunto de objetos x , então U é chamado de universo de discurso (domínio), podendo ser contínuo ou discreto. Um conjunto nebuloso A em um universo de discurso U é definido por uma função de pertinência μ_A que assume valores em um intervalo $[0,1]$ dado por (Zadeh, 1988):

$$\mu_A(x) : U \rightarrow [0,1] \quad (6.2)$$

O conjunto nebuloso A em U é, então, definido como o conjunto de pares ordenados $A = \{(\mu_A(x), x) \mid x \in U\}$. O conjunto suporte de um conjunto nebuloso A é o subconjunto dos pontos x de U tal que $\mu_A(x) > 0$. Assim, um conjunto nebuloso em que o conjunto suporte possui um único ponto $x \in U$ tal que $\mu_A(x) = 1$ é chamado de conjunto unitário nebuloso.

A função de pertinência pode assumir várias formas, entretanto as mais empregadas são: triangular (ver Figura 6.2), trapezoidal (ver Figura 6.3), gaussiana, exponencial e senoidal truncada (ver Figura 6.4).




Figura 6.3: Função de pertinência trapezoidal.

É importante destacar que o primeiro passo na representação de conjuntos nebulosos é a escolha da função de pertinência. A escolha desta função depende do problema a ser modelado e da capacidade computacional disponível para processar o que se deseja. Por exemplo, funções não-lineares, geralmente, são mais eficientes para problemas com alto nível de complexidade, entretanto elas demandam um alto custo computacional quando comparadas com funções de pertinência lineares (E.-Hawary, 1998; Gupta et al., 2010).




Figura 6.4: Função de pertinência senoidal truncada.

6.3 SEN para o Problema de Alocação de Medidores com RRD

De modo geral, o objetivo do SEN é modelar as ações através do conhecimento de um especialista, ao invés de, necessariamente, modelar o processo em si. A motivação para esta nova abordagem veio de casos onde o conhecimento de especialista na área de controle era disponível, seja por meio de operadores ou de projetistas. Além disso, os modelos matemáticos envolvidos eram muito dispendiosos ou complicados para serem desenvolvidos, diferentemente do que ocorre com os métodos tradicionais de controle. A estrutura básica de um SEN é mostrada na Figura 6.5, na qual enfatiza-se os seus componentes básicos: a interface de fuzzificação, a base de conhecimento, a base de dados, o procedimento de inferência e a interface de defuzzificação.

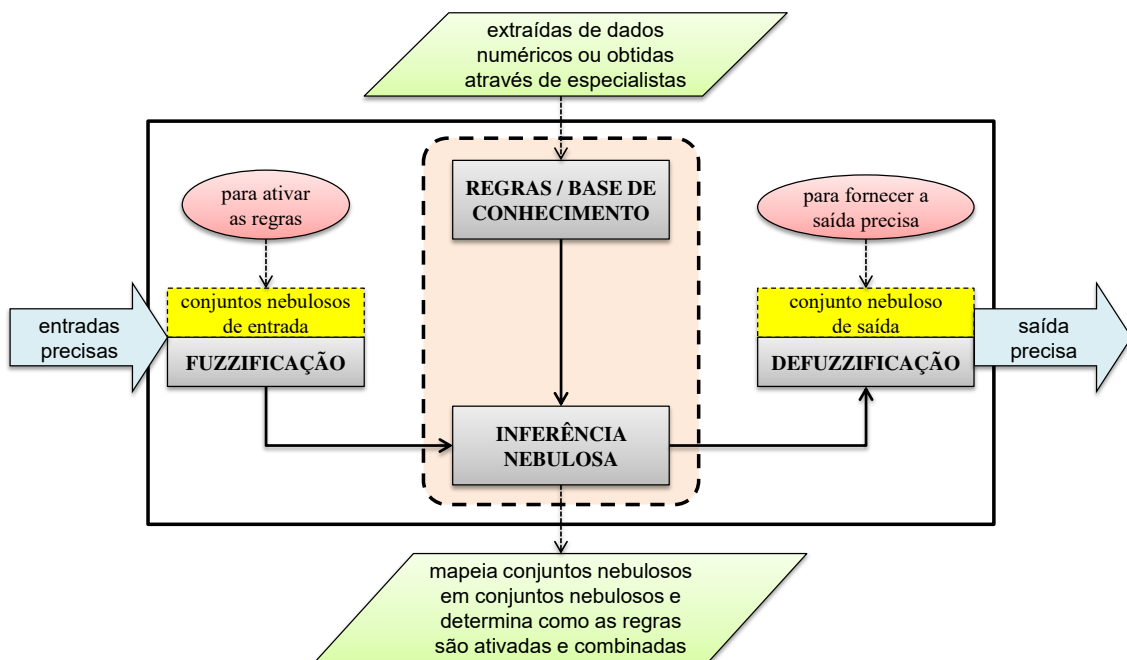


Figura 6.5: Estrutura básica de um SEN (Adaptado de Tanscheit (2007)).

A interface de fuzzificação obtém os valores das variáveis de entrada, faz um escalonamento para condicionar os valores em universos de discurso normalizados e fuzzifica os valores, transformando números em conjuntos nebulosos, de modo que possam se tornar instâncias de variáveis linguísticas (Gomide et al., 1995; Tanscheit,

2007). A base de conhecimento consiste de uma base de regras, caracterizando a estratégia de controle e suas metas. A base de dados armazena as definições necessárias sobre discretizações e normalizações dos universos de discurso, as partições nebulosas dos espaços de entrada e saída e as definições das funções de pertinência. Extrair regras de especialistas na forma de sentenças do tipo *se ... então* pode não ser uma tarefa fácil, por mais conhecedores que eles sejam do problema em questão (Tanscheit, 2007). Alternativamente, ao uso de especialistas para a definição da base de regras, existem métodos de extração de regras de dados numéricos. Estes métodos são particularmente úteis em problemas de classificação e previsão de séries temporais (Tanscheit, 2007; Deb et al., 2017). O procedimento de inferência processa os dados nebulosos de entrada, junto com as regras, de modo a inferir as ações de controle nebuloso, aplicando o operador de implicação nebuloso e as regras de inferência da lógica nebulosa (Gomide et al., 1995; Tanscheit, 2007). O estágio de defuzzificação transforma as ações de controle nebulosas inferidas em ações de controle não-nebuloso. Em seguida, efetua um escalamento, de modo a compatibilizar os valores normalizados vindos do passo anterior com os valores dos universos de discurso reais das variáveis (Gomide et al., 1995).

Após a inferência da ação de controle nebuloso, é necessária a determinação de uma ação de controle não-nebuloso que melhor represente a decisão nebulosa. Apesar de não haver nenhum procedimento sistemático para a escolha da estratégia de defuzzificação, as mais comuns incluem: o critério do máximo, que escolhe o ponto onde a função inferida tem seu máximo; a média dos máximos, que representa o valor médio dentre todos pontos de máximo quando existe mais de um máximo, e; o método do centro de área, que retorna o centro de área da função inferida (Gomide et al., 1995).

A metodologia multiobjetivo baseada no BRKGA proposta nesta tese para solução concorrente dos problemas de alocação de medidores e RRD possui duas formulações: uma baseada numa alocação pós-reconfiguração e a outra fundamentada numa alocação simultânea à RRD. Em ambas as abordagens, as soluções contidas na fronteira de Pareto com menor custo de instalação de medidores serão selecionadas para todos os patamares de carga. Desta forma, define-se um SIN que seleciona o plano de medição com base em dois critérios: número mínimo de medidores e o menor risco de violação dos limites para os erros relativos de magnitude e fase da tensão. As principais características deste SEN são:

(i) variáveis de entrada / saída: as variáveis de entrada são riscos nodais e número de medidores. Para ambas as variáveis de entrada, as variáveis linguísticas são *alto*, *médio* e *baixo*. A variável de saída é o tipo de sistema de medição. As variáveis linguísticas para o tipo de plano de medição são: *plano ótimo*, *plano aceitável*, *plano regular*, *plano médio*, *plano crítico* e *plano ruim*;

(ii) funções de pertinência: triangular e trapezoidal para as variáveis de entrada e saída;

(iii) base de conhecimento: baseada no operador *max-prod*. Para este SEN, existem 9 regras geradas a partir das combinações de variáveis de entrada *alto*, *médio* e *baixo*, a saber:

Regra #1: SE número de medidores é baixo E risco de violação baixo ENTÃO plano ótimo;

Regra #2: SE número de medidores é baixo E risco de violação médio ENTÃO plano aceitável;

Regra #3: SE número de medidores é baixo E risco de violação alto ENTÃO plano regular;

Regra #4: SE número de medidores é médio E risco de violação baixo ENTÃO plano aceitável;

Regra #5: SE número de medidores é médio E risco de violação médio ENTÃO plano médio;

Regra #6: SE número de medidores é médio E risco de violação alto ENTÃO plano crítico;

Regra #7: SE número de medidores é alto E risco de violação baixo ENTÃO plano regular;

Regra #8: SE número de medidores é alto E risco de violação médio ENTÃO plano crítico;

Regra #9: SE número de medidores é alto E risco de violação alto ENTÃO plano ruim;

(iv) processo de desfuzzificação: o método do centro de área.

As regras #2 e #4, #3 e #7, bem como #6 e #8 podem ser agrupadas em uma única regra, gerando os seis tipos de variáveis linguísticas do plano de medição. A Tabela 6.1 resume as 9 regras geradas a partir das combinações de variáveis de entrada.

A partir da base de conhecimento definida acima, nota-se que se dois planos de medição possuem o mesmo número de medidores, então a preferência do SEN será pelo plano com o menor risco de violar a precisão do estimador de estado.

Tabela 6.1: Regras geradas a partir das combinações de variáveis de entrada do SEN.

		Risco de Violação da Precisão do Estimador		
		<i>baixo</i>	<i>médio</i>	<i>alto</i>
Número de Medidores do Plano de Medição	<i>baixo</i>	Plano Ótimo	Plano Aceitável	Plano Regular
	<i>médio</i>	Plano Aceitável	Plano Médio	Plano Crítico
	<i>alto</i>	Plano Regular	Plano Crítico	Plano Ruim

A Figura 6.6 ilustra a superfície SEN produzida a partir das 9 regras geradas a partir das combinações de variáveis de entrada *alto*, *médio* e *baixo* para o risco de violar a precisão do estimador (R^{max}) e número de medidores (N^{meter}) do plano de medição.




Figura 6.6: Superfície do SEN produzida a partir das 9 regras geradas a partir das combinações de variáveis de entrada *alto*, *médio* e *baixo*.

6.4 Conceitos da Teoria Pareto

Muitos problemas do mundo real apresentam uma grande quantidade de objetivos a serem otimizados que são, em sua grande maioria, conflitantes entre si. Ou seja, é impossível melhorar algum objetivo sem deteriorar algum outro. Estes problemas são conhecidos como POMs.

Diferentemente de outros algoritmos evolucionários, a extensão do algoritmo BRKGA para a otimização multiobjetivo ocorre de forma bem discreta e com poucas aplicações no campo da engenharia (Zheng, Chien e Gen, 2015; Tangpattanakul, Jozefowicz e Lopez, 2013; Silva et al., 2013). Os poucos trabalhos existentes fazem uso do conceito de dominância entre soluções a fim de construir a fronteira de Pareto – de modo semelhante ao NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) (Deb et al., 2002) – ou construir a população elite.

Outra forma de solucionar simultaneamente os problemas de RRD e alocação de medidores é usar o conceito de dominância entre soluções para construir a fronteira de Pareto e preencher a população elite em uma abordagem multiobjetivo do BRKGA. Entretanto, antes de descrever esta metodologia alternativa, faz-se necessário introduzir alguns conceitos da teoria Pareto em POMs.

Os POMs são conhecidos como multiobjetivo/multicritério/multidesempenho ou otimização vetorial. Eles distinguem-se dos problemas clássicos de otimização monobjetivo com relação ao conceito de solução do problema. Por se tratar de objetivos conflitantes, cada objetivo corresponde a uma solução ótima individual na otimização multiobjetivo. Portanto, não é possível encontrar uma única solução que simultaneamente otimize todos os objetivos. Isso faz com que esses problemas apresentem um conjunto ótimo de compromissos entre os objetivos, denominado de conjunto de soluções Pareto-ótimas (fronteira de Pareto ótima) ou soluções não-dominadas. A escolha de uma solução particular depende das características do problema e é atribuída ao tomador de decisão.

A Figura 6.7 ilustra o conjunto de soluções Pareto-ótimas para um problema de minimização com duas funções f_1 e f_2 . Pode-se verificar que nenhum objetivo pode ser melhorado sem degradar o outro.




Figura 6.7: Exemplo de uma fronteira de Pareto.

Em um POM, emprega-se o conceito de dominância de Pareto para comparar duas soluções factíveis do problema.

Definição 1: Dadas duas soluções \mathbf{x} e \mathbf{y} , diz-se que \mathbf{x} domina \mathbf{y} (denotado como $\mathbf{x} \preceq \mathbf{y}$) se as seguintes condições são satisfeitas: (i) a solução \mathbf{x} é pelo menos igual a \mathbf{y} em todas as funções objetivo; (ii) a solução \mathbf{x} é estritamente melhor que \mathbf{y} em pelo menos uma função objetivo.

Definição 2: Dadas duas soluções \mathbf{x} e \mathbf{y} , diz-se que \mathbf{x} não domina e nem é dominada por \mathbf{y} (denotado como $\mathbf{x} \not\preceq \mathbf{y}$) se as seguintes condições são satisfeitas: (i) a solução \mathbf{x} não é pelo menos igual a \mathbf{y} em todas as funções objetivo; (ii) a solução \mathbf{x} não é estritamente melhor que \mathbf{y} em pelo menos uma função objetivo.

Estas definições são fundamentais, pois a partir delas é possível analisar um POM com restrições. Problemas com restrições são tratados com uma simples modificação na definição de dominância.

Definição 3: Dadas duas soluções \mathbf{x} e \mathbf{y} , diz-se que \mathbf{x} domina \mathbf{y} com restrições (denotado como $\mathbf{x} \preceq^r \mathbf{y}$) se as seguintes condições são satisfeitas: (i) a solução \mathbf{x} é factível e \mathbf{y} não é factível; (ii) ambas as soluções são infactíveis, mas a solução \mathbf{x} viola menos as restrições que \mathbf{y} ; (iii) ambas as soluções são factíveis e a solução \mathbf{x} domina \mathbf{y} .

A **Definição 3** é conhecida como dominância restrita (Deb et al., 2002). Através do conceito de dominância, um conjunto de soluções para um POM pode ser dividido em um conjunto de soluções dominadas e outro de não-dominadas.

Definição 4: Dado um conjunto de soluções \mathbb{P} , o conjunto não-dominado \mathbb{P}' é formado por: $\mathbb{P}' = \{x \in \mathbb{P} \mid \nexists y: y \preceq x\}$.

Dessa forma, quando o conjunto de soluções \mathbb{P} corresponde ao conjunto de soluções factíveis de um POM, o conjunto não-dominado \mathbb{P}' é chamado de conjunto Pareto-ótimo.

A partir da definição acima, a fronteira de Pareto para um POM pode ser definida da seguinte forma:

Definição 5: Dado um POM com f_m ($m = 1, \dots, N_{obj}$) funções objetivo e cujo conjunto Pareto-ótimo é \mathbb{P}' . A fronteira de Pareto \mathcal{PF} é formada por: $\mathcal{PF} = \{f(x) \mid x \in \mathbb{P}'\}$, em que $f(x) = \{f_1(x), f_2(x), \dots, f_{N_{obj}}(x)\}$ é o vetor de funções objetivo para a solução x .

Para a minimização de um POM, o vetor $f(x^*) = \{f_1(x^*), f_2(x^*), \dots, f_{N_{obj}}(x^*)\}$ é dito ideal se, e somente se, $f_m(x^*) = \min\{f_m(x^*) \mid x^* \in \mathbb{P}'\}$ para $m = 1, \dots, N_{obj}$. O vetor ideal (ponto de utopia/ponto ideal) é aquele que permite a cada uma das m funções objetivo alcançar o seu ótimo. Apesar de ser improvável a obtenção do ponto de utopia como solução para um POM, a sua definição é de grande interesse durante o processo de tomada de decisão, visto que o decisor pode optar por pontos da \mathcal{PF} o mais próximo possível, segundo uma determinada métrica, do vetor ideal $f(x^*)$.

O processo de otimização multiobjetivo é composto de duas etapas básicas: determinação de soluções e tomada de decisão. Como essas etapas podem ocorrer em ordens diversas e isso tem impacto sobre o processo, os métodos podem ser classificados segundo a forma como estruturam a tomada de decisão e a determinação de soluções ótimas. Neste sentido, os métodos podem ser classificados em três categorias: métodos *a priori*, métodos *a posteriori* e métodos interativos.

Nesta tese, utilizou-se o método interativo, pois a tomada de decisão foi realizada durante a busca de soluções. Assim, a fronteira de Pareto é dinamicamente construída através do conceito de dominância entre soluções.

6.5 Formulação Multiobjetivo Pareto para o Problema de Alocação de Medidores com RRD

O POM associado ao RRD e à alocação de medidores visa minimizar a perda anual de energia sem sacrificar a precisão do estado estimado. Além disso, as metas de acurácia do estimador precisam ser obtidas com baixo custo de instalação de medidores para a concessionária de distribuição. Na alocação pós-reconfiguração (a RRD é realizada antes da alocação de medidores), esses objetivos conflitantes são alcançados através da solução do seguinte problema de otimização:

$$\begin{aligned} \min \quad & F(X) := \{F_1(X), F_2(X)\} \\ \text{sujeito a:} \quad & \text{Restrição (4.11)} \end{aligned} \quad (6.3)$$

De modo semelhante, na solução simultânea dos problemas de RRD e alocação de medidores, os objetivos identificados no capítulo 4 são otimizados através do modelo matemático definido abaixo:

$$\begin{aligned} \min \quad & F(Z) := F(X, Y) = \{F_2(X), F_3(X), F_4(Y)\} \\ \text{sujeito a:} \quad & \text{Restrições (4.17) e (4.19) a (4.24)} \end{aligned} \quad (6.4)$$

O algoritmo proposto neste trabalho para solucionar (6.3) e (6.4) é denominado de MOBRKGA daqui por diante. O MOBRKGA utiliza o conceito de dominância entre soluções para construir a fronteira de Pareto e preencher a população elite em uma abordagem multiobjetivo do BRKGA. Adicionalmente, o MOBRKGA usa o método ANEC2PDF para calcular índices de precisão do estimador de estado na solução concorrente dos problemas de alocação de medidores e RRD.

Um cromossomo C_i e uma solução $Z_i = (X_i, Y_i)$ no MOBRKGA são definidos como sendo $C_i = [c_{i1}, \dots, c_{iD}]$ e $Z_i = (X_i, Y_i) = [x_{i1}, \dots, x_{iNB}, y_{i1}, \dots, y_{iNR}]$, respectivamente. Em que $D = NB + NR$ é a dimensão do espaço de busca. Com esta definição, as primeiras NB posições de C_i e Z_i estão associadas com o problema de alocação de medidores e as últimas NR posições de C_i e Z_i estão associadas ao problema de RRD. Os operadores especiais de *crossover*, mutação e decodificação para o MOBRKGA atender a restrição de radialidade já foram introduzidos no capítulo 5.

Desta forma, será descrita apenas a fase de decodificação de uma solução para o problema de alocação de medidores.

A decodificação de uma solução Z_i no MOBRKGA para o processo de alocação de medidores ocorre do seguinte modo: “uma barra j de um cromossomo C_i contém um medidor se $c_{ij} \geq P_{EM}$ para $j = 1, \dots, NB$, onde: $P_{EM} = 0,5$ é a probabilidade de existir um medidor em uma barra da rede de distribuição. Se $c_{ij} < P_{EM}$, então não há medidor instalado nesta barra. Dessa forma, se $c_{ij} \geq P_{EM}$, então $x_{ij} \leftarrow 1$. Caso contrário, $x_{ij} \leftarrow 0$ ”.

Como foi visto no capítulo 5, a topologia da rede de distribuição é representada segundo o grafo $G(NB, NR)$ com NB vértices e NR ramos. Desta forma, as configurações e planos de medição iniciais podem ser obtidos de acordo com os Algoritmos 6.1 e 6.2.

Algoritmo 6.1: Pseudocódigo de inicialização do BRKGA

#Especificar:

O tamanho da população p_t ;

O número aleatório distribuído uniformemente no intervalo $[0,1]$ u ;

O i -ésimo cromossomo C_i ;

A posição de C_i associada com a subestação s ($1 \leq s \leq NB$).

para i de 1 até p_t **faça**

#Fase de reconfiguração da rede.

1. Gerar uma árvore C_i de acordo com o Algoritmo 6.2;

#Fase de alocação de medidores.

para j de 1 até NB **faça**

$u \leftarrow rand(0,1)$;

$c_{ij} \leftarrow P_{EM} \cdot u$;

se $u \geq 0,5$ **então**

$c_{ij} \leftarrow P_{EM} \cdot (1 + u)$;

fim se

fim para

$c_{is} \leftarrow 1$;

fim para

retornar C

O Algoritmo 6.1 sempre irá produzir soluções que satisfazem a restrição de radialidade e com um medidor sempre instalado na subestação.

Algoritmo 6.2: Pseudocódigo para obter uma árvore no BRKGA

#Especificar:

- O grafo $G(NB, NR)$ com NB vértices e NR ramos;
- Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado $(s, r) SR[j]$;
- O i -ésimo cromossomo C_i ;
- O número de ramos raiz $|R|$;
- O número aleatório distribuído uniformemente no intervalo $[0,1] u$.

$T \leftarrow \emptyset$;

#Inicialização da árvore T com o conjunto de ramos raiz.

para j de 1 até $|R|$ **faça**

- $(u, v) \leftarrow SR[j]$;
- $T \leftarrow T \cup \{(u, v)\}$;
- $m \leftarrow j + NB$;
- $c_{im} \leftarrow 1$;

fim para

#Construção da árvore T de forma aleatória.

enquanto $|T| < NB - 1$ **faça**

1. Aleatoriamente escolha um ramo $p \in G$ e faça $(u, v) \leftarrow SR[p]$;

se $p \notin T$ **então**

se p não forma uma malha em T e p está conectado com alguma barra em T **então**

- $T \leftarrow T \cup \{(u, v)\}$;
- $u \leftarrow rand(0,1)$;
- $m \leftarrow j + NB$;
- $c_{im} \leftarrow P_{CR} + u \cdot (1 - P_{CR})$;

fim se

fim se

fim enquanto

retornar C_i

Para as operações de mutação e *crossover*, a técnica proposta para gerar novas configurações radiais baseia-se nos algoritmos de mutação e *crossover* propostos em (Raidl, 2000). Os algoritmos 6.3, 6.4, 6.5 e 6.6 descrevem esses operadores.

Algoritmo 6.3: Pseudocódigo de mutação no BRKGA – Fase de reconfiguração

#Especificar:

- Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
- A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado $(s, r) SR[j]$;
- O k -ésimo cromossomo C_k ;
- O cromossomo com mutação C^{mut} ;
- O número aleatório distribuído uniformemente no intervalo $[0,1] u$.

```

 $T \leftarrow \emptyset;$ 
para  $j$  de  $NB + 1$  até  $D$  faça
     $C_j^{mut} \leftarrow c_{kj};$ 
     $m \leftarrow j - NB;$ 
     $(s, t) \leftarrow SR[m];$ 
    se  $c_{kj} \geq P_{CR}$  então
         $T \leftarrow T \cup \{(s, t)\};$ 
    fim se
fim para
1. Aleatoriamente selecione um ramo  $p \in G$  tal que  $p \notin T$ ;
 $(a, b) \leftarrow SR[p];$ 
2. Obter o conjunto  $L$  de todos os ramos em  $T$  que formam um caminho fechado entre os nós  $a$  e  $b$ , isto é,  $L \leftarrow \{(k, l) \mid (k, l) \text{ formam um caminho fechado entre } a \text{ e } b\};$ 
3. Aleatoriamente selecione um ramo  $q$  tal que  $q \in L - \{(a, b)\};$ 
 $(u, v) \leftarrow SR[q];$ 
 $T \leftarrow T \cup \{(a, b) \setminus (u, v)\};$ 
 $u \leftarrow rand(0,1);$ 
 $C_p^{mut} \leftarrow P_{CR} + u \cdot (1 - P_{CM});$ 
 $C_q^{mut} \leftarrow P_{CR} \cdot u;$ 
retornar  $C^{mut}$ 

```

Algoritmo 6.4: Pseudocódigo de mutação do BRKGA – Fase de alocação

#Especificar:

- O k -ésimo cromossomo C_k ;
- A taxa de mutação mr ($0 \leq mr \leq 1$);
- O plano de medição MP^{out} ;
- A posição de MP^{out} associada com a subestação s ($1 \leq s \leq NB$);
- O número aleatório distribuído uniformemente no intervalo $[0,1]$ u .

```

para  $j$  de 1 até  $NB$  faça
     $MP_j \leftarrow c_{kj};$ 
fim para
para  $j$  de 1 até  $NB$  faça
     $u \leftarrow rand(0,1);$ 
    se  $u \leq mr$  e  $MP_j < P_{EM}$  então
         $MP_j^{out} \leftarrow P_{EM} \cdot (1 + u);$ 
    fim se
    se  $u \leq mr$  e  $MP_j \geq P_{EM}$  então
         $MP_j^{out} \leftarrow P_{EM} \cdot u;$ 
    fim se
fim para
 $MP_s^{out} \leftarrow 1;$ 
retornar  $MP^{out}$ 

```

Algoritmo 6.5: Pseudocódigo de *crossover* do BRKGA – Fase de reconfiguração

#Especificar:

Os k -ésimo e m -ésimo cromossomos C_k e C_m ;
Árvore $T(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
O cromossomo com crossover C^{cross} ;
O índice p com $p \in \{k, m\}$;
Árvores $T_p(NB, E)$ com NB vértices e E ramos ($E = NB - 1$);
O número aleatório distribuído uniformemente no intervalo $[0,1]$ u ;
A função que retorna o nó inicial s e o nó final r do ramo j em um par ordenado (s, r) $SR[j]$.

$T_p \leftarrow \emptyset$;

para j de $NB + 1$ até D **faça**

$q \leftarrow j - NB$;

$(u, v) \leftarrow SR[q]$;

se $c_{pq} \geq P_{CR}$ **então**

$T_p \leftarrow T_p \cup \{(u, v)\}$;

fim se

fim para

$T^{out} \leftarrow T_k \cap T_m$;

$F_{km} \leftarrow (T_k \cup T_m) \setminus T^{out}$;

enquanto $|T^{out}| < N^{node} - 1$ **faça**

 1. Aleatoriamente selecione um ramo $p \in F_{km}$ e faça $(u, v) \leftarrow SR[p]$;

se p não forma uma malha em T^{out} e p está conectado com alguma barra em T^{out}

então

$T^{out} \leftarrow T^{out} \cup \{(u, v)\}$;

fim se

fim enquanto

para j de $NB + 1$ até D **faça**

$u \leftarrow rand(0,1)$;

$q \leftarrow j - NB$;

$C_q^{cross} \leftarrow P_{CR} \cdot u$;

$(s, t) \leftarrow SR[q]$;

se $(s, t) \in T^{out}$ **então**

$C_q^{cross} \leftarrow P_{CR} \cdot (1 + u)$;

fim se

fim para

$MP_s^{out} \leftarrow 1$;

retornar C^{cross}

Algoritmo 6.6: Pseudocódigo de *crossover* do BRKGA – Fase de alocação

#Especificar:

Os k -ésimo e m -ésimo cromossomos C_k e C_m ;

O plano de medição MP^{out} ;

O número aleatório distribuído uniformemente no intervalo $[0,1]$ u .

```

para  $j$  de 1 até  $NB$  faça
   $MP_j^k \leftarrow c_{kj};$ 
   $MP_j^m \leftarrow c_{mj};$ 
fim para
para  $j$  de 1 até  $NB$  faça
   $u \leftarrow rand(0,1);$ 
   $MP_j^{out} \leftarrow MP_j^k;$ 
  se  $u \geq 0,5$  então
     $MP_j^{out} \leftarrow MP_j^m;$ 
  fim se
fim para
retornar  $MP^{out}$ 

```

O MOBRKGA proposto nesta tese para RRD e alocação de medidores pode ser resumido através dos fluxogramas mostrados na Figura 6.8. Na Figura 6.8 (a) é mostrado o fluxograma para o paradigma de alocação de medidores pós-reconfiguração. Ou seja, primeiro as topologias ótimas são determinadas para reduzir as perdas anuais de energia e, em seguida, a alocação de medidores é realizada para cada topologia visando melhorar a precisão do estimador de estado. Essa abordagem produz uma fronteira de Pareto relacionada ao problema de alocação de medidores para cada topologia ótima gerada pela RRD. As soluções da fronteira de Pareto contendo o menor número de medidores e o menor risco de violação os limites para os erros relativos serão selecionadas para todos os agrupamentos de carga. No caso de haver uma topologia para cada agrupamento de carga, o plano de medição ideal para o período anual é definido a partir do SEN que seleciona o plano de medição, contido na fronteira de Pareto, com base em dois critérios: número mínimo de medidores e o menor risco de violação os limites para os erros relativos. Na Figura 6.8 (b) é mostrado o fluxograma para a solução simultânea dos problemas de RRD e alocação de medidores, considerando vários patamares de carga. Nesta abordagem, uma solução da fronteira de Pareto corresponde a um único plano de medição e topologia ótima.

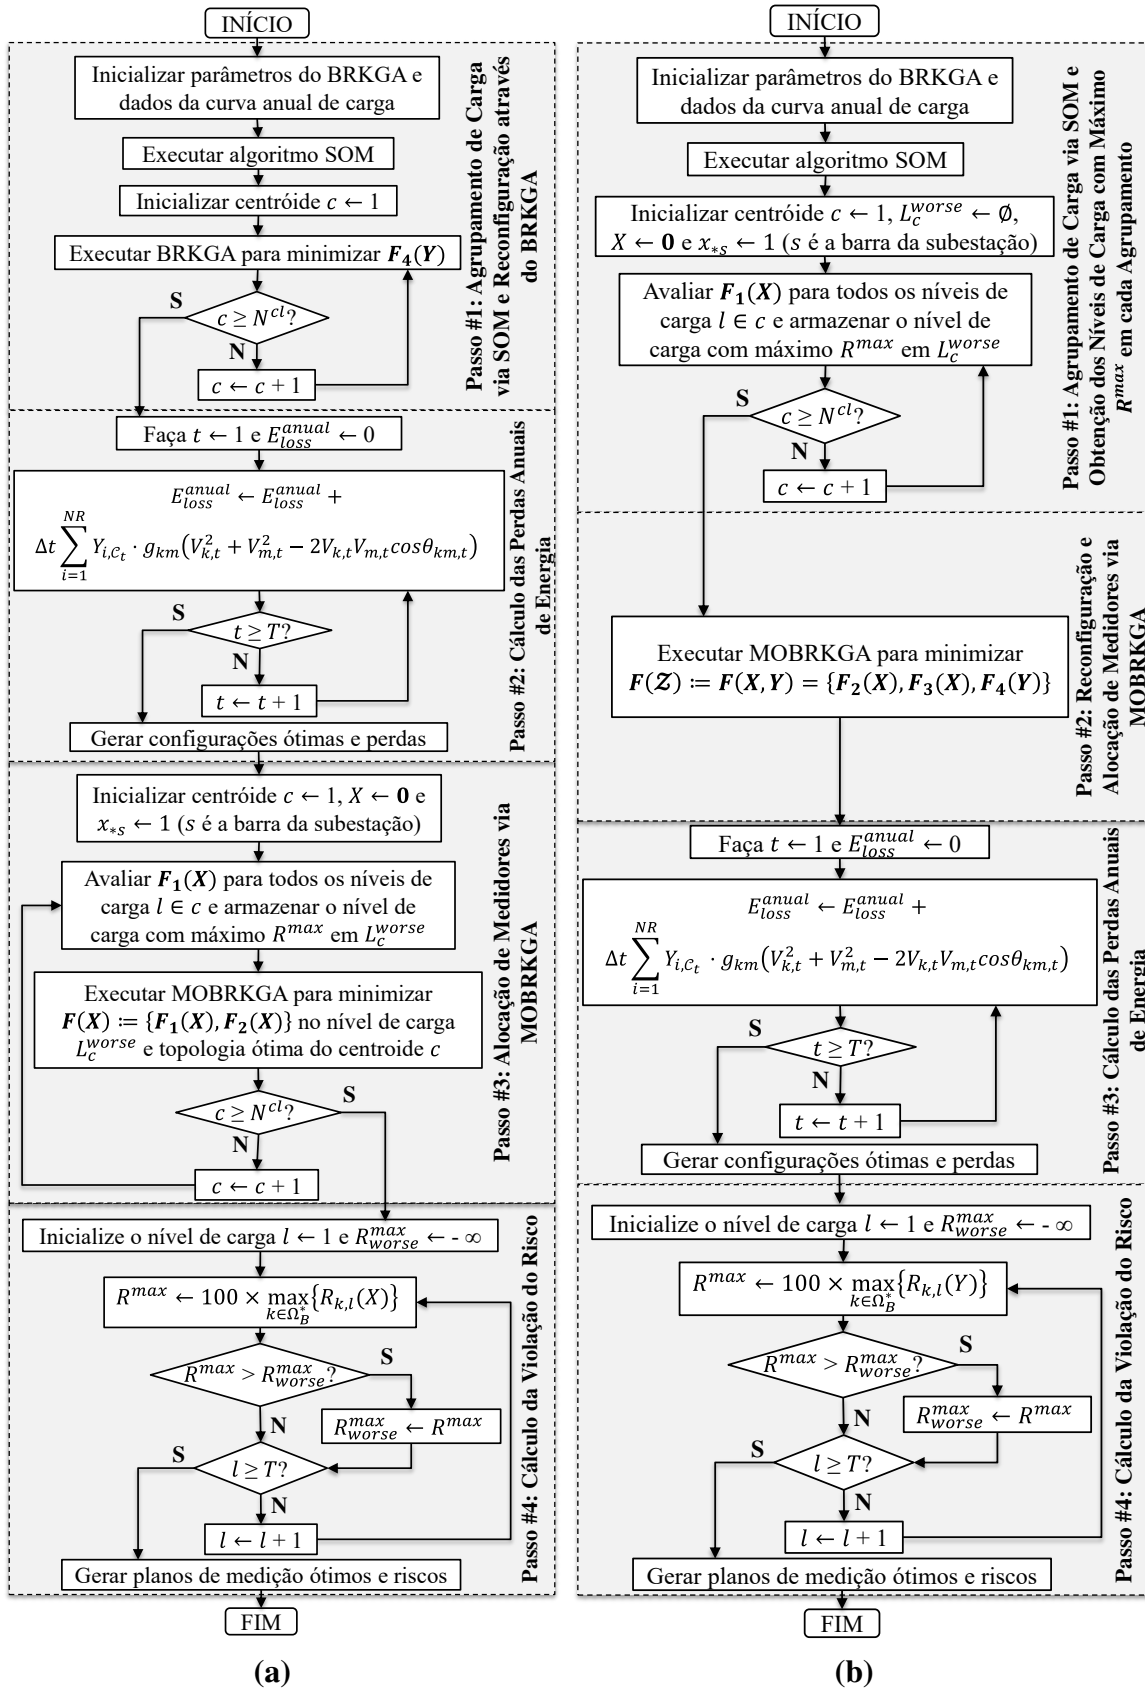


Figura 6.8: Fluxogramas dos algoritmos. (a) Algoritmo para minimização anual de perda de energia através da RRD e alocação de medidores pós-RRD. (b) Algoritmo para solução simultânea da minimização anual de perda de energia via RRD e alocação de medidores.

É importante discutir as diferenças entre as duas abordagens ilustradas nas Figuras 6.8 (a) e 6.8 (b). Conforme antes mencionado, a Figura 6.8 (a) está relacionada com o paradigma de alocação pós-reconfiguração. Desta forma, espera-se que o custo de restauração da precisão (custo de instalação de medidores) deste paradigma, caso a haja degradação da acurácia pela RRD, seja superior ao do paradigma de reconfiguração concorrente a reconfiguração da Figura 6.8 (b). Este aumento nos custos de instalação de medidores se deve ao fato de que no paradigma de alocação pós-reconfiguração a modificação da topologia da rede não é explorada para melhorar a precisão do estimador de estado. Em outras palavras, a RRD é realizada exclusivamente com o objetivo de minimizar as perdas anuais de energia. Esta diferença será comprovada na seção de resultados.

6.6 Avaliação da Performance de Métodos de Otimização Multiobjetivo

Com o objetivo de avaliar a performance em relação a quantidade e qualidade das soluções produzidas através do MOBRKGA realizou-se uma comparação com a meta-heurística NSGA-II. Excluindo-se a estratégia associada com a quantidade de soluções na fronteira de Pareto, há duas abordagens para a comparação do desempenho de dois ou mais algoritmos de otimização multiobjetivo: uma é baseada nas métricas de convergência e outra nas métricas de diversidade das soluções encontradas. As métricas de convergência podem comparar soluções P encontradas com o conjunto de soluções Pareto-ótimas do problema, denominado P' . Além disso, é possível usar estas métricas para comparar (de forma relativa) soluções P produzidas por um algoritmo com soluções Q produzidas por outro algoritmo. Abaixo seguem as definições matemáticas e interpretações das métricas de convergência adotadas neste trabalho:

(i) Taxa de Erro (ER – *Error Ratio*) (Riquelme et al., 2015): este índice calcula o número de soluções em P que não estão em P' :

$$ER = \frac{|P \setminus P'|}{|P|} \quad (6.5)$$

em que $|\cdot|$ representa a cardinalidade de um conjunto de elementos. Quanto menor for o valor de ER , melhor será a convergência. Se $ER = 0$, então $P \subseteq P'$. Este índice é aplicável apenas a problemas de otimização discreta.

(ii) Métrica de Distância Geracional (GDM – *Generational Distance Metric*) (Veldhuizen, 1999): este índice representa a distância euclidiana média (no espaço dos objetivos) entre as soluções de P e P' :

$$GDM = \frac{\sum_{s \in P} mindist_s}{|P|} \quad (6.6)$$

em que $mindist_s$ representa a distância euclidiana no espaço dos objetivos entre a solução s e a solução mais próxima dela no conjunto P' :

$$mindist_s = \min_{t \in P'} \left\{ \sqrt{\sum_{m=1}^{N_{obj}} [f_m(s) - f_m(t)]^2} \right\} \quad (6.7)$$

em que N_{obj} é o número de funções objetivo que compõem o POM e $f_m(s)$ é o valor da função objetivo f_m para a solução s . Quanto mais próximo de zero for o valor de GDM , melhor será a convergência de P . Este índice pode ser aplicado a problemas de otimização discreta e contínua.

(iii) Métrica de Cobertura (SC – *Set Coverage*) (Zitzler e Thiele, 1999): dados dois conjuntos de soluções P e Q , essa métrica calcula a proporção de soluções de Q que são fracamente dominadas pelas soluções de P :

$$SC(P, Q) = \frac{|s \in P / \exists t \in Q \wedge s \preceq t|}{|Q|} \quad (6.8)$$

Quando $SC(P, Q) = 1$ todas as soluções de Q são dominadas por soluções de P . Se $SC(P, Q) = 0$, então nenhuma solução de Q é fracamente dominada pelas soluções em P .

As métricas de diversidade, por sua vez, calculam a distribuição das soluções de um conjunto. Abaixo seguem as definições matemáticas e interpretações das métricas de diversidade adotadas nesta tese:

(i) Espaçamento (SP – *Spacing*) (Schott, 1995): este índice representa o desvio-padrão entre as distâncias de soluções consecutivas (no espaço dos objetivos) do conjunto P :

$$SP = \sqrt{\frac{\sum_{s \in P} (\text{near}dist_s - \overline{\text{near}dist})^2}{|P| - 1}} \quad (6.9)$$

em que $\text{near}dist_s$ representa a distância euclidiana (no espaço dos objetivos) entre a solução s e a solução mais próxima dela no conjunto P , sendo expresso como:

$$\text{near}dist_s = \min_{t \in P', t \neq s} \left\{ \sqrt{\sum_{m=1}^{N_{obj}} [f_m(s) - f_m(t)]^2} \right\} \quad (6.10)$$

em que N_{obj} é o número de funções objetivo que compõem o POM e $f_m(s)$ é o valor da função objetivo f_m para a solução s . O valor de $\overline{\text{near}dist}$ é a média dos valores de $\text{near}dist_s$:

$$\overline{\text{near}dist} = \frac{\sum_{s \in P} \text{near}dist_s}{|P|} \quad (6.11)$$

Quanto menor for o valor da métrica SP , melhor distribuídas estão as soluções do conjunto P .

(ii) Dispersão (SPREAD) (Li e Zheng, 2009): este índice avalia o espalhamento das soluções no conjunto P ao longo da fronteira de Pareto, assim como a distribuição entre soluções vizinhas (no espaço dos objetivos) a P :

$$SPREAD = \frac{\sum_{m=1}^{N_{obj}} \text{ext}dist_m + \sum_{s \in P} |\text{near}dist_s - \overline{\text{near}dist}|}{\sum_{m=1}^{N_{obj}} \text{ext}dist_m + |P| \times \overline{\text{near}dist}} \quad (6.12)$$

em que $\text{ext}dist_m$ representa a distância euclidiana entre as soluções extremas na m -ésima função objetivo dos conjuntos P e Q :

$$\text{ext}dist_m = \text{dist}_{st} \mid s = \min_{k \in P} \{f_m(k)\} \wedge t = \min_{k \in Q} \{f_m(k)\} \quad (6.13)$$

no caso de minimização da função f_m . O valor ideal para *SPREAD* é 0.

(iii) Hipervolume (HV) (Zitzler e Thiele, 1999): neste índice, calcula-se o volume da região coberta entre os pontos das soluções do conjunto P encontradas e um ponto de referência. Para cada solução $s \in P$, é construído um hipercubo v_s com referência a um ponto W . O ponto de referência pode ser encontrado construindo-se um vetor com os piores valores de função-objetivo. O resultado da métrica é a união de todos os hipercubos encontrados. Quanto maior o valor do hipervolume melhor, pois um alto valor de hipervolume indica que houve um elevado espalhamento entre as soluções de P e indica também que houve uma melhor convergência. Essa métrica é calculada através de:

$$HV = \sum_{s \in P} v_s \quad (6.14)$$

em que v_s representa o hipercubo da solução s .

RESULTADOS DOS TESTES

7.1 Introdução

Neste capítulo apresenta-se os resultados dos testes com a metodologia proposta nesta tese: o MOBRKGA para RRD e alocação de medidores. Inicialmente, a metodologia foi implementada usando o MATLAB. Uma segunda implementação foi realizada utilizando a linguagem Julia a fim de comparar os tempos computacionais. As simulações foram realizados em PC com processador Intel Core i7-7500 CPU, 3.50 GHz com 8 GB de RAM e aplicadas no sistema de 69 barras (Baran e Wu, 1989a; Savier e Das, 2007) doravante denominado de S69. Todos os testes foram realizados considerando-se o modelo de sequência positiva do S69. O principal objetivo deste capítulo é validar a metodologia de alocação e RRD proposta no capítulo 6.

Os resultados apresentados nas próximas seções são organizados da seguinte forma:

1. A seção 7.2 apresenta uma descrição do sistema teste S69;
2. Na seção 7.3 apresentam-se considerações referentes aos testes;
3. Os resultados da abordagem multiobjetivo Pareto são demonstrados na seção 7.4;
4. A seção 7.5 apresenta uma análise de desempenho do MOBRKGA.

7.2 Descrição do Sistema Teste

O sistema teste utilizado para validação das metodologias propostas foi apresentado em (Baran e Wu, 1989a; Savier e Das, 2007). Este sistema teste possui 69 nós e 73 ramos e suas principais características são resumidas na Tabela 7.1.

Tabela 7.1: Principais dados do S69.

Número de barras	69
Número de ramos	73
Pico de carga ativa (kW)	3.802,19
Pico de carga reativa (kVAr)	2.694,60
Tensão nominal (kV)	12,66
Número de pontos de carga	48
Número de nós de injeções nulas	20
Perdas de energia com a configuração inicial (MWh)	570,5780

A configuração inicial do S69 considera 5 chaves abertas localizadas nos ramos (11/43), (13/21), (15/46), (50/59) e (27/65). A topologia inicial deste sistema é ilustrada na Figura 7.1. Para facilitar a visualização, a subestação está definida por um retângulo azul, os pontos de carga foram destacados com um círculo magenta e os nós de injeções nulas foram destacados com um círculo bege.




Figura 7.1: Diagrama unifilar do S69.

Excluindo-se o nó da subestação (nó #1) e os 48 pontos de carga, o restante do S69 é composto de 20 nós de injeções nulas, o que corresponde a quase 29% de todos os nós do sistema.

7.3 Hipóteses Assumidas nos Testes

Os testes no S69 foram realizados considerando-se que:

- i) O nó da subestação (SE), nó #1, é o nó de referência ($V\theta$) para todos os algoritmos propostos;
- ii) Os erros relativos especificados de tensão e ângulo são, respectivamente, $\epsilon_V \leq 1\%$ e $\epsilon_\theta \leq 5\%$;
- iii) A máxima violação de risco é $\bar{R} = 5\%$;
- iv) Os limites de tensão são $V_{min} = 0,9V_{ref} = 1,0$ p.u. e $V_{max} = 1,1V_{ref} = 1,1$ p.u., pois a tensão de referência do sistema teste, V_{ref} , é igual a 1,0 p.u. (Tahboub et al., 2015);
- v) Foi considerado um erro máximo de 1% associado às medições reais e de 50% associado às pseudo-medições;
- vi) Considera-se a correlação entre medições de injeção/fluxo de potência ativa e reativa igual a $\rho_{pq}^{P*} = \rho = 0,95$, onde $* \in \{I \vee F\}$ e; I e F denotam injeção e fluxo de potência, respectivamente;
- vii) O intervalo de tempo nos dados históricos da demanda corresponde a 30 minutos ($\Delta t = 0,5$), ou seja, existem 17520 patamares de carga para o período anual (Tahboub et al., 2015);
- viii) Para o MOBRKGA utilizou-se os seguintes parâmetros: tamanho da população (p_t) = 60; tamanho padrão da população elite (p_e^{std}) = $0,2p_t$; tamanho da população mutante (p_m) = $0,2p_t$; taxa de mutação (rm) = 50%; taxa de crossover de 60%; reinicialização a cada 50 gerações, e; número máximo de gerações (g^{max}) = 1000;
- ix) O ponto de utopia (U_{PF}) é o vetor $U_{PF} = [0,0 \ 0,0 \ 1]$. O primeiro elemento de U_{PF} está associado com as perdas anuais de energia. O segundo elemento está associado com um plano de medição 100% preciso. Por fim, o ultimo elemento de U_{PF} expressa que há no mínimo um medidor presente na rede: o medidor presente na subestação.
- x) Na solução do problema de alocação de medidores, as medições de tensão e injeção de potência na subestação foram consideradas como medições reais provenientes do SCADA. Os valores verdadeiros das medições de injeção de potência foram obtidas a partir da solução do fluxo de potência para um dado plano de medição.

Para análise de desempenho do algoritmo proposto foram adotados os seguintes estudos de caso:

- 1) **Caso #0 (caso base):** existe apenas um medidor instalado na subestação e a configuração inicial é adotada, ou seja, a RRD não é realizada;
- 2) **Caso #1:** o algoritmo MOBRKGA é aplicado ao caso #0 com o objetivo de minimizar $F_1(X)$ e $F_2(X)$, isto é, minimizar $F(X)$ definida em (6.3). Esse caso é equivalente a alocação convencional de medidores;
- 3) **Caso #2:** o MOBRKGA busca minimizar apenas $F_4(Y)$ com o plano de medição obtido no caso #1, ou seja, o caso #2 corresponde a tradicional RRD para minimizar a perda de energia anual. O objetivo deste caso é reduzir as perdas de energia anuais para uma ou quatro topologias com um plano de medição definido anteriormente à RRD;
- 4) **Caso #3:** o MOBRKGA é aplicado ao caso #0 para minimizar $F_4(Y)$. Em seguida, com uma ou quatro topologias obtidas da minimização $F_4(Y)$, o problema de otimização definido em (6.3) é resolvido, de acordo com o fluxograma da Figura 6.8 (a), para alocar medidores multifuncionais;
- 5) **Caso #4:** o algoritmo MOBRKGA é aplicado ao caso #0 para resolver o problema de otimização definido em (6.4), ou seja, para otimizar a topologia e a alocação de medidores multifuncionais em uma estrutura de múltiplos objetivos, como o fluxograma apresentado na Figura 6.8 (b).

7.4 Resultados dos Estudos de Casos

A Figura 7.2 mostra os riscos nodais e as perdas de potência ativa para o caso #0. A partir desta figura, pode-se observar que o risco nodal máximo R^{max} está acima do limite aceitável $\bar{R} = 5\%$ para todos os patamares de carga. Por exemplo, os valores mínimo e máximo de R^{max} são 63,4774% e 63,9909% para os patamares de carga #5006 e #2869, respectivamente. Além disso, pode-se notar que, com apenas um medidor na subestação e sem a RRD, as perdas ativas são reduzidas à medida que o risco de violação é reduzido. Esse efeito ocorre devido a erros nas pseudo-medições relacionadas aos medidores de potência que são funções do carregamento dos alimentadores. Desta forma, com a redução das cargas, os valores medidos são menores

e os erros aleatórios das medições também ficam menores. Consequentemente, a precisão do estimador de estado e as perdas são reduzidas à medida que a carga do alimentador é reduzida.

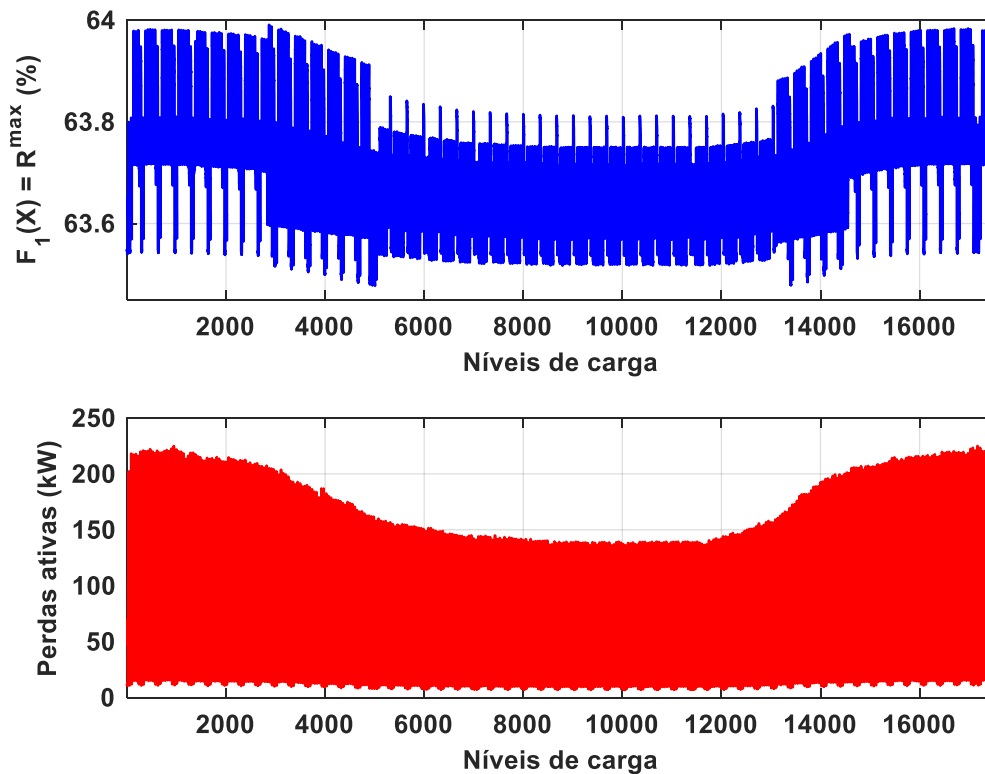


Figura 7.2: R^{max} (parte superior) e perdas ativas (parte inferior) para cada nível da curva de carga para o caso #0.

No caso #1, o MOBRKGA foi aplicado para obter um plano de medição para o S69 no patamar de carga #2869, porque este é o patamar crítico de carga em relação à precisão do estimador de estado (Raposo et al., 2017). A aproximação da fronteira de Pareto para este estudo de caso é ilustrada na parte superior da Figura 7.3. Essa fronteira é composta por dez soluções. Em relação aos custos do plano de medição, a solução mais econômica é a que contém seis medidores (solução identificada por um círculo azul na parte superior da Figura 7.3), pois as soluções com 7 e 8 medidores possuem a mesma classificação, segundo o SEN, do plano de medição com 6 medidores (ver Tabela 7.2). Este plano de medição é validado no S69, verificando-se a restrição (4.11) para todos os patamares de carga, como mostrado na parte inferior da Figura 7.3. A

partir desta figura, pode-se observar que $R^{max} \leq 5\%$ para todos os patamares de carga. Como exemplo, o valor máximo de R^{max} é 1,0578%.




Figura 7.3: Aproximação da Fronteira de Pareto para o caso #1 (parte superior) e risco nodal (parte inferior), considerando um plano de medição com 6 medidores instalados.

Tabela 7.2: Elementos da fronteira de Pareto para o caso #1.

Solução $Z_i (X_i)$	$R^{max} = F_1(X) (\%)$	$N^{meter} = F_2(X)$	SIN
1	1,0000E-15	24	Plano regular
2	8,5187E-10	19	Plano aceitável
3	1,0517E-07	17	Plano aceitável
4	6,8909E-04	14	Plano aceitável
5	1,3828E-02	13	Plano aceitável
6	1,2579E-01	11	Plano aceitável
7	3,1001E-01	9	Plano aceitável
8	5,5975E-01	8	Plano ótimo
9	6,9292E-01	7	Plano ótimo
10	9,7924E-01	6	Plano ótimo

Os elementos desta fronteira são apresentados na Tabela 7.2, com destaque para a solução Pareto ótima segundo a menor norma Euclidiana em relação a U_{PF} . A Figura 7.4 mostra a execução do SEN para $F_1(X) = 0,9792\%$ e $F_2(X) = 6$.

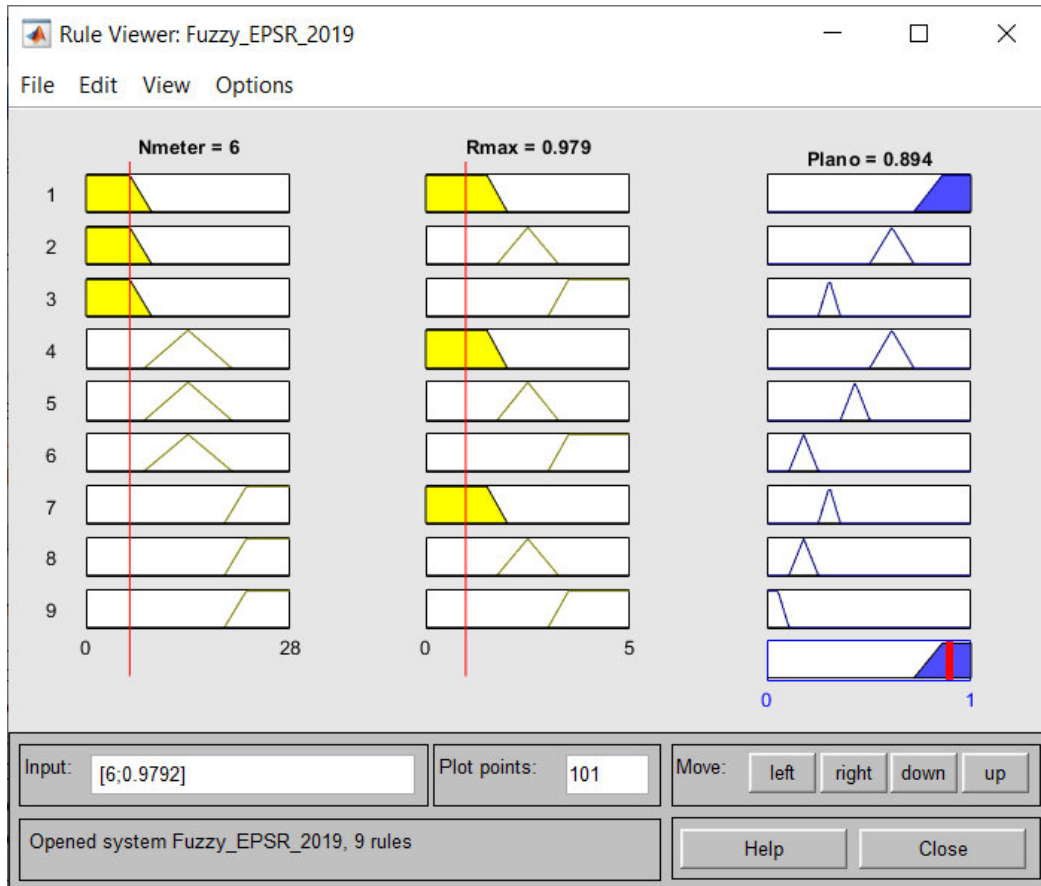


Figura 7.4: Demonstração do SEN com $N^{meter} = 6$ e $R^{max} = 0,9792\%$ – caso #1.

A Figura 7.5 ilustra a localização dos medidores multifuncionais do plano de medição com $N^{meter} = 6$, obtido a partir do caso #1 como solução ótima. Por outro lado, a Tabela 7.3 mostra o quantitativo de medições por medidor multifuncional, excetuando-se a barra da subestação e as medições de corrente.

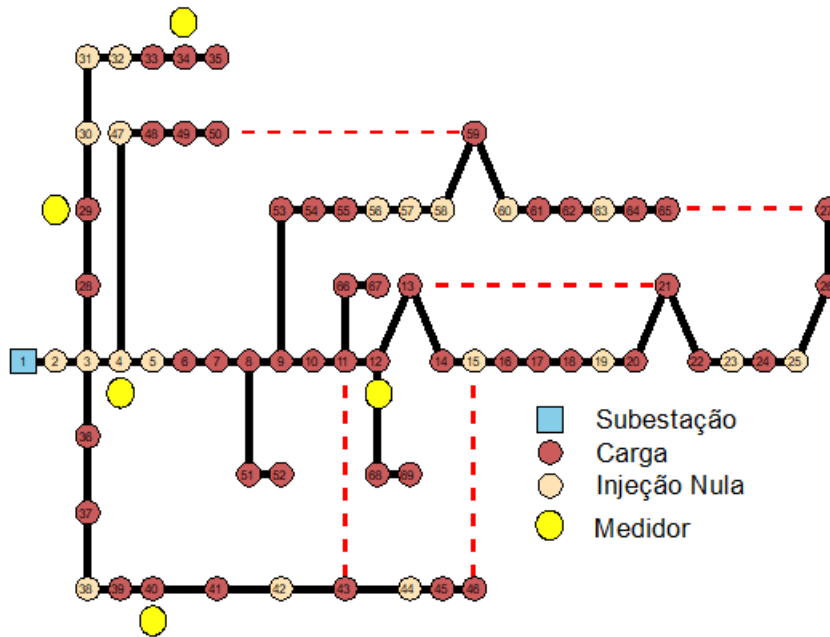


Figura 7.5: Visualização do plano de medição com 6 medidores no S69 (1 na SE + 5 na rede) – caso #1.

Tabela 7.3: Número de medições por medidor multifuncional – caso #1.

Barra com medidor	Medições disponíveis
#4	9
#12	9
#29	7
#34	7
#40	7

No caso #2, a RRD no S69 é realizada para o plano de medição obtido no caso #1. Este plano de medição possui medidores instalados nos nós #1, #4, #12, #29, #34 e #40. A Tabela 7.4 demonstra a validação das topologias ótimas associadas ao caso #2, calculando o índice anual de perdas de energia definido em (4.28). Em outras palavras, o plano de medição do caso #1 estará associado a uma topologia anual ou para quatro topologias anuais do S69, sendo uma para cada estação do ano. A partir desta tabela, pode-se notar que há uma redução de mais de 50% nas perdas anuais de energia, considerando uma ou quatro topologias ideais. No entanto, o plano de medição obtido no caso #1 não conseguiu manter $R^{max} \leq 5\%$ para qualquer patamar de carga quando a RRD do caso #2 foi executada. Por exemplo, o risco máximo, de 1,0578% no caso #1, varia de 68,2% a 68,8% após a RRD, mesmo com 6 medidores instalados no S69.

Tabela 7.4: Resultados do caso #2.

$\#N_t$	Número de agrupamentos de carga	Conjunto ótimo de chaves abertas	Patamares de carga	Perdas de Energia (MWh) para o caso #0	Perdas de Energia (MWh) para o caso #2	R^{max} (%)
1	N/A	11/43, 13/21, 14/15, 57/58, 61/62	17520	570,5780	257,0476	68,7104
4	1	11/43, 13/21, 14/15, 55/56, 61/62	2841	225,1501	99,7494	68,7102
	2	11/43, 13/21, 14/15, 57/58, 61/62	3993	174,3349	78,7242	68,5413
	3	11/43, 13/21, 14/15, 55/56, 61/62	5927	137,9299	63,1479	68,4172
	4	11/43, 13/21, 14/15, 58/59, 61/62	4759	33,1631	15,4256	68,2919

$\#N_t$: Número de topologias

O caso #3 consiste em alocar medidores para as topologias obtidas no caso #2 a fim de restaurar a precisão do estimador de estado deteriorada após a RRD. A Figura 7.6 mostra a aproximação da fronteira de Pareto com 14 soluções obtidas pelo MOBRKGA para o caso #3 do S69 com uma única topologia ($N_t = 1$). A partir desta figura, percebe-se que as soluções de 10, 11 e 12 medidores (soluções mais econômicas) foram selecionadas como alternativas de projeto para restabelecer a precisão do estimador. Embora o SEN tenha classificado as soluções de 8 a 12 como planos aceitáveis, a escolha pelas soluções 13 e 14 visa demonstrar o efeito na precisão do estimador de estado em planos de medição com número reduzido de medidores. A acurácia dessas soluções foi avaliada verificando-se a restrição (4.11) para todos os patamares de carga. A Figura 7.7 mostra o risco nodal máximo para todos os patamares de carga para as alternativas de projeto com 10, 11 e 12 medidores multifuncionais.

A partir desta figura, pode-se observar que a precisão do estimador de estado aumenta à medida que mais medidores são adicionados ao plano de medição. Por exemplo, os valores máximos de risco para projetos com $N^{meter} = 10$, $N^{meter} = 11$ e $N^{meter} = 12$ (solução melhor classificada através do SEN) são iguais a $R^{max} = 4,6368\%$, $R^{max} = 2,5746\%$ e $R^{max} = 1,0078\%$, respectivamente. Os elementos desta fronteira, bem como suas respectivas classificações segundo o SEN, são apresentados na Tabela 7.5, com destaque para as soluções Pareto ótimas segundo a menor norma Euclidiana em relação a U_{PF} . A partir desta tabela é possível verificar que o tomador de decisão poderia optar por planos de medição com maior precisão para o estimador,

prevendo possíveis falhas de medidores, visto que a escolha por um plano crítico com 10 medidores aumentaria a probabilidade de perda de precisão do estimador de estado se pelo menos um dos medidores do plano ficar indisponível (Raposo et al., 2019b). Por outro lado, a escolha por soluções com maior acurácia implicaria em gastos adicionais através da aquisição de novos medidores. A Figura 7.8 mostra a execução do SEN para $F_1(X) = 1,0078\%$ e $F_2(X) = 12$. As Figuras 7.9, 7.10 e 7.11 mostram a localização dos medidores multifuncionais dos planos de medição com $N^{meter} = 10$, $N^{meter} = 11$ e $N^{meter} = 12$, respectivamente.




Figura 7.6: Aproximação da fronteira de Pareto para uma topologia – caso #3.

Tabela 7.5: Elementos da fronteira de Pareto para uma topologia – caso #3.

Solução $Z_i(X_i)$	$R^{max} = F_1(X)$ (%)	$N^{meter} = F_2(X)$	SEN
1	0,0000E+00	30	Plano regular
2	4,8317E-13	29	Plano regular
3	1,0374E-12	25	Plano regular
4	5,5111E-10	23	Plano regular
5	2,7490E-04	22	Plano regular

(conclusão)

Solução $Z_i(X_i)$	$R^{max} = F_1(X)$ (%)	$N^{meter} = F_2(X)$	SEN
6	1,4145E-03	21	Plano regular
7	4,5077E-03	20	Plano regular
8	9,1674E-03	18	Plano aceitável
9	7,9761E-02	15	Plano aceitável
10	3,3560E-01	14	Plano aceitável
11	4,9778E-01	13	Plano aceitável
12	1,0078E+00	12	Plano aceitável
13	2,5747E+00	11	Plano médio
14	4,6369E+00	10	Plano crítico

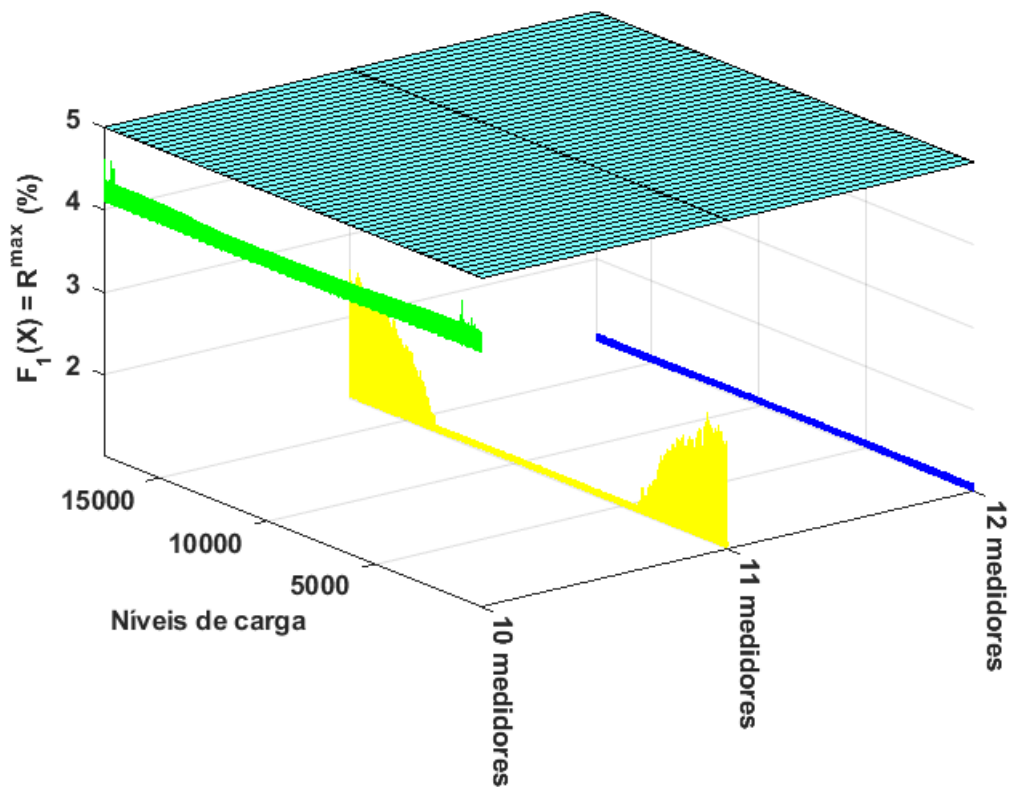


Figura 7.7: Riscos nodais considerando três planos de medição para uma topologia – caso #3.

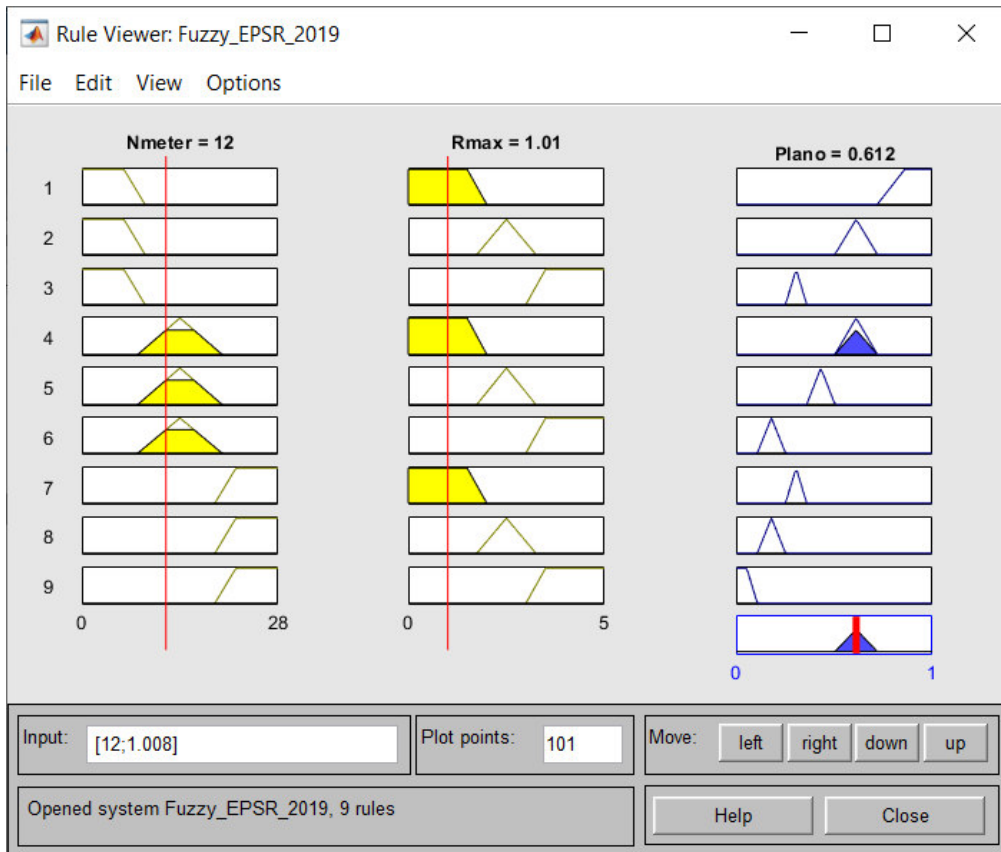


Figura 7.8: Demonstração do SEN com $N^{meter} = 12$ e $R^{max} = 1,0078\%$ – caso #3.




Figura 7.9: Localização do plano de medição com 10 medidores no S69 (1 na SE + 9 na rede) para uma topologia – caso #3.

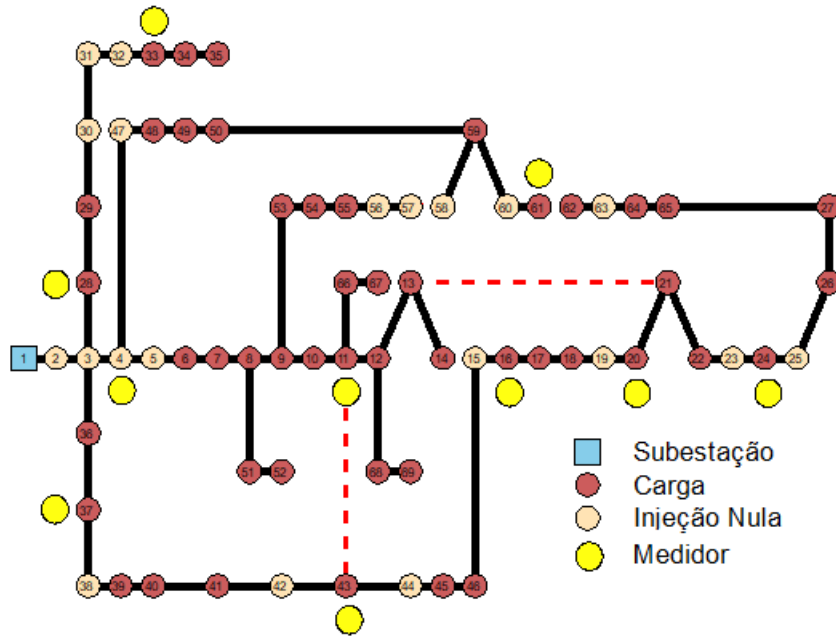


Figura 7.10: Localização do plano de medição com 11 medidores no S69 (1 na SE + 10 na rede) para uma topologia – caso #3.




Figura 7.11: Localização do plano de medição com 12 medidores no S69 (1 na SE + 11 na rede) para uma topologia – caso #3.

As Tabelas 7.6, 7.7 e 7.8 mostram o quantitativo de medições por medidor multifuncional, excetuando-se a barra da subestação e as medições de corrente, dos planos de medição com $N^{meter} = 10$, $N^{meter} = 11$ e $N^{meter} = 12$, respectivamente.

Tabela 7.6: Número de medições por medidor multifuncional com 10 medidores no S69 (1 na SE + 9 na rede) para uma topologia – caso #3.

Barra com medidor	Medições disponíveis
#8	9
#16	7
#20	7
#24	7
#28	7
#33	7
#37	7
#43	7
#50	5

Tabela 7.7: Número de medições por medidor multifuncional com 11 medidores no S69 (1 na SE + 10 na rede) para uma topologia – caso #3.

Barra com medidor	Medições disponíveis
#4	9
#11	9
#16	7
#20	7
#24	7
#28	7
#33	7
#37	7
#43	7
#61	5

Tabela 7.8: Número de medições por medidor multifuncional com 12 medidores no S69 (1 na SE + 11 na rede) para uma topologia – caso #3.

Barra com medidor	Medições disponíveis
#4	9
#10	7
#16	7
#18	7
#24	7
#29	7
#33	7
#37	7
#41	7
#45	7
#60	7

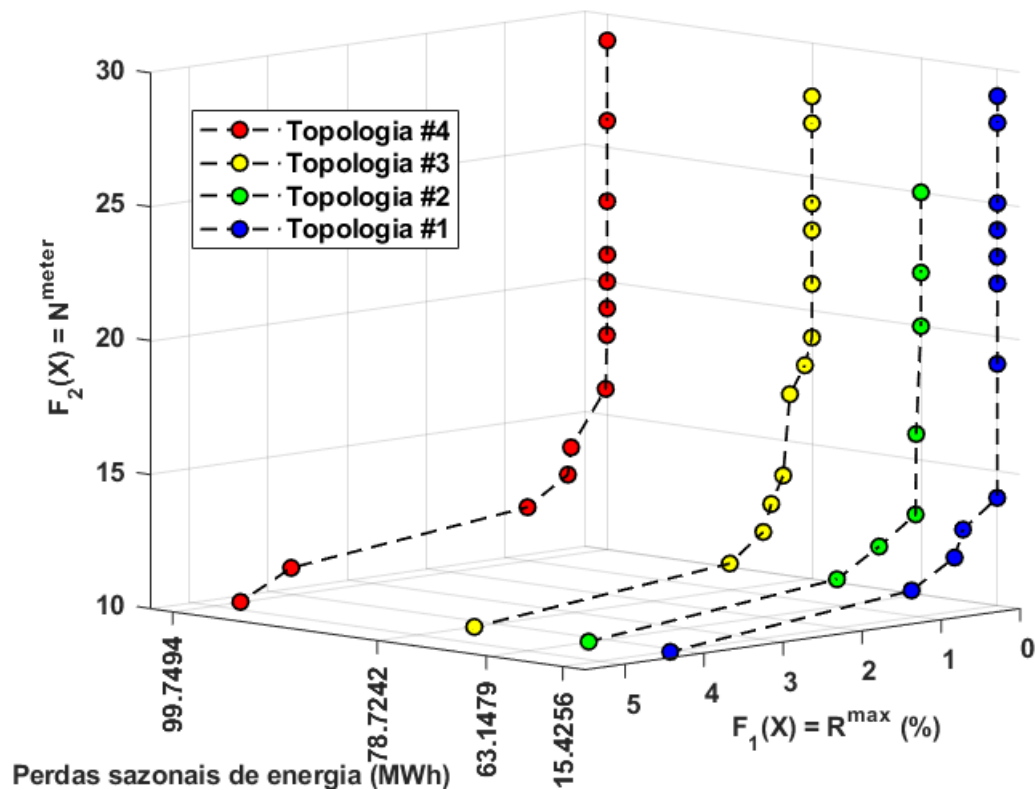


Figura 7.12: Aproximação da fronteira de Pareto para cada topologia – caso #3.

A Figura 7.12 ilustra a aproximação da fronteira de Pareto para o caso #3, considerando quatro topologias devido a questões de sazonalidade. Nesse cenário, o número de soluções ideais geradas pelo MOBKRGA para os agrupamentos de carga #1, #2, #3 e #4 são 12, 8, 13 e 13, respectivamente. As soluções mais econômicas para os agrupamentos de carga #1, #2, #3 e #4 têm 11, 11, 11 e 12 medidores multifuncionais. Os riscos nodais máximos para essas soluções são ilustrados na Figura 7.13. A partir desta figura, é possível verificar que todas as soluções atendem a restrição de desigualdade de risco. Em termos quantitativos, $R^{max} = 3,5679\%$, $R^{max} = 4,6368\%$, $R^{max} = 4,5280\%$ e $R^{max} = 1,1084\%$ para os agrupamentos de carga #1, #2, #3 e #4, respectivamente. Em outras palavras, os planos de medição gerados para uma ou quatro topologias são robustos em relação a precisão do estimador de estado aos custos de instalação dos medidores. Utilizando-se o SEN, descrito no capítulo 6, a solução contendo 12 medidores e classificada como plano aceitável foi escolhida como alternativa de projeto. Além disso, os resultados do caso #3 demonstram que a precisão do estimador é aceitável para todas as topologias ótimas durante o período anual. Ou

seja, o plano de medição selecionado pelo SEN (12 medidores) foi testado para um período anual (17520 patamares de carga) com quatro topologias e a precisão do estimador foi aceitável ($R^{max} = 1,1084\% \leq 5\%$) conforme é mostrado no gráfico de cor vermelha da Figura 7.13. Este teste é realizado considerando-se a topologia associada com cada patamar de carga e avaliando-se a precisão do estimador para as variações topológicas e de carregamento. No entanto, os custos de instalação dos medidores dobraram em comparação com o sistema de medição do caso #1. Portanto, os casos #2 e #3 demonstram claramente que a RRD pode deteriorar a precisão do estimador e requer custos adicionais para restaurá-la.




Figura 7.13: Riscos nodais considerando um plano de medição para cada topologia – caso #3.

A Tabela 7.9 mostra as soluções pertencentes a cada aproximação da fronteira de Pareto iniciando-se das menores para as maiores perdas anuais de energia, com destaque para a solução Pareto ótima de acordo com a menor norma Euclidiana em relação a U_{PF} .

Tabela 7.9: Elementos da fronteira de Pareto para quatro topologias – caso #3.

Topologia	Solução X_i	E^{loss} (MWh)	$R^{max} = F_1(X)$ (%)	$N^{meter} = F_2(X)$
#1	1	15,4256	0,0000E+00	29
	2	15,4256	5,4143E-12	28
	3	15,4256	6,7064E-10	25
	4	15,4256	1,3114E-06	24
	5	15,4256	1,4250E-06	23
	6	15,4256	2,9458E-06	22
	7	15,4256	9,0500E-04	19
	8	15,4256	2,5647E-03	14
	9	15,4256	4,3551E-01	13
	10	15,4256	5,4295E-01	12
	11	15,4256	3,5679E+00	11
	12	15,4256	4,1406E+00	10
#2	1	63,1479	0,0000E+00	25
	2	63,1479	3,6117E-08	22
	3	63,1479	3,0472E-06	20
	4	63,1479	5,9831E-02	16
	5	63,1479	6,7455E-02	13
	6	63,1479	5,2897E-01	12
	7	63,1479	4,6368E+00	11
	8	63,1479	4,8044E+00	10
#3	1	78,7242	0,0000E+00	28
	2	78,7242	2,7484E-11	27
	3	78,7242	4,0508E-10	24
	4	78,7242	2,8962E-08	23
	5	78,7242	2,9088E-08	21
	6	78,7242	2,7737E-04	19
	7	78,7242	8,9027E-02	18
	8	78,7242	2,7827E-01	17
	9	78,7242	3,6374E-01	14
	10	78,7242	5,1499E-01	13
	11	78,7242	6,1534E-01	12
	12	78,7242	4,5280E+00	11
	13	78,7242	4,8730E+00	10
#4	1	99,7494	0,0000E+00	29
	2	99,7494	2,2737E-11	26
	3	99,7494	5,1712E-10	23
	4	99,7494	2,5677E-05	21
	5	99,7494	7,1806E-04	20
	6	99,7494	1,4145E-03	19
	7	99,7494	4,1745E-03	18
	8	99,7494	1,9205E-02	16
	9	99,7494	4,5700E-01	14
	10	99,7494	4,9788E-01	13
	11	99,7494	1,1084E+00	12

(conclusão)

Topologia	Solução X_i	E^{loss} (MWh)	$R^{max} = F_1(X)$ (%)	$N^{meter} = F_2(X)$
#4	12	99,7494	4,0000E+00	11
	13	99,7494	4,6415E+00	10

No caso #4, o MOBRKGA foi aplicado ao caso #0 para minimizar simultaneamente as perdas anuais de energia, os custos do plano de medição e o risco de violar a precisão do estimador de estado. Isto é, o problema de alocação de medidores é resolvido simultaneamente com a RRD para minimizar o aumento do custo de implantação do plano de medição identificado no caso #3. Essa estratégia permite que o engenheiro escolha soluções que atendam aos critérios definidos pela concessionária de distribuição de energia. A aproximação da fronteira de Pareto para o caso #4 é ilustrada na Figura 7.14.




Figura 7.14: Aproximação da fronteira de Pareto para o caso #4 via MOBRKGA.

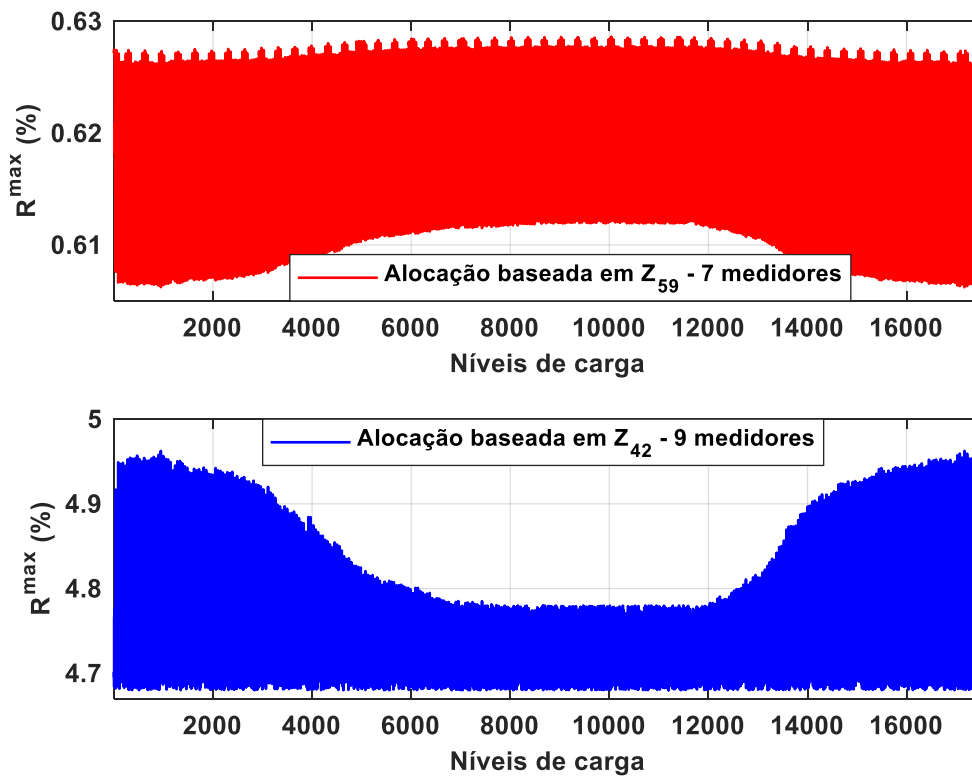


Figura 7.15: Riscos nodais para as soluções Z_{42} e Z_{59} – caso #4.

O MOBRKGA forneceu 131 soluções associadas a uma única topologia que minimiza simultaneamente $F_2(X)$, $F_3(X)$ e $F_4(Y)$, ou seja, $F(Z)$, para quatro agrupamentos de carga, conforme definido em (6.4). Dentre as 131 soluções, é possível destacar as alternativas $F(Z_{42}) = \{9, 4,6128\%, 263,9918 \text{ MWh}\}$ e $F(Z_{59}) = \{7, 0,6170\%, 274,6437 \text{ MWh}\}$ representadas pelos quadrados azul e vermelho na Figura 7.15, respectivamente. As perdas de energia anuais relacionadas com essas duas soluções representam uma redução de cerca de 50% em relação ao caso #0. Além disso, tem-se $R^{max} = 4,9645\%$ e $R^{max} = 0,6286\%$ para as alternativas $F(Z_{42})$ e $F(Z_{59})$, respectivamente, para todos os patamares de carga no período anual, como mostrado na Figura 7.15. Os valores dos riscos mostrados na aproximação da fronteira de Pareto da Figura 7.14 diferem daqueles associados com $F(Z_{42})$ e $F(Z_{59})$. Este fato é devido aos riscos visualizados na Figura 7.14 serem calculados através da média ponderada dos riscos para os agrupamentos de carga com pesos iguais a probabilidades de ocorrência dos agrupamentos (ver equação (4.10)). Finalmente, deve-se enfatizar que as soluções $F(Z_{42})$ e $F(Z_{59})$ têm menos medidores do que aquelas associadas ao caso #3 (pós-

reconfiguração). Portanto, solucionar simultaneamente os problemas de alocação de medidores e RRD é mais eficiente do que a alocação pós-reconfiguração com relação a precisão do estimador de estado, os custos do plano de medição e as reduções de perdas anuais de energia.

As 131 soluções contidas na aproximação da fronteira de Pareto são mostradas na Tabela 7.10, com destaque para a solução Pareto ótima de acordo com a menor norma Euclidiana em relação a U_{PF} .

Tabela 7.10: Elementos da fronteira de Pareto para o caso #4.

Solução Z_i	$E^{loss} = F_4(Y)$ (MWh)	$R_{Ncl}^{max} = F_3(X)$ (%)	$N^{meter} = F_2(X)$
1	257,0472	0,0000E+00	35
2	257,0472	1,1151E-02	34
3	257,0472	9,6867E-02	23
4	257,0472	9,9953E-02	20
5	257,0472	5,2417E-01	17
6	257,0472	5,8658E-01	16
7	257,0472	1,3084E+00	12
8	257,0472	1,4696E+00	11
9	257,2810	1,4389E-07	32
10	257,2810	1,0885E-03	25
11	257,2810	4,9424E-03	23
12	257,2810	3,0667E-01	17
13	257,2810	4,8764E-01	16
14	257,2810	5,9649E-01	15
15	257,2810	6,4404E-01	14
16	257,2810	6,4640E-01	13
17	257,2810	1,2556E+00	12
18	257,5418	0,0000E+00	34
19	257,5418	6,3407E-10	25
20	257,5418	7,2050E-06	23
21	257,5418	1,9925E-02	22
22	257,5418	4,8315E-01	16
23	257,5418	4,9216E-01	14
24	257,5418	5,9662E-01	13
25	257,8754	4,8317E-01	15
26	258,2207	4,4793E-10	28
27	258,2207	7,4708E-09	23
28	258,2207	5,3075E-02	19
29	258,2207	3,1409E-01	16
30	258,2207	5,9662E-01	13
31	258,2207	1,0928E+00	12

(continua)

Solução Z_i	$E^{loss} = F_4(Y)$ (MWh)	$R_{Ncl}^{max} = F_3(X)$ (%)	$N^{meter} = F_2(X)$
32	258,2207	1,0930E+00	11
33	259,4505	2,2829E-01	18
34	263,9260	8,8451E-13	33
35	263,9260	1,0901E-03	21
36	263,9260	5,9661E-01	11
37	263,9260	2,2016E+00	10
38	263,9918	3,5236E-01	15
39	263,9918	4,8800E-01	13
40	263,9918	5,9661E-01	11
41	263,9918	2,0256E+00	10
42	263,9918	4,6128E+00	9
43	266,0686	1,5284E-10	32
44	268,1207	2,5273E-13	33
45	268,1207	6,9754E-01	8
46	268,1578	1,7796E+00	7
47	273,0278	5,3385E-03	12
48	273,0278	4,6427E-03	12
49	273,0278	9,6922E-02	17
50	273,0278	1,4105E-01	12
51	273,1522	1,4916E-02	20
52	273,8743	3,3186E-04	21
53	273,8743	9,6639E-02	17
54	274,6437	0,0000E+00	26
55	274,6437	9,2330E-02	15
56	274,6437	9,2793E-02	13
57	274,6437	4,9417E-01	10
58	274,6437	5,8380E-01	9
59	274,6437	6,1694E-01	7
60	274,7781	2,0173E-02	19
61	274,7781	6,8855E-02	14
62	274,7781	9,2764E-02	13
63	274,7781	5,9770E-01	7
64	275,6972	9,2559E-02	13
65	275,8023	4,9412E-01	10
66	275,8023	5,8359E-01	9
67	275,8341	2,0110E-02	19
68	275,8341	9,2530E-02	13
69	275,8341	4,8522E-01	11
70	278,3353	2,4601E-02	18
71	278,3933	4,8526E-01	9
72	279,4275	1,0648E-02	20
73	279,4275	9,2072E-02	13
74	282,6286	9,1750E-02	13
75	283,4740	9,0923E-02	13

(continua)

Solução Z_i	$E^{loss} = F_4(Y)$ (MWh)	$R_{Ncl}^{max} = F_3(X)$ (%)	$N^{meter} = F_2(X)$
76	284,6772	9,0666E-02	13
77	287,0203	9,0485E-02	13
78	288,2139	8,5345E-03	18
79	293,5843	8,8863E-02	13
80	293,5843	3,7749E-01	11
81	294,9386	8,8586E-02	13
82	294,9386	3,4853E-01	11
83	301,3427	1,6303E-11	24
84	302,4205	1,8209E-01	8
85	302,4579	8,6847E-02	13
86	302,5299	8,6401E-02	13
87	302,5973	1,6205E-04	21
88	302,7331	1,7613E-01	7
89	303,9976	6,7326E-10	21
90	303,9976	2,7897E-04	15
91	305,8400	8,6285E-02	13
92	309,8782	1,1211E-01	8
93	310,0362	8,6062E-02	13
94	310,7717	8,5266E-02	13
95	310,8353	8,5146E-02	13
96	312,5455	8,5005E-02	13
97	312,5455	9,3590E-02	12
98	312,7971	8,4965E-02	13
99	312,9039	8,4951E-02	13
100	313,2074	1,2854E-01	7
101	313,2083	9,4535E-02	7
102	313,5481	5,7466E-02	13
103	320,8012	1,9084E-02	13
104	321,7784	0,0000E+00	23
105	322,5433	4,8862E-02	11
106	325,3131	2,7573E+00	6
107	326,5905	3,0601E-02	12
108	327,5011	2,7736E-03	14
109	331,6614	2,4926E-04	19
110	332,1683	2,4421E-04	19
111	333,7325	1,8178E-03	14
112	336,9673	1,9554E+00	6
113	339,6315	1,8503E+00	6
114	340,8325	2,3987E-04	16
115	340,8589	2,4780E-02	11
116	343,5229	4,8976E-01	6
117	346,1834	1,1821E-06	17
118	346,1834	3,0082E-02	10
119	347,5546	2,1529E+00	5

(conclusão)

Solução Z_i	$E^{loss} = F_4(Y)$ (MWh)	$R_{Ncl}^{max} = F_3(X)$ (%)	$N^{meter} = F_2(X)$
120	351,1514	3,7984E-10	19
121	354,3302	8,4471E-07	12
122	357,5528	1,4256E-02	11
123	359,7834	7,9712E-02	8
124	367,3087	7,9536E-02	8
125	374,9304	9,4140E-03	11
126	374,9304	3,7088E-02	9
127	374,9304	7,4278E-02	8
128	374,9304	8,1205E-02	7
129	383,7301	3,7591E-03	11
130	519,0973	1,3634E-01	6
131	525,8268	0,0000E+00	21

A partir da Tabela 7.10, é possível verificar que o tomador de decisão poderia optar por planos de medição com maior confiabilidade em relação a precisão do estimador de estado (Raposo et al., 2019b), prevendo possíveis contingências ao plano atual com apenas 7 ou 9 medidores multifuncionais. Entretanto, a escolha por soluções mais robustas implicaria em gastos adicionais através da aquisição de novos medidores. Como exemplo, soluções que representam as topologias ótimas ou próximas a elas possuem um número elevado de dispositivos de medição instalados na rede. Entretanto, a escolha das soluções $F(Z_8) = \{11, 1,4696\%, 257,0472 \text{ MWh}\}$ e $F(Z_{17}) = \{12, 1,2556\%, 257,2810 \text{ MWh}\}$ poderia resultar em um investimento de baixo custo para a concessionária de distribuição, equilibrando perdas anuais de energia, alta precisão do estimador de estado e investimento com dispositivos de medição.

7.5 Análise de Desempenho do MOBRKGA

Uma comparação dos custos computacionais associados ao MOBRKGA e NSGA-II (Deb et al., 2002) é apresentada na Tabela 7.11. A partir desta tabela, pode-se concluir que o MOBRKGA supera o NSGA-II em relação ao custo computacional. Por exemplo, o MOBRKGA requer apenas 7,7667% do tempo de CPU exigido pelo NSGA-II para resolver o problema de RRD no caso #3 com uma topologia ótima. A Figura

7.16 ilustra a aproximação da fronteira de Pareto com 106 soluções obtidas pelo NSGA-II para o caso #4.




Figura 7.16: Aproximação da fronteira de Pareto para o caso #4 via NSGA-II.

Tabela 7.11: Comparação dos custos computacionais associados com o MOBRKGA e NSGA-II.

Casos	Tempo computacional (h)		Speedup
	NSGA-II	MOBRKGA	
#1	41,2911	3,2023	12,8941
#3 (com uma topologia)	41,4314	3,2178	12,8755
#3 (com quatro topologias)	80,0763	8,7403	9,1617
#4	125,0207	9,4820	13,1851

Com o objetivo de avaliar a performance em relação a quantidade e qualidade das soluções produzidas através do MOBRKGA realizou-se uma comparação com a meta-heurística NSGA-II. As Tabelas 7.12 e 7.13 demonstram os resultados das métricas de desempenho citadas no capítulo 6 para os algoritmos MOBRKGA (soluções

da fronteira P) e NSGA-II (soluções da fronteira Q) considerando-se os casos #1 e #4, respectivamente.

Tabela 7.12: Métricas de desempenho MOBRKGA vs. NSGA-II – caso #1, onde ✓ (✖) indica o melhor (pior) algoritmo com relação a uma métrica.

Métricas de performance	MOBRKGA (P)	NSGA-II (Q)
Taxa de Erro (ER)	0,8234✓	0,8501✖
Distância Geracional (GD)	0,5183✓	1,3244✖
Cobertura (SC)	0,7273✖	1,0000✓
Espaçamento (SP)	1,0873✖	0,3490✓
Dispersão ($SPREAD$)	0,4854✖	0,2402✓
Hipervolume (HV)	0,9950✓	0,9940✖

Tabela 7.13: Métricas de desempenho MOBRKGA vs. NSGA-II – caso #4, onde ✓ (✖) indica o melhor (pior) algoritmo com relação a uma métrica.

Métricas de performance	MOBRKGA (P)	NSGA-II (Q)
Taxa de Erro (ER)	0,8019✓	0,8400✖
Distância Geracional (GD)	4,7900✓	5,2324✖
Cobertura (SC)	0,5200✖	0,9811✓
Espaçamento (SP)	3,8500✖	2,9656✓
Dispersão ($SPREAD$)	0,9642✖	0,4581✓
Hipervolume (HV)	0,4592✓	0,3870✖

A partir das Tabelas 7.12 e 7.13, nota-se, a partir das métricas, que o desempenho do MOBRKGA foi equivalente ao NSGA-II. Todavia, a métrica mais usada em comparações de algoritmos multiobjetivos é o hipervolume (Zitzler e Thiele, 1999). Com base nesta métrica, pode-se afirmar que o MOBRKGA é superior ao NSGA-II nos casos selecionados.

Os resultados apresentados na Tabela 7.11 demonstraram que o MOBRKGA possui menor custo computacional com relação ao NSGA-II. Contudo, os tempos de execução do MOBRKGA ainda são consideravelmente elevados, mesmo para estudos de planejamento. Por exemplo, o tempo computacional requerido pelo MOBRKGA para solucionar o caso de estudo #4 é cerca de 9,5 horas. É importante destacar que tanto o NSGA-II como o MOBRKGA foram implementados em MATLAB que possui alto custo computacional devido ao fato de ser uma linguagem interpretada, dinâmica e simples. Uma alternativa para reduzir o custo computacional dos modelos desta tese

seria convertê-los para Java, C/C++ ou FORTRAN. Todavia, esta conversão é laboriosa, tediosa e sujeita a erros. O problema de codificar o protótipo de um modelo computacional em uma linguagem mais simples de alto nível e convertê-lo em seguida para outra linguagem, de baixo nível de alta performance, para reduzir o seu custo computacional é conhecido como problema das duas linguagens (“two-language problem”). Este é um grande problema devido a: exige que os programadores aprendam mais que uma linguagem, resulta em mais tempo de desenvolvimento e introdução de mais erros inesperados. O problema das duas linguagens pode ser superado usando-se a linguagem de programação Julia. O projeto da linguagem Julia foi iniciado no MIT em 2009 por quatro cocriadores (Bakshi, 2020): Stefan Karpinski, Viral Shah, Alan Edelman e Jeff Bezanson. A principal meta no desenvolvimento da linguagem Julia foi solucionar o problema das duas linguagens. As principais características da linguagem Julia são:

- i) Interoperabilidade com C, FORTRAN e Python;
- ii) Código aberto e multiplataforma;
- iii) Compilação JIT (“Just in Time”);
- iv) Alta performance (menor custo computacional com relação ao Python e o MATLAB).

Atualmente, já existem aplicações comerciais na área de sistemas de potência usando a linguagem Julia. Por exemplo, a empresa PSR (uma empresa brasileira de consultoria internacional no setor de eletricidade e gás com clientes em mais de trinta países espalhados por quatro continentes) está usando a linguagem Julia para desenvolver modelos de otimização para a operação e planejamento de sistemas de potência (Julia Computing, 2020). Desta forma, decidiu-se codificar os algoritmos MOBRKGA e o NSGA-II em Julia para avaliar o potencial desta linguagem na solução dos problemas de alocação de medidores e RRD. A Tabela 7.14 mostra os custos computacionais associado com as linguagens MATLAB e Julia para os casos #1, #3 e #4.

Tabela 7.14: Comparação dos custos computacionais associados com o MOBRKGA nas linguagens MATLAB e Julia.

Casos	Tempo computacional (h)		<i>Speedup</i>
	MATLAB	Julia	
#1	3,2023	0,3407	9,3999
#3 (com uma topologia)	3,2178	0,3944	8,1579
#3 (com quatro topologias)	8,7403	0,9765	8,9509
#4	9,4820	0,7513	12,6202

A partir da Tabela 7.14 é possível verificar uma redução acentuada no tempo de execução do MOBRKGA após a conversão da linguagem MATLAB para a linguagem Julia. Para o caso #4, há uma economia de tempo da ordem de 92,07% do tempo requerido para execução. É importante destacar que esses resultados foram obtidos considerando-se sempre uma primeira execução do programa na linguagem Julia, pois a linguagem tem a vantagem de alocar espaço pré-definido na memória para simulações de um mesmo programa de forma subsequente. Assim, caso fosse utilizado este artifício, o *speedup* médio para os casos analisados na Tabela 7.14 fica em torno de 125, reduzindo bruscamente o tempo computacional do MOBRKGA em linguagem Julia. Portanto, pode-se concluir que é vantajoso, do ponto de vista do custo computacional, converter os programas associados com os modelos desta tese para a linguagem Julia. Esta conversão permitirá a expansão dos modelos desta tese para redes de grande usando coordenadas de fase para representar de forma mais precisa a natureza desbalanceada das redes de distribuição.

CONCLUSÕES

8.1 Introdução

Nesta tese foram desenvolvidas técnicas e algoritmos para alocar medidores multifuncionais visando a estimação de estado em redes de distribuição radiais juntamente com a RRD, bem como redução dos investimentos instalação dos medidores. A metodologia proposta pressupõe que a alocação dos medidores é realizada subsequentemente ou simultaneamente a RRD para a redução anual das perdas de energia. Esta formulação do problema de alocação evita que a precisão do estimador de estado seja deteriorada quando a topologia da rede elétrica é modificada, além de permitir que um nível especificado de precisão seja obtido. Estes objetivos foram alcançados usando-se uma formulação multiobjetivo baseada na teoria Pareto que minimiza as perdas anuais de energia, o número de medidores instalados e o risco de violar a precisão do estimador (maximiza a precisão do estimador). A precisão do estimador é calculada analiticamente sem o uso da SMC e considera o fato de existir correlação entre medições de potência. Além disso, o um método analítico, denominado ANEC2PDF, foi projetado para avaliar a precisão do estimador de estado sistemas com número considerável de nós de injeções nulas. O ANEC2PDF contorna problemas de mau-condicionamento de matrizes associadas com o estimador de estado baseado na formulação normal usando um sistema aumentado pelas restrições de igualdade referentes aos nós de injeções nulas. O problema de otimização descrito acima foi solucionado através do algoritmo genético de chaves aleatórias viciadas na sua versão multiobjetivo, o MOBRKGA. Os resultados no S69 demonstram que as soluções obtidas pelo método proposto têm boa qualidade e estabelecem um compromisso aceitável com os objetivos, isto é, topologias com reduções significativas nas perdas anuais de energia e planos de medição precisos e com baixo custo de instalação, tanto para os paradigmas de pós-reconfiguração quanto para a alocação de medidores simultânea a RRD. Além disso, a metodologia proposta para alocação de medidores é

flexível por levar em conta o número de topologias definidas pelos engenheiros de planejamento da operação.

8.2 Comentários sobre o MOBRKGA

A versão multiobjetivo do MOBRKGA segundo a teoria Pareto baseia-se no critério de dominância entre soluções a fim de gerar um conjunto de alternativas factíveis para o tomador de decisão. Os resultados em uma rede de distribuição de 69 barras também demonstraram que a precisão do estimador de estado é reduzida após a RRD. Assim, a RRD deixa de ser uma alternativa de projeto de custo nulo, pois será necessário instalar medidores adicionais para restaurar a precisão do estimador após a RRD. Entretanto, o modelo de otimização multiobjetivo proposto, baseado no MOBRKGA, obteve soluções de alta qualidade com relação à redução nas perdas anuais de energia sem reduzir a precisão do estimador e com um pequeno número de medidores instalados na rede, tanto para os paradigmas de pós-reconfiguração quanto para a alocação simultânea de medidores. A vantagem do MOBRKGA em relação a outras estratégias, como a baseada em conjuntos nebulosos, é produzir uma gama de alternativas de projeto que atendam a outros objetivos da concessionária de distribuição de energia, pois como foi visto, para atender o critério de precisão do estimador e economia de instalação de medidores há um aumento nas perdas anuais na rede, o que para a grande maioria das empresas do setor é inegociável em aplicações práticas. Em relação a técnicas semelhantes, como o NSGA-II, o MOBRKGA mostrou-se bastante eficiente tanto do ponto de vista de desempenho computacional quanto de qualidade de soluções. No que se refere a conversão do código-fonte do modelo proposto de MATLAB para Julia a fim de reduzir o custo computacional, os ganhos computacionais obtidos mostraram-se bastante significativos, evidenciando a potencialidade do emprego da linguagem Julia no MOBRKGA para a análise de sistemas de distribuição de grande porte. Por fim, é importante destacar que o uso de outras métricas para calcular a distância entre o ponto de utopia e um ponto da fronteira Pareto influencia na solução final e, desta forma, na alternativa de projeto para o tomador de decisão.

8.3 Sugestões para Trabalhos Futuros

O tema principal desta tese é alocação ótima de medidores visando a estimação de estado em redes de distribuição de energia elétrica concomitantemente à RRD sob demanda variável. Trabalhos futuros neste assunto concentram-se no desenvolvimento de modelos e técnicas para simular de forma mais precisa locais candidatos para instalação de medidores na rede de distribuição e topologias ótimas sob a perspectiva de redes de distribuição malhadas e indisponibilidade das medições ou de componentes da rede. A seguir, algumas sugestões para trabalhos futuros são apresentadas.

8.3.1 Extensão da metodologia proposta em coordenadas de fase

Neste trabalho, o índice de probabilidade bivariado P_i foi estimado utilizando-se o modelo de sequência positiva da rede. A escolha deste modelo teve por objetivo comparar as metodologias propostas de alocação com o método de referência desenvolvido por (Singh et al., 2009) e (Raposo et al., 2017). Entretanto, este modelo não permite representar de forma mais adequada aspectos associados à natureza desbalanceada das redes de distribuição, como por exemplo: a existência de laterais bifásicas ou monofásicas e os desequilíbrios das cargas entre as fases. Adicionalmente, será possível inferir sobre a correlação de medições entre fases.

8.3.2 Alocação ótima de medidores multifuncionais considerando-se as falhas nos medidores e equipamentos da rede de distribuição

A avaliação da precisão do estimador de estado consiste basicamente em estimar índices estatísticos relacionados ao erro entre os valores estimados e verdadeiros das tensões nodais. Geralmente, esta avaliação é realizada considerando-se somente os erros nas medições. Todavia, há outros tipos de incertezas que podem ser consideradas na avaliação da precisão do estimador de estado: por exemplo: contingências nos equipamentos da rede elétrica (geradores, linhas e transformadores) e a indisponibilidade dos medidores devido as falhas intrínsecas nos mesmos ou problemas

na infraestrutura de comunicação. É também importante considerar as indisponibilidades dos medidores devido as diferenças nas latências nas medições dos sistemas SCADA e AMI. As incertezas relacionadas com as falhas nos medidores e componentes da rede elétrica são de natureza discreta. Esta característica reduz a precisão dos métodos analíticos usados para avaliar a precisão do estimador de estado, pois as distribuições de probabilidade das tensões nodais tornam-se multimodais. Por outro lado, o custo computacional da SMC para avaliar a precisão do estimador de estado torna-se muito alto quando a indisponibilidade dos medidores e componentes é considerada devido ao aumento nas variâncias das tensões nodais. Desta forma, é importante desenvolver técnicas de baixo custo computacional que permitam avaliar a precisão do estimador de estados considerando-se falhas nos medidores e nos equipamentos da rede elétrica. Estas técnicas poderiam ser embarcadas em algoritmos meta-heurísticos para realizar uma alocação de medidores robusta (imune) as indisponibilidades de medidores e componentes da rede elétrica.

8.3.3 Alocação de medidores para detecção de perdas não-técnicas

O planejamento de um sistema de medição também deve ser robusto para identificar a presença de erros grosseiros nas medições. Em redes de distribuição de energia elétrica nacionais estes erros grosseiros podem estar associados com perdas não-técnicas, ou seja, fraudes/furto de energia elétrica (Manito et al., 2019). As perdas de energia não-técnicas são responsáveis por perdas significativas no faturamento das concessionárias. Devido a isso, é oportuno desenvolver metodologias de alocação de medidores que assegurem que fraudes/furtos de energia sejam identificados e quantificados pela concessionária. Um pré-requisito importante para realizar esta tarefa é a implementação de um modelo de estimação de estados trifásico para representar precisamente as redes de distribuição primárias e secundárias que possuem cargas desequilibradas e trechos monofásicos, bifásicos e trifásicos em um mesmo alimentador. O estimador de estados trifásico pode ser combinado com testes de hipótese geométricos para detectar as perdas não técnicas (Rodrigues et al., 2018). Outra condição para um planejamento robusto do sistema de medição contra fraudes é a caracterização probabilísticas das incertezas referentes as perdas, por exemplo: as distribuições de probabilidade do número de consumidores e da potência associadas

com as perdas técnicas por classe consumidora (residencial, comercial, industrial, etc.). É também importante modelar a dependência geoespacial das perdas técnicas. A modelagem de incertezas nas perdas técnicas e nos erros de medição permitirá a estimação da probabilidade de detecção de perdas não técnicas para um plano de medição sob estudo via Simulação Monte Carlo. Desta forma, pode-se utilizar algoritmos meta-heurísticos, tais como o BRKGA, para maximizar a probabilidade de detecção de perdas através da alocação de medidores. Obviamente, esta alocação também deve considerar a minimização do número de medidores para incluir aspectos referentes aos custos de medição. Portanto, teremos um problema de otimização multiobjetivo associado com a alocação de medidores orientada a detecção de perdas não-técnicas.

8.3.4 Inclusão de restrições associadas com o número de manobras na RRD

Além da minimização das perdas de energia, é necessário considerar restrições físicas referentes ao número de reconfigurações em um período anual. Por exemplo, os tempos de vida de chaves de ar e vácuo, que são usadas como dispositivos de seccionamento na RRD, são de aproximadamente 200 operações (Takenobu et al., 2018). Adicionalmente, também se relata que RRD frequentes, tais como aquelas horárias, podem gerar sobretensões transitórias (Takenobu et al., 2018). Dadas estas condições, pode ser razoável permitir somente poucas RRD em um período anual. Os métodos de RRD convencionais não tratam os períodos de reconfiguração como variáveis de decisão no problema de otimização. Em outras palavras, determinar o dia, mês ou semana do ano no(a) qual a topologia da rede será modificada. Desta forma, as soluções fornecidas por métodos convencionais podem direcionar a reconfigurações extremamente frequentes. Portanto, deve-se limitar o número de reconfigurações permitidas em um ano. Portanto, seria interessante expandir a metodologia proposta para determinar os períodos de reconfiguração da rede sujeito ao número de reconfigurações permitidas. Outra alternativa mais simples para reduzir o número de reconfigurações é adicionar uma componente na função objetivo relacionada com a minimização do número de reconfigurações ou de manobras de chaves.

8.3.5 RRD considerando-se aspectos de confiabilidade

Um objetivo de grande importância no planejamento de redes de distribuição é a confiabilidade do fornecimento de energia elétrica. A confiabilidade é geralmente incluída em estudos de planejamento através da aplicação de métodos probabilísticos para estimar índices para os pontos de carga associados com a frequência e a duração das interrupções. Os principais métodos probabilísticos usados na estimação de índices de confiabilidade são a SMC e o Método Analítico de Enumeração de Estados (MAEE) (Brown, 2009; Billinton e Allan, 1996). O MAEE possui baixo custo computacional. Desta forma, este método torna-se muito adequado para aplicações envolvendo otimização da confiabilidade. Entretanto, o MAEE tem as seguintes limitações:

- i) As distribuições de probabilidade dos índices não podem ser geradas, isto é, o MAEE só gera os valores esperados dos índices.
- ii) Incertezas dependentes do tempo (flutuações sazonais na carga e variabilidade de geração distribuída renovável) só podem ser modeladas ignorando-se a convolução entre as variações cronológicas nas incertezas e a duração das falhas nos equipamentos.

A SMC pode modelar qualquer tipo de incerteza baseada em distribuições de probabilidade ou séries temporais. Portanto, a SMC é mais adequada para considerar incertezas dependentes do tempo no cálculo de índices de confiabilidade. Todavia, a principal desvantagem da SMC é o seu alto custo computacional devido a necessidade de amostrar um grande número de cenários para estimar os índices com um precisão aceitável.

Portanto, a extensão da metodologia de RRD proposta nesta tese para considerar índices de confiabilidade requer que se desenvolvam algumas estratégias para minimizar o custo computacional da SMC, por exemplo:

- i) Diminuição do número de cenários através da aplicação de técnicas de redução de variância ou importância amostral;
- ii) Utilização de técnicas de processamento paralelo para reduzir os tempos de CPU.

O desenvolvimento destas estas estratégias permitirá a inclusão de índices de confiabilidade não apenas na RRD, mas também em outros problemas de planejamento,

por exemplo: roteamento de alimentadores, recondutoramento das seções, alocação de subestações, alocação de geração distribuída, etc.

8.4 Artigos Publicados

O desenvolvimento do projeto de pesquisa desta tese resultou nas seguintes publicações:

i) Artigos publicados em periódicos:

i-1) Raposo, A. A. M., Rodrigues, A. B., e Da Silva, M. (2017) Optimal Meter Placement Algorithm for State Estimation in Power Distribution Networks, **Electric Power Systems Research**, Vol. 147, pp. 22-30. DOI: <http://doi.org/10.1016/j.epsr.2017.02.015>.

Resumo:

Este artigo propõe um algoritmo para alocar medidores em redes de distribuição para melhorar a precisão do estimador de estado. Esse algoritmo considera três novas questões no problema de alocação do medidor: medições correlacionadas, múltiplos níveis de carga e avaliação de precisão da estimação de estado sem usar a SMC, ou seja, o algoritmo é baseado numa abordagem analítica. A função objetivo usada no problema de alocação de medidor está associada à maximização da precisão do estimador de estado. Essa função objetivo é otimizada considerando restrições para o número máximo de medidores que podem ser instalados e o nível de precisão do estimador de estado. O problema de otimização é resolvido com o algoritmo de enxame de partículas na versão binária (BPSO – *Binary Particle Swarm Optimization*). Os resultados dos testes indicaram que a alocação do medidor obtida com o algoritmo proposto é muito precisa para todos os níveis da curva de carga. Por exemplo, foi demonstrado que a precisão do estimador de estado é quatro vezes melhor quando a correlação nas medições de potência é incluída no modelo. Além disso, o custo computacional da estimativa da precisão do estado estimado com base na abordagem analítica proposta é cerca de 47 vezes menor do que o associado à SMC.

i-2) Raposo, A. A. M., Rodrigues, A. B., e Silva, M. G. (2020) Robust Meter Placement for State Estimation Considering Distribution Network Reconfiguration for Annual Energy Loss Reduction, **Electric Power Systems Research**, Vol. 182, pp. 1-9. DOI: <http://doi.org/10.1016/j.epsr.2020.106233>.

Resumo:

Este artigo propõe uma metodologia para alocar medidores em redes de distribuição orientadas à estimação de estado. A abordagem proposta considera que a alocação do medidor é realizada simultaneamente com a RRD para redução anual de perda de energia. Essa formulação do problema de alocação evita que a precisão do estimador de estado seja degradada quando a topologia for alterada e que um número excessivo de medidores seja instalado para obter uma precisão aceitável. Esses objetivos foram alcançados usando uma formulação multiobjetiva que minimiza perdas resistivas, o risco de violar a precisão do estimador de estado e o número de medidores instalados na

rede. O problema de alocação de medidores formulado neste artigo é resolvido através do MOBRKGA. Os resultados dos testes demonstram que o MOBRKGA pode gerar soluções de alta qualidade com redução significativa nas perdas anuais de energia e planos de medição com boa precisão e baixo custo de instalação.

ii) Artigos publicados em anais de congressos:

ii-1) Raposo, A. A. M., Rodrigues, A. B., e Silva, M. G. (2018) Alocação Ótima de Medidores para a Estimação de Estado Considerando a Reconfiguração da Rede de Distribuição. **XXII Congresso Brasileiro de Automática (CBA 2018), 9-12 de Setembro, 2018**, João Pessoa – Brasil, SBA, pp. 1-6. DOI: <https://doi.org/10.20906/cps/cba2018-0003>.

Resumo:

Este artigo propõe uma metodologia para alocação ótima de medidores orientada a estimação de estado em redes de distribuição. A metodologia proposta considera que a alocação de medidores é realizada de forma simultânea com a RRD para minimizar perdas resistivas. Esta formulação do problema de alocação evita que a precisão do estimador de estado seja deteriorada quando a topologia da rede elétrica é modificada. Estes objetivos foram alcançados usando-se uma formulação multiobjetivo fuzzy que minimiza as perdas resistivas, o número de medidores instalados e o risco de violar a precisão do estimador. A precisão do estimador é calculada analiticamente sem o uso da SMC. O problema de otimização descrito acima foi solucionado através do BRKGA. Os resultados demonstram que as soluções obtidas pelo método proposto tem boa qualidade e estabelecem um compromisso aceitável com os objetivos, isto é, topologias com reduções significativas nas perdas e planos de medição precisos e com baixo custo de instalação.

ii-2) Raposo, A. A. M., Costa, A. B., Rodrigues, A. B., e Silva, M. G. (2019) Algoritmo Colônia de Abelhas Artificiais para Alocação de Medidores e Reconfiguração em Redes de Distribuição. **14º Simpósio Brasileiro de Automação Inteligente (SBAI 2019), 27-30 de Outubro, 2019**, Ouro Preto – Brasil, SBA, pp. 536-541. DOI: <https://doi.org/10.17648/sbai-2019-112473>.

Resumo:

Este artigo propõe uma técnica probabilística para realizar simultaneamente a RRD e a alocação de medidores em redes de distribuição. Um modelo linearizado baseado em fórmulas analíticas fechadas é usado para avaliar a precisão de um plano de medição candidato para a estimação de estado. A técnica CAAOM foi utilizada para minimizar simultaneamente as perdas resistivas, o número de medidores e a imprecisão do estimador de estado. Além disso, o algoritmo proposto considera o efeito da correlação entre as medições. Os resultados dos testes demonstraram que o algoritmo de colônias de abelhas é capaz de obter topologias com reduções significativas nas perdas e planos de medição com precisão aceitável e número reduzido de medidores.

ii-3) Raposo, A. A. M., Filho, L. A. S., Rodrigues, A. B., e Silva, M. G. (2019) Alocação Ótima de Medidores para Estimação de Estado em Redes de Distribuição Considerando a Indisponibilidade das Medições. **XIII Conferência Brasileira sobre Qualidade de Energia Elétrica (CBQEE 2019), 1-4 de Setembro, 2019**, São Caetano do Sul – Brasil, SBQEE.

Resumo:

Este artigo propõe uma metodologia para alocação ótima de medidores para estimação de estado em redes de distribuição. A metodologia proposta considera que a alocação de medidores é realizada incluindo-se à indisponibilidade de até dois medidores multifuncionais. Esta formulação do problema de alocação evita que a precisão do estimador de estado seja degradada pelas falhas nos medidores. Consequentemente, pode-se obter estimativas mais precisas de índices de qualidade de energia associados com conformidade de tensão. A alocação de medidores foi realizada usando-se uma formulação multiobjetivo que maximiza a precisão do estimador e minimiza o número de medidores instalados na rede elétrica. Este problema de otimização foi solucionado usando-se a teoria de funções de utilidade, decisão com múltiplos objetivos e o BRKGA. Também foi considerado o efeito da correlação entre as medições. Os resultados dos testes demonstraram que a metodologia proposta obteve soluções de boa qualidade para o problema de alocação de medidores considerando-se as suas falhas.

REFERÊNCIAS

Ababei, C., e Kavasseri, R. (2011) Efficient network reconfiguration using minimum cost maximum flow-based branch exchanges and random walks-based loss estimations, **IEEE Trans. Power Systems**, Vol. 26, No. 1, pp. 30–37.

Abdelsalam, H. A., Abdelaziz, A. Y., Osama, R. A., e Salem, R. H. (2014) Impact of Distribution System Reconfiguration on Optimal Placement of Phasor Measurement Units. **2014 Clemson University Power Systems Conference, 11-14 de Março, 2014, Clemson USA**, IEEE, Piscataway, pp. 1-6.

Abur, A., e Expósito, A. G. (2004) **Power System State Estimation: Theory and Implementation**. CRC Press.

Alonso, F. R., Oliveira, D. Q., e De Souza, A. C. Z. (2015) Artificial Immune Systems Optimization Approach for Multiobjective Distribution System Reconfiguration, **IEEE Trans. on Power Systems**, Vol. 30, No. 2, pp. 840-847.

Al-Wakeel, A., Wu, J., e Jenkins N. (2016) State Estimation of Medium Voltage Distribution Networks Using Smart Meter Measurements, **Applied Energy**, Vol. 184, No. 15, pp. 207-218.

Andervazh, M. R., Olamaei, J., e Haghifam, M. R. (2013) Adaptive Multi-Objective Distribution Network Reconfiguration Using Multi-Objective Discrete Particles Swarm Optimization Algorithm and Graph Theory, **IET Generation, Transmission & Distribution**, Vol. 7, No. 12, pp. 1367-1382.

Ashisa, A., Sanjoy, D., e Anil, P. (2007) An AIS-ACO Hybrid Approach for Multi-objective Distribution System Reconfiguration, **IEEE Trans. on Power Systems**, Vol. 22, No. 3, pp. 1101–1111.

Bahadoorsingh, S., Milanovic, J. V., Zhang, Y., Gupta, C. P., e Dragovic, J. (2007) Minimization of Voltage Sag Costs by Optimal Reconfiguration of Distribution Network Using Genetic Algorithms, **IEEE Transactions on Power Delivery**, Vol. 22, No. 4, pp. 2271-2278.

Bakshi, T. (2020) **Tanmay Teaches Julia for Beginners: A Springboard to Machine Learning for All Ages**. New York, McGraw-Hill Education.

Baran, M. E., e Wu, F. F. (1989a) Optimal capacitor placement on radial distribution systems, **IEEE Transactions on Power Delivery**, Vol. 4, No. 1, pp. 725 – 734.

Baran, M. E., e Wu, F. F. (1989b) Network reconfiguration in distribution systems for loss reduction and load balancing, **IEEE Transactions on Power Delivery**, Vol. 4, No. 2, pp. 1401-1407.

Bean, J. C. (1994) Genetic Algorithms and Random Keys for Sequencing and Optimization, **ORSA Journal on Computing**, Vol. 6, No. 2, pp. 154–160.

Bernardon, D. P., e Garcia, V. J. (2018). **Smart Operation for Power Distribution Systems: Concepts and Applications**. Springer International Publishing.

Bezdek, J. C. (1981) **Pattern Recognition with Fuzzy Objective Function Algorithm**. Plenum Press.

Billinton, R., e Li, W. (1994) **Reliability Assessment of Electric Power Systems Using Monte Carlo Methods**. Springer.

Billinton, R., e Allan, R. N. (1996) **Reliability Evaluation of Power Systems**. 2^a ed. New York, Springer.

Boardman, E. (2020) Advanced Applications in Advanced Distribution Management System, **IEEE Power & Energy Magazine**, No. 1, pp. 43-54.

Borghetti, A. (2012) A mixed-integer linear programming approach for the computation of the minimum-losses radial configuration of electrical distribution networks, **IEEE Trans. Power Systems**, Vol. 27, No. 3, pp. 1264–1273.

Botea, A., Rintanen, J., e Banerjee, D. (2012) Optimal reconfiguration for supply restoration with informed A* search, **IEEE Trans. Smart Grid**, Vol. 3, No. 2, pp. 583–593.

Brown, R. E. (2009) **Electric Power Distribution Reliability**. 2^a ed. New York, Marcel Dekker.

Caro, E., Conejo, A. J., Mínguez, R., Zima, M., e Andersson, G. (2011) Multiple Bad Data Identification Considering Measurement Dependencies, **IEEE Trans. Power Systems**, Vol. 26, No. 4, pp. 1953–1961.

Caro, E., Morales, J. M., Conejo, A. J., e Mínguez, R. (2010) Calculation of Measurement Correlations Using Point Estimate, **IEEE Trans. on Power Delivery**, Vol. 25, No. 4, pp. 2095-2103.

Chagas, E. A., Rodrigues, A. B., e da Silva, M. G. (2018) Probabilistic Power Flow for Power Quality Assessment of Islanded Microgrid. **2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS 2018), 24-28 de Junho, 2018**, Boise–USA, IEEE, Piscataway, pp. 1-6.

Chen, T.-H., Chen, M.-S., Hwang, K.-J., Kotas, P., e Chebli, E. A. (1991) Distribution system power flow analysis – a rigid approach, **IEEE Trans. on Power Delivery**, Vol. 6, No. 3, pp. 1146-1152.

CIREN – 18th International Conference and Exhibition on Electricity Distribution, 2005. Turin, Italy, 6-9 June. (2005). **Control of Active Networks**, A. Shafiu, V. Thornley, N. Jenkins, e G. Strbac. Session No. 4, pp. 1-4.

Costa, A. S., e Salgado, R. (2001) **Notas de Aula da Disciplina EEL 7100 – Operação de Sistemas de Energia Elétrica** [Internet], DEE/UFSC. Disponível em:

<<http://www.labspot.ufsc.br/~simoes/osee/osee.html>>, [Acesso em: 23 de outubro de 2018].

D.-García, A. D., Heydt, G. T., e Suryanarayanan, S. (2011) **Implications of the Smart Grid Initiative on Distribution Engineering. Part 3 – Restoration, State Estimation and Reliability Enhancement**. Arizona State University, PSERC Publication.

Damavandi, M. G., Krishnamurthy, V., e Marti, J. R. (2015) Robust Meter Placement for State Estimation in Active Distribution Systems, **IEEE Trans. Smart Grid**, Vol. 6, No. 4, pp. 1972-1982.

Deb, C., Zhang, F., Yang, J., Li, S. E., e Shah, K. W. (2017) A review on time series forecasting techniques for building energy consumption, **Renewable and Sustainable Energy Reviews**, Vol. 74, pp. 902-924.

Deb, K., Pratep, A., Argawal, S., e Meyarivan, T. (2002) A Fast and Elite Multiobjective Genetic Algorithm: NSGA-II, **IEEE Trans. on Evolutionary Computation**. Vol. 6, No 2, pp. 182-197.

Debs, A. S. (1990) **Modern Power Systems Control and Operation**. Taiwan, Kluwer Academic Publishers.

Dunn, J. C. (1973) A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters, **Journal of Cybernetics**, Vol. 3, pp. 32-57.

E.-Hawary, M; E. (1998) **Electric Power Applications of Fuzzy Systems**. IEEE Press.

Eldurssi, A. M., e O'Connell, R. M. (2015) A Fast Nondominated Sorting Guided Genetic Algorithm for Multi-Objective Power Distribution System Reconfiguration Problem, **IEEE Trans. on Power Systems**, Vol. 30, No. 2, pp. 593-601.

Esmaili, A., Esmaili, S., e Hojabri, H. (2016) Short-Circuit Level Control Through a Multi-Objective Feeder Reconfiguration Using Fault Current Limiters in the Presence of Distributed Generations, **IET Generation, Transmission & Distribution**, Vol. 10, No. 14, pp. 3458-3469.

Expósito, A. G., Quiles, C. G., e Džafic, I. (2015) State Estimation in Two Time Scales for Smart Distribution Systems. **IEEE Trans. on Smart Grid**, Vol. 6, No. 1, pp. 421-430.

Fard, A. K., Niknam, T., Taherpoor, H., e Abbasi, A. (2015) Multi-objective probabilistic reconfiguration considering uncertainty and multi-level load model, **IET Science Measurement & Technology**, 2015, Vol. 9, Iss. 1, pp. 44–55.

FedCSIS – Federated Conference on Computer Science and Information Systems, 2013. Krakow, Poland, 8-11 September. (2013). **Biased Random-Key Genetic Algorithm With Hybrid Decoding for Multi-Objective Optimization**, P. Tangpattanukul, N. Jozefowicz, e P. Lopez. pp. 393-400.

Gers, J. M. (2013) **Distribution System Analysis and Automation**. London, The Institution of Engineering and Technology (IET).

Gomide, F., Gudwin, R., e Tanscheit, R. (1995) Conceitos Fundamentais da Teoria de Conjuntos Fuzzy, Lógica Fuzzy e Aplicações, **Proceedings 6th IFSA Congress - Tutorials**, pp. 1-38.

Gonçalves, J. F., e Resende, M. G. C. (2011) Biased Random-Key Genetic Algorithms for Combinatorial Optimization, **Journal of Heuristics**, Vol. 17, pp. 487-525.

Gupta, N., Swarnkar, A., Niazi, K. R., e Bansal, R. C. (2010) Multi-Objective Reconfiguration of Distribution Systems Using Adaptive Genetic Algorithm in Fuzzy Framework, **IET Generation, Transmission & Distribution**, Vol. 4, No. 12, pp. 1288-1298.

Jabr, R., Singh, R., e Pal, B. C. (2012) Minimum loss network reconfiguration using mixed-integer convex programming, **IEEE Trans. Power Systems**, Vol. 27, No. 2, pp. 1106–1115.

Jazebi, S. Hadji, M. M., e Naghizadeh, R. A. (2014) Distribution Network Reconfiguration in the Presence of Harmonic Loads: Optimization Techniques and Analysis, **IEEE Trans. on Smart Grid**, vol. 5, no. 4, pp. 1929-1935.

Juarez, E. E., e Hernández, A. (2007) A Method for Voltage Sag State Estimation in Power Systems, **IEEE Transactions on Power Delivery**, Vol. 22, No. 4, pp. 2517-2526.

Julia Computing (2020) **Energy Analytics and Optimization–PSR uses Julia for energy market simulation, analytics and planning** [Internet], Julia Computing. Disponível em: <https://juliacomputing.com/case-studies/psr.html> [Acessado 13 de Fevereiro de 2020].

Kashem, M. A., Ganapathy, V., e Jasmon, G. B. (1999) Network reconfiguration for load balancing in distribution networks, **IEE Proceedings - Generation, Transmission and Distribution**, Vol. 146, No. 6, pp. 563 – 567.

Kayal, P., e Chanda, C. K. (2013) Placement of Wind and Solar Based DGS in Distribution System for Power Loss Minimization and Voltage Stability Improvement, **Electrical Power and Energy Systems**, Vol. 53, pp. 795-809.

Kohonen, T. (2001) **Self-Organizing Maps**. 3ª ed. Springer.

Kruskal, J. B. (1956) On the shortest spanning subtree of a graph and the traveling salesman problem, **Proceedings of the American Mathematics Society**, Vol. 7, No. 1, pp. 48-50.

L.-Garcia, A. (2008) **Probability, Statistics, and Random Processes for Electrical Engineering**. 3ª ed. Pearson Prentice Hall.

Lewis, F. L., Xie, L., e Popa, D. (2008) **Optimal and Robust Estimation With an Introduction to Stochastic Control Theory**. 2^a ed. CRC Press.

Li, M., e Zheng, J. (2009) **Spread assessment for evolutionary multi-objective optimization**, in *Evolutionary Multi-Criterion Optimization*. Springer, pp. 216–230.

Lin, W. M., e Teng, J. H. (1996) Distribution Fast Decoupled State Estimation by Measurement Pairing, **IEE Proceedings-Generation, Transmission and Distribution**, 143 (1), pp. 43–48.

Lin, W. M., Teng, J. H., e Chen, S. J. (2001) A Highly Efficient Algorithm in Treating Current Measurements for the Branch-Current-Based Distribution State Estimation, **IEEE Trans. Power Delivery**, vol. 16, pp. 433–439.

Liu, J., Ponci, F., Monti, A., Muscas, C., Pegoraro, P. A., e Sulis, S. (2014) Optimal Meter Placement for Robust Measurement Systems in Active Distribution Grids, **IEEE Transactions on Instrumentation and Measurement**, Vol. 63, No. 5, pp. 1096-1105.

López, E., Opazo, H. García, L., e Bastard, P. (2004) Online reconfiguration considering variability demand: Applications to real networks, **IEEE Trans. Power Systems**, Vol. 19, No. 1, pp. 549–553.

Lu, C. N., Teng, J. H., e Liu, W. H. E. (1995) Distribution System State Estimation, **IEEE Trans. on Power Systems**, 10 (1), pp. 229–240.

MacQueen, J. B. (1967) Some Methods for Classification and Analysis of Multivariate Observations, **Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability**, 1, pp. 281-297.

Madtharad, C., Premrudeepreechacharn, S., Watson, N. R., e Udom, R. S. (2005) An optimal measurement placement method for power system harmonic state estimation, **IEEE Transactions on Power Delivery**, Vol. 20, No. 2, pp. 1514-1521.

Malekpour, A. R., Niknam, T., Pahwa, A., e Fard, A. K. (2013) Multi-Objective Stochastic Distribution Feeder Reconfiguration in Systems With Wind Power Generators and Fuel Cells Using the Point Estimate Method, **IEEE Trans. on Power Systems**. Vol. 28, No. 2, pp. 1483-1492.

Manito, A. R. A., Bezerra, U. H., Soares, T. M., Vieira, J. P. A., Nunes, M. V. A., Tostes, M. E. L., e Oliveira, R. C. (2019) Technical and non-technical losses calculation in distribution grids using a defined equivalent operational impedance. **IET Generation, Transmission & Distribution**, Vol. 13, No. 8, pp. 1315-1323.

Miller, S., e Childers, D. (2012) **Probability and Random Processes**. 2^a ed. Elsevier.

Monticelli, A. (1983) **Fluxo de Carga em Redes de Energia Elétrica**. São Paulo, São Paulo, Edgard Blücher LTDA.

Monticelli, A. (1999) **State Estimation in Electric Power Systems: A Generalized Approach**. New York, Massachusetts, Kluwer Academic Publishers.

Mendes, A., Boland, N., Guiney, P., e Riveros, C. (2013) Switch and tap changer reconfiguration of distribution networks using evolutionary algorithms, **IEEE Trans. Power Systems**, Vol. 28, No. 1, pp. 85–92.

Muhammad, M. A., Mokhlis, H., Naidu, K., Franco, J. F., Illias, H. A., e Wang, L. (2018) Integrated database approach in multiobjective network reconfiguration for distribution system using discrete optimisation techniques, **IET Generation, Transmission & Distribution**, Vol. 12, No. 4, pp. 976-986.

Muscas, C., Pilo, F., Pisano, G., e Sulis, S. (2006) Optimal placement of measurement devices in electric distribution systems. **23rd IEEE Instrumentation and Measurement Technology Conference (IMTC/06), 24-27 de Abril, 2006**, Sorrento Italy, IEEE, Piscataway, pp. 1873 - 1878.

Muscas, C., Pilo, F., Pisano, G., e Sulis, S. (2009) Optimal Allocation of Multichannel Measurement Devices for Distribution State Estimation, **IEEE Transactions on Instrumentation and Measurement**, Vol. 58, No. 6, pp. 1929-1937.

Narimani, M. R., Vahed, A. A., A.-Abarghoee, R., e Javidsharifi, M. (2014) Enhanced Gravitational Search Algorithm for Multi-Objective Distribution Feeder Reconfiguration Considering Reliability, Loss and Operational Cost, **IET Generation, Transmission & Distribution**, Vol. 8, No. 1, pp. 55-69.

Nešetřil, J., e Nešetřilová, H. (2012) The Origins of Minimal Spanning Tree Algorithms – Borůvka and Jarník, **Documenta Math**, Extra Volume ISMP, pp. 127-141.

Paterakis, N. G., Mazza, A., Santos, S. F., Erdinç, O., Chicco, G., Bakirtzis, A. G., e Catalão, J. P. S. (2016) Multi-Objective Reconfiguration of Radial Distribution Systems Using Reliability Indices, **IEEE Trans. on Power Systems**, Vol. 31, No. 2, pp. 1048-1062.

Pfitscher, L. L., Bernardon, D. P., Canha, L. N., Montagner, V. F., e Abaide, A. R. (2013) Intelligent system for automatic reconfiguration of distribution network in real time, **Electric Power Systems Research**, Vol. 97, pp. 84-92.

Prim, R. C. (1957) Shortest connection matrix network and some generalizations, **Bell System Technical Journal**, Vol. 36, pp. 1389-1401.

Raidl, G. R. (2000) An Efficient Evolutionary Algorithm for the Degree-Constrained Minimum Spanning Tree Problem, **Proceedings of the 2000 congress on evolutionary computation**, pp. 104-111.

Rajičić, D., e Taleski, R. (1998) Two novel methods for radial and weakly meshed network analysis, **Electric Power Systems Research**, Vol. 48, No. 2, pp. 79-87.

Ramos, E. R., Santos, J. R., e Reyes, J. (2010) A simpler and exact mathematical model for the computation of the minimal power losses tree, **Electric Power Systems Research**, Vol. 80, No. 5, pp. 562–571.

Rao, R., Ravindra, K., Satish, K., e Narasimham, S. (2013) Power loss minimization in distribution system using network reconfiguration in the presence of distributed generation, **IEEE Trans. Power Systems**, Vol. 28, No. 1, pp. 317–325.

Raposo, A. A. M., (2016) **Alocação de Medidores para a Estimação de Estado em Redes Elétricas Inteligentes**, Dissertação de Mestrado, PPGEE-UFMA.

Raposo, A. A. M., Rodrigues, A. B., e Da Silva, M. (2017) Optimal Meter Placement Algorithm for State Estimation in Power Distribution Networks, **Electric Power Systems Research**, Vol. 147, pp. 22-30.

Raposo, A. A. M., Rodrigues, A. B., e Silva, M. G. (2018) Alocação Ótima de Medidores para a Estimação de Estado Considerando a Reconfiguração da Rede de Distribuição. **XXII Congresso Brasileiro de Automática (CBA 2018), 9-12 de Setembro, 2018**, João Pessoa – Brasil, SBA, pp. 1-6.

Raposo, A. A. M., Costa, A. B., Rodrigues, A. B., e Silva, M. G. (2019a) Algoritmo Colônia de Abelhas Artificiais para Alocação de Medidores e Reconfiguração em Redes de Distribuição. **14º Simpósio Brasileiro de Automação Inteligente (SBAI 2019), 27-30 de Outubro, 2019**, Ouro Preto – Brasil, SBA, pp. 536-541.

Raposo, A. A. M., Filho, L. A. S., Rodrigues, A. B., e Silva, M. G. (2019b) Alocação Ótima de Medidores para Estimação de Estado em Redes de Distribuição Considerando a Indisponibilidade das Medições. **XIII Conferência Brasileira sobre Qualidade de Energia Elétrica (CBQEE 2019), 1-4 de Setembro, 2019**, São Caetano do Sul – Brasil, SBQEE.

Raposo, A. A. M., Rodrigues, A. B., e Silva, M. G. (2020) Robust Meter Placement for State Estimation Considering Distribution Network Reconfiguration for Annual Energy Loss Reduction, **Electric Power Systems Research**, Vol. 182, pp. 1-9.

Riquelme, N., Lüken, C. V., e Baran, B. (2015) Performance metrics in multi-objective optimization. **Latin American Computing Conference (CLEI), 19-23 de Outubro, 2015**, Arequipa Peru, IEEE.

Rodrigues, A. C., Costa, A. S., e Issicaba, D. (2018) Identification of Non-Technical Losses in Distribution Systems via State Estimation and Geometric Tests. **VII Simpósio Brasileiro de Sistemas Elétricos (SBSE 2018)**, 12-16 de Maio, 2018, Niterói-RJ Brasil, IEEE, Piscataway, pp. 1-8.

Savner, J. S., e Das, D. (2007). Impact of network reconfiguration on loss allocation of radial distribution systems, **IEEE Trans. on Power Delivery**, Vol. 22, No. 4, pp. 2473-2480.

Schott, J. R. (1995) **Fault tolerant design using single and multicriteria genetic algorithm optimization**, DTIC Document, Tech. Rep..

Shirmohammadi, D., Hong, H. W., Semlyen, A., e Luo, G. X. (1988) A compensation-based power flow method for weakly meshed distribution and transmission networks, **IEEE Trans. on Power Systems**, Vol. 3, No. 2, pp. 753-762.

- Shukla, J., Das, B., e Pant, V. (2017) Consideration of small signal stability in multi-objective DS reconfiguration in the presence of distributed generation, **IET Generation, Transmission & Distribution**, Vol. 11, No. 1, pp. 236–245.
- Silva, R. M. A., Resende, M. G. C., Pardalos, P. M., e Facó, J. L. (2013) Biased Random-Key Genetic Algorithm for Nonlinearly-Constrained Global Optimization, **Congress on Evolutionary Computation**, pp. 2201-2206.
- Silva, R. S., Fernandes, T. R., e Almeida, M. C. (2018) Specifying angular reference for three-phase distribution system state estimators, **IET Generation, Transmission & Distribution**, Vol. 12, No. 7, pp. 1655-1663.
- Singh, R., Pal, B. C., e Jabr, R. A. (2008) Choice of estimator for distribution system state estimation, **IET Generation, Transmission & Distribution**, 3 (7), pp. 666–678.
- Singh, R., Pal, B. C., e Vinter, R. B. (2009) Measurement Placement in Distribution System State Estimation, **IEEE Trans. on Power Systems**, Vol. 24, No. 2, pp. 668-675.
- Singh, R., Pal, B. C., e Vinter, R. B. (2011) Meter Placement for Distribution System State Estimation: An Ordinal Optimization Approach, **IEEE Trans. on Power Systems**, Vol. 26, No. 4, pp. 2328-2335.
- Souza, S. S. F., Romero, R., Pereira, J., e Saraiva, J. T. (2016) Artificial immune algorithm applied to distribution system reconfiguration with variable demand, **International Journal of Electrical Power & Energy Systems**, Vol. 82, pp. 561-568.
- Spears, W. M., e DeJong, K. A. (1991) On the virtues of parameterized uniform crossover, **Proceedings of the Fourth International Conference on Genetic Algorithms**, pp. 230-236.
- Srinivasa, R. R., Ravindra, K., Satisk, K., e Narasimham, S. V. L. (2013) Power Loss Minimization in Distribution System Using Network Reconfiguration in the Presence on Distributed Generation, **IEEE Trans. on Power Systems**, Vol. 28, No. 1, pp. 317–325.
- Tahboub, A. M., Pandi, V. R., e Zeineldin, H. H. (2015) Distribution System Reconfiguration for Annual Energy Loss Reduction Considering Variable Distributed Generation Profiles, **IEEE Transactions on Power Delivery**, Vol. 30, No 4, pp. 1677-1685.
- Takenobu, Y., Yasuda, N., Kawano, S., Hayashi, Y., e Minato, S. (2018) Evaluation of Annual Energy Loss Reduction Based on Reconfiguration Scheduling, **IEEE Transactions on Smart Grid**, Vol. 9, No 3, pp. 1986 – 1996.
- Tanscheit, R. (2007) **Sistemas fuzzy**, Inteligência computacional aplicada a administração, economia e engenharia em Matlab, São Paulo, Thomson Learning, pp. 229-264

- Taylor, J. A., e Hover, F. S. (2012) Convex models of distribution system reconfiguration, **IEEE Trans. Power Systems**, Vol. 27, No. 3, pp. 1407–1413.
- Veldhuizen, D. A. V. (1999) Multiobjective evolutionary algorithms: classifications, analyses, and new innovations, **Air Force Inst. Technol.**, Dayton, OH, Tech. Rep. AFIT/DS/ENG/99-01.
- Venkatesh, B, Ranjan, R., e Gooi, H. B. (2004) Optimal Reconfiguration of Radial Distribution Systems to Maximize Loadability, **IEEE Trans. on Power Systems.**, vol. 19, No. 1, pp. 260-266.
- Wang, C., e Gao, Y. (2013) Determination of power distribution network configuration using non-revisiting genetic algorithm, **IEEE Trans. Power Systems**, Vol. 28, No. 4, pp. 3638–3648.
- Wang, H., e Schulz, N. N. (2004) A Revised Branch Current-Based Distribution System State Estimation Algorithm and Meter Placement Impact, **IEEE Trans. on Power Systems**, 19 (1), pp. 207–213.
- Wang, H., Zhang, W., e Liu, Y. (2018) A Robust Measurement Placement Method for Active Distribution System State Estimation Considering Network Reconfiguration, **IEEE Trans. Smart Grid**, Vol. 9, No. 3, pp. 2108-2117.
- Yin, S. A., e Lu, C. N. (2009) Distribution feeder scheduling considering variable load profile and outage costs. **IEEE Trans. Power Systems**, Vol. 24, No. 2, pp. 652–660.
- Zadeh, L. A. (1965) Fuzzy Sets, **Information and Control**, Vol. 8, pp. 338-353.
- Zadeh, L. A. (1988) Fuzzy Logic, **IEEE Computer**, Vol. 21, No. 4, pp. 83-93.
- Zare, M., Abarghooee, R. A., Hooshmand, R. A., e Malekpour, M. (2018) Optimal reconfigurattion of distribution systems by considering switch and wind turbine placements to enhance reliability and efficiency, **IET Generation, Transmission & Distribution**, Vol. 12, No. 6, pp. 1271-1284.
- Zheng, J.-N., Chien, C.-F., e Gen, M. (2015) Multi-Objective Multi-Population Biased Random-Key Genetic Algorithm for the 3-D Container Loading Problem, **Computers and Industrial Engineering**, Vol. 89, pp. 80-87.
- Zitzler, E., e Thiele, L. (1999) Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach, **IEEE Trans. Evolutionary Computation**, Vol. 3, No 4, pp. 257-271.