

Universidade Federal de Juiz de Fora

Programa de Pós-Graduação em Engenharia Elétrica

Doutorado em Engenharia Elétrica

Felipe Gomes Duque

**METODOLOGIA PARA ESTIMAÇÃO DE ESTADOS E
ALOCAÇÃO DE EQUIPAMENTOS DE MEDIÇÃO EM
SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Juiz de Fora

2018

Felipe Gomes Duque

**Metodologia para Estimação de Estados e Alocação de Equipamentos de Medição em
Sistemas de Distribuição de Energia Elétrica**

Trabalho apresentado ao Programa de Pós-Graduação em Engenharia Elétrica, área de concentração: Sistemas de Energia, da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do Grau de Doutor em Engenharia Elétrica.

Orientador: Prof. Leonardo Willer de Oliveira, D. Sc.

Co-Orientador: Prof. Edimar José de Oliveira, D. Sc.

Juiz de Fora

2018

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Gomes Duque, Felipe.

Metodologia para Estimção de Estados e Alocação de Equipamentos de Medição em Sistemas de Distribuição de Energia Elétrica / Felipe Gomes Duque. -- 2018.

176 f.

Orientador: Leonardo Willer de Oliveira

Coorientador: Edimar José de Oliveira

Tese (doutorado) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2018.

1. Sistema de Energia Elétrica. I. Willer de Oliveira, Leonardo, orient. II. José de Oliveira, Edimar, coorient. III. Título.

Felipe Gomes Duque

**Metodologia para Estimaco de Estados e Alocao de Equipamentos de Medicao em
Sistemas de Distribuico de Energia Eltrica**

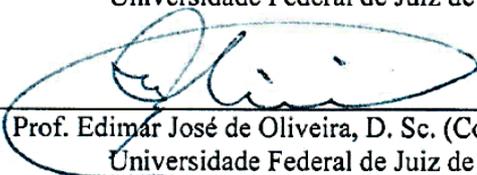
Trabalho apresentado ao Programa de Ps-Graduao em Engenharia Eltrica, rea de concentrao: Sistemas de Energia, da Universidade Federal de Juiz de Fora como requisito parcial para obteno do Grau de Doutor em Engenharia Eltrica.

Aprovada por:

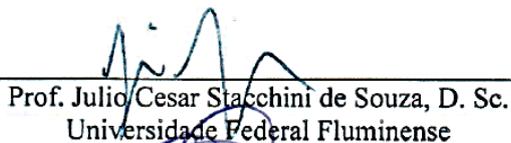
BANCA EXAMINADORA



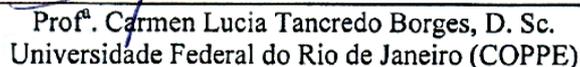
Prof. Leonardo Willer de Oliveira, D. Sc. (Orientador)
Universidade Federal de Juiz de Fora



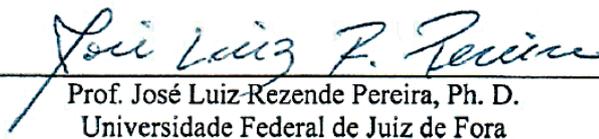
Prof. Edimar Jos de Oliveira, D. Sc. (Co-Orientador)
Universidade Federal de Juiz de Fora



Prof. Julio Cesar Stacchini de Souza, D. Sc.
Universidade Federal Fluminense



Prof.^a Carmen Lucia Tancredo Borges, D. Sc.
Universidade Federal do Rio de Janeiro (COPPE)



Prof. Jos Luiz Rezende Pereira, Ph. D.
Universidade Federal de Juiz de Fora



Prof. Leonardo de Mello Honrio, D. Sc.
Universidade Federal de Juiz de Fora

Dedico este trabalho aos meus pais, Roberto Augusto Duque e Eliana Gomes Duque e minha amada Ana Carolina Santos de Freitas.

AGRADECIMENTOS

A Deus, por me guiar e permitir a realização deste trabalho.

Aos meus familiares, em especial aos meus pais Roberto Augusto Duque e Eliana Gomes Duque, pelo incentivo e apoio durante toda a minha vida. A minha amada Ana Carolina Santos de Freitas por estar sempre ao meu lado e pela compreensão nos momentos distantes. Aos meus irmãos, Luca Gomes Duque de Oliveira e Vivian Gomes Duque por acreditarem em mim no alcance dos objetivos.

Aos meus amigos, de graduação Sílio Sperandio, de mestrado e doutorado Diego Arcanjo, Francisco Coelho, Heverton Souza, Thiago Resende e Wesley Peres, pelo companheirismo, discussões técnicas e sugestões durante todo este período.

Ao professor Leonardo Willer de Oliveira pela orientação, contribuição nos trabalhos publicados, pelo apoio, motivação, incentivo ao ingresso e concretização deste trabalho.

Ao professor Edimar José de Oliveira pelo imenso apoio e cooperação nas publicações dos trabalhos e efetivação dos mesmos.

Aos professores Vander Menengoy e José Luiz Rezende Pereira pelas diversas contribuições e sugestões dadas na UFJF durante o doutorado.

Aos membros da banca Julio Cesar Stacchini de Souza, Carmen Lucia Tancredo Borges, José Luiz Rezende Pereira e Leonardo de Mello Honório pela atenção, sugestões dadas ao trabalho e pela participação na banca.

Aos professores e pesquisadores do PPEE/UFJF pelos conhecimentos passados, que direta ou indiretamente contribuíram para a realização deste trabalho.

Ao LABSPOT (Laboratório de Sistemas de Potência do Programa de Pós Graduação em Engenharia Elétrica), pelo suporte técnico.

Ao CNPQ, ao INERGE, à FAPEMIG e ao CEPTEL.

*Não tente. Faça... ou não
faça. Não há tentativa.*

Mestre Yoda

Resumo da Tese de Doutorado apresentada à UFJF como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D. Sc.).

METODOLOGIA PARA ESTIMAÇÃO DE ESTADOS E ALOCAÇÃO DE EQUIPAMENTOS DE MEDIÇÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Felipe Gomes Duque

Abril de 2018

Orientador: Prof. Leonardo Willer de Oliveira, D. Sc.

Co-Orientador: Prof. Edimar José de Oliveira, D. Sc.

Programa: Engenharia Elétrica.

O presente trabalho propõe uma metodologia de planejamento de medição em Sistemas de Distribuição de Energia Elétrica (SDE) e um novo método para estimação de estados destes sistemas. Para tanto, a técnica metaheurística de otimização bio-inspirada denominada *Modified Monkey Search (MMS)* é proposta para alocação ótima de medidores inteligentes e unidades de medição fasorial. O modelo de otimização é multiobjetivo e visa a maximização da eficácia do processo de estimação de estados com o custo mínimo de investimento em sistemas de medição. O método de Pareto é associado ao algoritmo *MMS* para o tratamento adequado destes objetivos conflitantes considerando-se custos reais associados aos equipamentos de medição. Adicionalmente, um novo método de estimação de estados baseado na modelagem de um Fluxo de Potência Ótimo (FPO) modificado é proposto, cuja resolução é dada pelo Método de Pontos Interiores (MPI). O algoritmo *MMS* determina as variáveis discretas associadas aos tipos de equipamentos de medição, bem como aos locais de instalação dos mesmos no SDE. Estudos são realizados para comparar a nova metodologia de estimação de estados proposta com uma metodologia tradicional, bem como para comparar os resultados da metaheurística de otimização aplicada ao problema com outras técnicas desenvolvidas para esta finalidade. Os estudos são conduzidos com sistemas da literatura, além de um sistema real de médio porte de uma concessionária brasileira.

Palavras-chave: Planejamento de Medição, Alocação ótima, Estimação de Estados, Otimização Multiobjetivo, Distribuição.

Abstract of thesis presented to UFJF as a partial fulfillment of the requirements for a Doctor of Science degree (D. Sc.)

METHODOLOGY FOR STATE ESTIMATION AND ALLOCATION OF
MEASUREMENT EQUIPMENT IN ELECTRICITY DISTRIBUTION SYSTEM

Felipe Gomes Duque

April 2018

Advisor: Leonardo Willer de Oliveira, D. Sc.

Co-Advisor: Edimar José de Oliveira, D. Sc.

Department: Electrical Engineering.

The present work proposes an approach for planning the measurement locations in Electric Distribution Systems (EDS) and a new method for static state estimation. The bio-inspired meta-heuristic optimization technique called Modified Monkey Search (MMS) is proposed for optimal allocation of smart meters and phasor measurement units. The optimization model is multiobjective and aims at maximizing the efficiency of the state estimation process with minimum measurement investment costs. The Pareto's method is associated with the MMS algorithm for handling the conflicting objectives in a suitable manner by considering real costs related to measurement equipments. In addition, a new method for static state estimation based on the modeling of a modified Optimal Power Flow (OPF) is proposed, whose solution is given by the Interior Point Method (IPM). The MMS algorithm determines the discrete variables related to types and location of measurement equipments in the system. Studies are made to compare the new approach for static state estimation with a traditional method, as well as to compare the results from the meta-heuristic optimization applied to the problem with existing techniques. The studies are performed using systems from the literature, as well as a practical medium size distribution network from a Brazilian utility.

Keywords: Measurement Planning, Optimal Allocation, Static State Estimation, Multiobjective Optimization, Distribution.

Sumário

1	INTRODUÇÃO.....	1
1.1	CONSIDERAÇÕES INICIAS	1
1.2	REDES DE DISTRIBUIÇÃO INTELIGENTES.....	3
1.3	OBJETIVO	4
1.4	PUBLICAÇÕES DECORRENTES DO TRABALHO	5
1.5	ESTRUTURA DA PROPOSTA DE TRABALHO	6
2	MONITORAMENTO E ESTIMAÇÃO DE ESTADOS DE SISTEMAS DE ENERGIA	7
2.1	CONSIDERAÇÕES INICIAIS	7
2.2	UNIDADES DE MEDIÇÃO FASORIAL	8
2.2.1	Sistema de Medição Fasorial.....	8
2.2.2	Medida Fasorial.....	10
2.2.3	Norma IEC 61850	12
2.3	MEDIDORES INTELIGENTES	13
2.3.1	Evolução dos Sistemas de Monitoramento	14
2.3.2	Tipos de Plataforma de Comunicação.....	15
2.4	ESTUDOS ENVOLVENDO UMF E MI NA TRANSMISSÃO	16
2.5	ESTUDOS ENVOLVENDO UMF E MI NA DISTRIBUIÇÃO	17
2.6	ETAPAS DO PROCESSO DE ESTIMAÇÃO DE ESTADOS	19
2.6.1	Método do mínimo valor absoluto	22
2.6.2	Estimador de Máximo de Verossimilhança.....	22
2.6.3	Método de processamento de dados afetados por erros	23
2.7	ALTERNATIVAS PARA APERFEIÇOAMENTO DO PROCESSO DE ESTIMAÇÃO DE ESTADOS	23
2.7.1	Filtro de Kalman.....	23
2.7.2	M-Estimador.....	24
2.7.3	Filtro de Raiz Quadrada	24
2.7.4	Inteligência Artificial	25
2.8	CONSIDERAÇÕES FINAIS	25
3	ESTIMAÇÃO DE ESTADOS, CARACTERÍSTICAS E MÉTODOS MATEMÁTICOS PARA RESOLUÇÃO	26
3.1	CONSIDERAÇÕES INICIAIS	26

3.2	COMPOSIÇÃO DO ESTIMADOR DE ESTADOS DC.....	26
3.3	VARIÁVEIS DE ESTADO	27
3.4	EQUAÇÕES DAS MEDIDAS	29
3.5	RESOLUÇÃO DO PROBLEMA DE ESTIMAÇÃO DC	31
3.6	COMPOSIÇÃO DO ESTIMADOR DE ESTADOS AC.....	33
3.7	FUNÇÃO NÃO LINEAR PARA O SEP.....	35
3.8	COMPOSIÇÃO DA MATRIZ JACOBIANA H	36
3.9	ESTIMAÇÃO DE ESTADOS COM DIVERSIDADE DE MEDIDAS.....	39
3.9.1	Etapa 1 – Processamento de dados de menor precisão	39
3.9.2	Etapa 2 – Pós-Processamento de dados de tensão.....	41
3.9.3	Etapa 2 – Pós-Processamento de dados de tensão e corrente.....	42
3.10	CONSIDERAÇÕES FINAIS	43
4	METODOLOGIA PROPOSTA	44
4.1	CONSIDERAÇÕES INICIAIS	44
4.2	METODOLOGIA PROPOSTA PARA ESTIMAÇÃO DE ESTADOS.....	45
4.2.1	Modelo de Fluxo de Potência Ótimo Modificado ($E-OPF$).....	45
4.2.2	Representação da Carga	50
4.3	METODOLOGIA DE PLANEJAMENTO DE MEDIÇÃO – ABORDAGEM MONO-OBJETIVO	51
4.4	METODOLOGIA DE PLANEJAMENTO DE MEDIÇÃO – ABORDAGEM MULTIOBJETIVO	54
4.4.1	Formulação de um Problema Multiobjetivo.....	55
4.4.2	Conjunto Ótimo de Pareto.....	56
4.4.3	Função de aptidão.....	58
4.4.4	Aplicação do Método de Pareto para o Problema de Planejamento Proposto	60
4.5	FLUXOGRAMA DA METODOLOGIA DE PLANEJAMENTO PROPOSTA	62
4.6	SISTEMA TUTORIAL.....	66
4.7	CONSIDERAÇÕES FINAIS	77
5	VALIDAÇÃO DO NOVO MODELO DE ESTIMAÇÃO DE ESTADOS.....	78
5.1	CONSIDERAÇÕES INICIAIS	78
5.2	SISTEMA DE 14 BARRAS.....	79
5.2.1	Sistema 14 barras, Condição 1	81
5.2.2	Sistema 14 barras, Condição 2	85

5.2.2.1	Condição 2.1 - Minimização do índice DEE.....	86
5.2.2.2	Condição 2.2 - Minimização da FOB constituída de DEE e LAV	86
5.2.3	Sistema 14 barras, Condição 3	89
5.3	SISTEMA DE 33 BARRAS.....	91
5.3.1	Sistema 33 barras, Condição 1	92
5.3.2	Sistema 33 barras, Condição 2	96
5.3.3	Sistema 33 barras, Condição 3	98
5.4	CONSIDERAÇÕES FINAIS	99
6	RESULTADOS DA METODOLOGIA PROPOSTA	100
6.1	RESULTADOS PARA O MODELO DE PLANEJAMENTO MONO-OBJETIVO	101
6.1.1	Sistema 33 barras, Análise A	102
6.1.2	Sistema 33 barras, Análise B.....	108
6.2	RESULTADOS PARA O MODELO DE PLANEJAMENTO MONO-OBJETIVO E EQUIPAMENTOS COMERCIAIS	110
6.2.1	Sistema de 119 barras.....	112
6.2.2	Sistema de 476 barras.....	115
6.3	RESULTADOS PARA O MODELO DE PLANEJAMENTO MULTI-OBJETIVO	118
6.3.1	Planejamento Multiobjetivo - sistema de 119 barras	118
6.3.2	Planejamento Multiobjetivo - sistema de 476 barras	122
6.4	CONSIDERAÇÕES FINAIS	126
7	CONCLUSÕES.....	128
7.1	CONSIDERAÇÕES FINAIS	128
7.2	PROPOSTA DE CONTINUIDADE.....	130
APÊNDICE A.....		131
A.1	CONSIDERAÇÕES INICIAIS	131
A.2	PARÂMETROS DA ÁRVORE INICIAL	133
A.3	MEMÓRIA ADAPTATIVA	134
A.4	MECANISMO DE PERTURBAÇÃO DA SOLUÇÃO	135
A.5	CONVERGÊNCIA	137
A.6	PROCESSO DE INTENSIFICAÇÃO	137
A.7	FLUXOGRAMA DO ALGORITMO PROPOSTO DO MMS	138

APÊNDICE B.....	141
B.1 MÉTODO DE RESOLUÇÃO DO PROBLEMA DE OTIMIZAÇÃO <i>E-OPF</i>	141
B.2 MÉTODO PRIMAL-DUAL DOS PONTOS INTERIORES	141
REFERÊNCIAS BIBLIOGRÁFICAS	145

LISTA DE FIGURAS

Figura 2.1. Sistema de medição fasorial sincronizado.	9
Figura 2.2. Estrutura básica de uma UMF.	10
Figura 2.3. Representação fasorial de um sinal senoidal.	11
Figura 2.4. Comunicação via norma IEC 61850 em paralelo com link IEEE 802.11.	13
Figura 2.5. Evolução do sistema de monitoramento.	15
Figura 2.6. Etapas básicas do processo de estimação de estados.	20
Figura 2.7. Modelo seção barramento-dispositivos seccionadores e modelo barra-linha (G_n – gerador, T_n – Transformador, LT_n – Linha de Transmissão, SE_n – Subestação, CS_n – Condensador Síncrono, C_n – Carga, DS_n – Dispositivo Seccionador)	20
Figura 3.1. Sistema de 3 barras.	28
Figura 3.2. Sistema de 3 barras com medições.	30
Figura 3.3. Modelo π equivalente da rede.	35
Figura 4.1. Modelo da rede não linear.	48
Figura 4.2. Codificação de uma solução candidata no <i>MMS</i> proposto.	53
Figura 4.3. Curva ou superfície de Pareto para um problema de minimização de duas funções.	56
Figura 4.4. Tipos de curvas de Pareto.	57
Figura 4.5. Curva ilustrativa dos parâmetros associados à aptidão no método de Pareto.	59
Figura 4.6. Fronteira de Pareto para o problema de planejamento proposto.	61
Figura 4.7. Fluxograma da metodologia proposta.	63
Figura 4.8. Sistema 14 barras modificado.	67
Figura 4.9 – Fronteiras de Pareto para a população inicial, sistema 14 barras.	74
Figura 4.10 – Primeira fronteira de Pareto após a convergência do <i>MMS</i> , sistema 14 barras.	76
Figura 5.1. Demandas de potência ativa.	80
Figura 5.2. Demanda Aleatória Ativa do Caso Base Sistema 14 barras.	82
Figura 5.3. <i>FOB</i> , sistema 14 barras, Condição 1.	83
Figura 5.4. Valores reais e estimados de módulo de tensão, 14 barras, Condição 1.	84

Figura 5.5. Valores reais e estimados de ângulo de fase, 14 barras, Condição 1.	85
Figura 5.6. Impacto do número de UMF na <i>FOB</i> , sistema 14 barras, Condições 2.1 e 2.2.	87
Figura 5.7. Comparativo estimativas de módulo de tensão, sistema 14 barras.	88
Figura 5.8. Comparativo estimativas de ângulo de fase, sistema 14 barras.	89
Figura 5.9. Sistema de 33 barras.....	91
Figura 5.10. Demanda Aleatória Ativa do Caso Base Sistema 33 barras.	93
Figura 5.11. Variação da <i>FOB</i> , sistema 33 barras, Condição 1.....	94
Figura 5.12. Módulo de tensão por barra, sistema 33 barras, Condição 1.	95
Figura 5.13. Módulo de tensão por barra, sistema 33 barras, Condição 1.	95
Figura 5.14. Evolução <i>FOB</i> , sistema 33 barras, Condição 2.....	97
Figura 5.15. Número de simulações do <i>E-OPF</i> , sistema 33 barras, Condição 2.	98
Figura 6.1. <i>FOB</i> do <i>MMS</i> , sistema 33 barras, Análise A.	105
Figura 6.2 – Módulos de tensão, sistema de 33 barras, Análise A.	105
Figura 6.3 – Ângulos de fase, sistema de 33 barras, Análise A.	106
Figura 6.4. <i>FOB</i> do <i>MMS</i> , sistema 33 barras, Análise B.....	109
Figura 6.5 – Configuração dos Canais de Medição.....	111
Figura 6.6. Sistema 119 barras.	113
Figura 6.7 – Configuração da medição, sistema 119, equipamentos comerciais.	115
Figura 6.8. Sistema 476 barras.	116
Figura 6.9 – Fronteiras de Pareto para a população inicial, sistema 119 barras.....	119
Figura 6.10 – Primeira fronteira obtida pelo <i>MMS</i> -Pareto, sistema 119 barras.	120
Figura 6.11 – Fronteiras de Pareto para a população inicial, sistema 476 barras.....	123
Figura 6.12 – Fronteiras de Pareto para a população final, sistema 476 barras.	123

LISTA TABELAS

Tabela 3.1– Matriz Jacobiana para estimação de estados	36
Tabela 4.1 – Dados de barras do sistema 14 barras modificado.....	67
Tabela 4.2 – Dados dos Equipamentos de Medição IMS.....	68
Tabela 4.3 – Dados da população inicial do <i>MMS</i> , sistema tutorial.....	70
Tabela 4.4 – Resultado do fluxo de potência, sistema 14 barras.	71
Tabela 4.5 – Valores de correntes, sistema 14 barras.....	71
Tabela 4.6 – Fronteiras das soluções da população inicial, sistema 14 barras.	73
Tabela 4.7 – Matriz <i>A</i> com as funções de aptidão, sistema 14 barras.	75
Tabela 4.8 – Matriz de Planejamento, sistema 14 barras.	77
Tabela 5.1 – Limites de demanda.....	80
Tabela 5.2 – Variações <i>FOB</i> , sistema 14 barras, Condição 1.	83
Tabela 5.3 – Resultados, sistema 14 barras, Condição 1.....	85
Tabela 5.4 – Resultados sistema 14 barras, Condição 2.1.....	86
Tabela 5.5 – Resultados sistema 14 barras, Condição 2.2.....	86
Tabela 5.6 – Configurações do sistema 14 barras.	89
Tabela 5.7 – Resultados sistema 14 barras, Condição 3.....	90
Tabela 5.8 – Resultados para 4 UMFs no sistema 14 barras e diferentes topologias.....	91
Tabela 5.9 – Solução FPC, sistema 33 barras.....	92
Tabela 5.10 – Variações <i>FOB</i> , sistema 14 barras, Condição 1.	94
Tabela 5.11– Resultados, sistema 33 barras, Condição 1.....	96
Tabela 5.12 – Resultados sistema 33 barras, Condição 2.....	96
Tabela 5.13 – Configurações original e adicionais do sistema 33 barras.....	98
Tabela 5.14 – Resultados, sistema 33 barras, Condição 3 e 1 UMF na SE.....	98
Tabela 5.15 – Resultados, sistema 33 barras, Condição 3 e 4 UMFs no sistema.....	99
Tabela 6.1 –Valores Reais e Estimados sem alocação de UMF e MI, sistema 33 barras.	103
Tabela 6.2 – I_{MVD} e I_{AFD} sem alocação de UMF e MI, sistema 33 barras.....	104

Tabela 6.3 – Resultados Análise A, sistema 33 barras.....	104
Tabela 6.4 – Resultados sistema 33 barras, Análise A, UMF e MI em todas a barras.....	107
Tabela 6.5 – Resultados sistema 33 barras, Análise A, UMF e MI nos finais do alimentador.	107
Tabela 6.6– Resultados de <i>FOB</i> , sistema 33 barras, Análise B, sem UMF e MI.....	108
Tabela 6.7 – Resultados de <i>FOB</i> , sistema 33 barras, Análise B, com <i>UMF</i> e/ou <i>MI</i>	109
Tabela 6.8 – Resultados dos Passos (<i>a</i>) e (<i>b</i>), sistema 119 barras.....	112
Tabela 6.9 – Resultados dos passos com parâmetros ótimos, sistema 119 barras.	114
Tabela 6.10 – Resultados, sistema 119 barras, equipamentos comerciais.	114
Tabela 6.11 – Resultados, sistema 476 barras, equipamentos comerciais.	117
Tabela 6.12 – Dados da população inicial, sistema 119 barras.	120
Tabela 6.13 – Opções de planejamento, sistema 119 barras - barras monitoradas.	121
Tabela 6.14 – Opções de planejamento, sistema 119 barras - trechos monitorados.	121
Tabela 6.15 – Opções de planejamento, sistema 119 barras - objetivos e parâmetros.....	122
Tabela 6.16 – Opções de planejamento, sistema 476 barras - barras monitoradas.	124
Tabela 6.17 – Opções de planejamento, sistema 476 barras - trechos monitorados.	125
Tabela 6.18 – Opções de planejamento, sistema 476 barras - Objetivos e parâmetros.....	126

LISTA DE ABREVIATURAS E SIGLAS

<i>Advanced Metering Infrastructure</i>	AMI
Agência Nacional de Energia Elétrica	ANEEL
Algoritmo Genético	AG
<i>Automatic Meter Reading</i>	AMR
Busca Exaustiva	BE
Desempenho da Estimativa de Estado	DEE
<i>Extended Optimal Power Flow</i>	E-OPF
<i>Flexible AC Transmission System</i> ”	FACTS
Fluxo de Potência Convencional	FPC
Fluxo de Potência Ótimo	FPO
Função Objetivo	FOB
Geração Distribuída	GD
<i>Global Positioning System</i>	GPS
Instituto de Engenheiros Eletrônicos e Eletricistas	IEEE
<i>Intelligent Electronic Devices</i>	IEDs
<i>Least Absolute Value Method</i>	LAVM
<i>Least Absolute Values</i>	LAV
<i>Maximum Likelihood</i>	ML
Medidores Inteligentes	MI
Método Primal-dual de pontos Interiores	MPI
Modelo de estimação linear	DC
Modelo de estimação não linear	AC
<i>Merging Units</i>	MU
<i>Modified Monkey Search</i>	MMS
<i>Monkey Search</i>	MS
Operador Nacional do Sistema	ONS
<i>Phase Measurements Units</i>	PMU
<i>Phasor Data Concentrator</i>	PDC
<i>Power Line Communication</i>	PLC
PowerNET P-300 G4	P300
PowerNET P-600 G4	P600
PowerNET PQ-600 G4	PQ600

PowerNET PQ-700 G4	PQ700
Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional	PRODIST
Recozimento Simulado	RS
Rede Serviço de Rádio de Pacote Geral	GPRS
Redes Neurais Artificiais	RNA
Sistema Elétrico de Potência	SEP
Sistemas de Distribuição de Energia Elétrica	SDE
<i>Strength Pareto Evolutionary Algorithm</i>	<i>SPEA2</i>
Subestações	SE
Superintendência de Fiscalização dos Serviços de Eletricidade	SFE
<i>Supervisory Control and Data Aquisition</i>	<i>SCADA</i>
Unidades de Medição Fasorial Sincronizadas	UMF
<i>Weighted Least Squares</i>	<i>WLS</i>

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAS

Um Sistema Elétrico de Potência (SEP) tem a função básica de fornecimento de energia elétrica com qualidade a consumidores comerciais, industriais e residenciais. De acordo com [1], um SEP é definido como um conjunto de equipamentos que operam de maneira coordenada de forma a gerar, transmitir e fornecer energia aos consumidores, mantendo o melhor padrão de qualidade possível e atendendo a requisitos como [2]:

- (i). Continuidade no fornecimento;
- (ii). Conformidade com os padrões exigidos;
- (iii). Flexibilidade para se adequar às possíveis mudanças de topologia da rede;
- (iv). Manutenibilidade, com rápida recuperação em caso de faltas.

Em Sistemas de Distribuição de Energia Elétrica (SDE), a fim de garantir uma operação confiável e eficiente, o controle de potência reativa e tensão deve atender a alguns requisitos [3]. Um deles está relacionado com o módulo da tensão, nos diferentes pontos do sistema, que necessita ser mantido dentro de limites independentemente do nível de carregamento dos alimentadores. Um segundo requisito a ser considerado refere-se ao fato de que quando o fluxo de potência reativa é minimizado, através da melhoria dos perfis de tensão nodal, as perdas ativas são reduzidas.

Para prover um serviço com qualidade, um sistema distribuição enfrenta algumas dificuldades, como a diversidade de cargas e suas variações ao longo do dia. Além da natureza da carga, a necessidade de previsão de seu crescimento e de seu atendimento com qualidade de energia, eficiência e controle de tensão para diversos níveis de demanda, a possibilidade de isolamento de trechos para manutenção de equipamentos e o balanceamento de cargas são desafios para um SDE [4].

Diante de tais desafios, para a fiscalização do serviço de eletricidade, a Agência Nacional de Energia Elétrica (ANEEL) regula não apenas a distribuição, mas todos os segmentos de um SEP: geração, transmissão, distribuição e comercialização [5]. Opções para ganho de eficiência, como redução de perdas técnicas através de alternativas combinadas [6], são viáveis para um SDE desde que sujeitas às limitações impostas pela ANEEL através da Resolução Número 505 [7].

O alcance dos requisitos anteriormente mencionados depende de uma questão estratégica importante, principalmente diante da evolução dos SDE: seu monitoramento adequado. O funcionamento dos centros de controle exige a aquisição de informações sobre medidas, estrutura topológica e proteção de instalações do sistema. O desempenho das funções de monitoração e análise de segurança de um sistema depende da disponibilidade de informações que traduzam seu estado e de ferramenta adequada para tanto. Para isto, técnicas como estimação de estados permitem ao operador monitorar as condições de funcionamento de um sistema a partir de dados recolhidos em tempo real, tais como [8]:

- (i). Estimativas de fluxo de potência em trechos e transformadores, potências geradas e cargas, bem como níveis de tensão;
- (ii). Anomalias do sistema bem como a localização geográfica, alertando ao operador para situações de problema;
- (iii). Índices de segurança como, por exemplo, reserva da capacidade de geração, margem de estabilidade, indicando estados vulneráveis;
- (iv). Ações corretivas em resposta a diversas situações e condições indesejáveis ao sistema.

Um estimador de estados deve permitir o tratamento de dados através de metodologias de detecção, identificação e eliminação de erros grosseiros, podendo também ser dotado de ferramentas de análise de observabilidade do sistema e de qualidade da base de dados utilizada. Por este motivo, a estimação de estados tem sido considerada como uma ferramenta básica de apoio ao operador do sistema. O sucesso das ações de controle realizadas com suporte de um estimador de estados está diretamente relacionado com a precisão com que o verdadeiro estado é estimado a cada instante [9].

Em novos ambientes reestruturados, que englobam os vários participantes do mercado de energia elétrica, a estimação de estados tem um papel ainda mais importante. Este novo contexto caracteriza-se pela crescente exigência de garantia da segurança na operação do sistema e tendência cada vez menor de disponibilidade, em tempo útil, de informações relativas ao desempenho operacional das empresas do setor de energia elétrica [10].

Neste cenário, novas tecnologias e técnicas têm surgido para solucionar problemas relativos à estimação de estados de SDE, em que a disponibilidade de dados é menor se comparada ao segmento de transmissão. Este fato pode ser comprovado por diversos tópicos em estudo visando à melhoria de precisão do processo de estimação de estados [10]. Uma

alternativa é a aquisição de informações com maior precisão e taxa de atualização em relação aos tradicionais sistemas de controle e aquisição de dados, ou *Supervisory Control and Data Acquisition (SCADA)*, através de Unidades de Medição Fasorial sincronizadas (UMF) (em inglês *Phase Measurements Units - PMU*) [11]. No entanto, uma análise de viabilidade técnico-econômica deve ser conduzida a fim de dar suporte ao processo decisório sobre investimentos em sistemas de medição diversos. Ainda, ferramentas e modelos consolidados para o segmento de transmissão devem ser avaliados e/ou adaptados para aplicação na distribuição, considerando-se as particularidades deste segmento.

Esta necessidade consiste em tema ainda aberto para investigação, incluindo a concepção de redes elétricas inteligentes e, portanto, serviu como motivação para a presente tese de doutorado.

1.2 REDES DE DISTRIBUIÇÃO INTELIGENTES

Recentemente, o setor elétrico brasileiro foi marcado em consequência de um período de estiagem prolongado que afetou os reservatórios e a produção de energia nas usinas hidrelétricas. Em todo o país, medidas para a conscientização quanto ao uso racional da energia elétrica tem sido propostas e aplicadas, com aumento significativo das tarifas em curto período. No contexto de tais medidas, a implantação de redes inteligentes, em inglês *smart grids*, no Brasil teria como principais motivadores a busca de eficiência comercial e energética, o aumento de confiabilidade do sistema elétrico, a segurança operacional e sistêmica e a sustentabilidade econômica e ambiental [12].

Smart grids são redes inteligentes de transmissão e distribuição de energia com base na comunicação interativa entre todas as partes da cadeia de conversão energética. Estas redes devem conectar unidades descentralizadas de geração de porte variado a consumidores através de uma estrutura ampla, além de controlar a geração e evitar sobrecargas com produção de energia aderente à demanda real [13].

Conforme [14], a expressão *smart grids* deve ser entendida mais como um conceito do que uma tecnologia ou equipamento específico. Baseia-se na utilização intensiva de tecnologias de automação, computação e comunicação para monitoração e controle de rede elétrica, a fim

de permitir a implantação de estratégias de controle e otimização mais eficientes que as atualmente em uso.

O conceito de *smart grids* abre um gama de possibilidades a ser explorada para melhorar as condições de operação de um sistema elétrico. Dentre estas possibilidades, emerge o conceito de *self healing*, que pressupõe os componentes de uma rede elétrica como agentes independentes dotados de inteligência, competindo e cooperando entre si a fim de alcançar os objetivos gerais do sistema [15]. Daí, o papel de um estimador de estados é crucial em sistemas modernos de gerenciamento de energia, devido à diversidade de aplicativos que dependem de dados precisos em tempo real para contemplar a situação operativa de um SEP [16].

1.3 OBJETIVO

O objetivo da presente tese de doutorado é o desenvolvimento de uma nova metodologia de otimização metaheurística multiobjetivo para o planejamento de sistemas de medição para monitoramento de SDE, através da determinação do investimento ótimo em Medidores Inteligentes (MI), em inglês *smart metering*, e/ou em UMF quando viáveis para o sistema, considerando-se seus custos de aquisição. Mais especificamente, este planejamento envolve a decisão sobre tipos de equipamento e pontos estratégicos de uma rede elétrica para sua instalação, visando maximizar a eficiência do processo de estimação de estados, aliando máxima precisão com mínimo custo possível de investimento.

Este objetivo inclui ainda o desenvolvimento de uma nova técnica de estimação de estados adequada para aplicação em SDE com disponibilidade reduzida de medições de boa qualidade em sua rede elétrica. Esta técnica utiliza um novo modelo de otimização baseado em fluxo de potência ótimo (FPO) e solucionada via Método Primal-dual de pontos Interiores (MPI). Portanto, a técnica de estimação de estados desenvolvida é uma das principais contribuições da presente tese.

A metodologia de otimização baseia-se em técnica metaheurística, considerando seu potencial de aplicação a problemas envolvendo decisões que podem ser modeladas através de variáveis discretas, como o investimento em MI ou em UMF em determinado ponto da rede, juntamente com variáveis contínuas, como as que representam o estado do sistema. Trata-se, portanto, de um problema de programação inteira-mista não linear, de difícil resolução via métodos matemáticos exatos.

Outra contribuição desta tese é a incorporação dos conceitos de dominância de Pareto, aplicáveis a problemas de otimização multiobjetivo, à metaheurística utilizada, denominada *Modified Monkey Search (MMS)* e baseada na técnica *Monkey Search (MS)*, de forma inédita. Em outras palavras, a otimização multiobjetivo via metaheurística *MMS* integrada com conceitos de Pareto caracteriza outra inovação da presente proposta. Destaca-se ainda que a abordagem multiobjetivo é importante para disponibilizar às concessionárias de distribuição de energia soluções de boa qualidade e diversas dentro de um universo de alternativas de planejamento, para a seleção assistida daquela que mais se adequa às suas condições e necessidades.

Por fim, a consideração de sistemas modernos de medição, como UMF, para o segmento de distribuição, é motivada pela importância e contemporaneidade do tema à luz dos conceitos de *smart grids* e *self healing* aplicáveis a redes elétricas atuais.

1.4 PUBLICAÇÕES DECORRENTES DO TRABALHO

A presente tese de doutorado está associada a trabalhos divulgados em periódicos especializados, além de um artigo recentemente submetido:

- (i). Duque, F. G., de Oliveira, L. W., de Oliveira, E. J., Marcato, A. L., & Silva Jr, I. C. (2015). Allocation of capacitor banks in distribution systems through a modified monkey search optimization technique. *International Journal of Electrical Power & Energy Systems*, 73, 420-432.
- (ii). Duque, F. G., de Oliveira, L. W., & de Oliveira, E. J. (2016). An approach for optimal allocation of fixed and switched capacitor banks in distribution systems based on the monkey search optimization method. *Journal of Control, Automation and Electrical Systems*, 27(2), 212-227.
- (iii). Duque, F. G., de Oliveira, L. W., de Oliveira, E. J., & Augusto, A. A. (2017). State estimator for electrical distribution systems based on an optimization model. *Electric Power Systems Research*, 152, 122-129.
- (iv). Duque, F. G., de Oliveira, L. W., de Oliveira, E. J. Planning of Measurement Systems in Distribution Networks Through an Optimization Approach, submitted to the *Journal: Electrical Power Components and Systems*, Dec.2016.

1.5 ESTRUTURA DA PROPOSTA DE TRABALHO

Além deste capítulo introdutório, a presente tese é dividida em seis capítulos e dois apêndices. O capítulo 2 traz conceitos e características de equipamentos de monitoramento, além de uma revisão sobre monitoramento de sistemas de energia, envolvendo a aplicação de equipamentos de medição em redes elétricas de transmissão e de distribuição.

O capítulo 3 apresenta conceitos sobre o processo de estimação de estados, apresentando suas etapas, a composição de funções para modelagem deste processo e considerações sobre o impacto de medidas de tensão e corrente para o mesmo.

O capítulo 4 apresenta a metodologia proposta nesta tese para o planejamento multiobjetivo de sistemas de monitoramento em redes de distribuição, através de um novo algoritmo proposto envolvendo a técnica *MMS* aliada aos conceitos Pareto. Adicionalmente, este capítulo apresenta o novo método de estimação de estados proposto na presente tese.

O capítulo 5 apresenta estudos de casos preliminares que objetivam validar o novo modelo de estimação de estados proposto em SDE considerando diferentes cenários, envolvendo variações de erros, medidas e múltiplas topologias de rede.

O capítulo 6 traz os resultados finais obtidos pela aplicação da metodologia proposta nesta tese em sistemas amplamente investigados na literatura, bem como em um sistema de distribuição real brasileiro, incluindo diferentes tipos de equipamentos de medição comerciais.

O capítulo 7 traz as principais conclusões sobre o trabalho desenvolvido nesta tese e algumas propostas para sua continuidade.

Os apêndices A, e B contemplam respectivamente, a metaheurística de otimização *MMS* e o método primal-dual de pontos interiores.

2 MONITORAMENTO E ESTIMAÇÃO DE ESTADOS DE SISTEMAS DE ENERGIA

2.1 CONSIDERAÇÕES INICIAIS

Atualmente, as redes de distribuição de energia elétrica estão passando por uma série de mudanças que aumentam os requisitos por qualidade do serviço oferecido pelas empresas. Assim, um sistema de energia deve manter a qualidade, a segurança e a confiabilidade do fornecimento, requisito associado à sua capacidade de evitar interrupções ou de minimizar os seus efeitos. As agências reguladoras fiscalizam as empresas de transmissão e distribuição, que são sujeitas a multas e punições caso violações de limites e patamares estabelecidos para os requisitos operativos citados ocorram. Para assegurar que estes sejam atendidos, faz-se necessário um monitoramento satisfatório do sistema.

Qualidade de energia elétrica significa que tensão e frequência devem apresentar variações mínimas em relação aos seus valores nominais, além de controle de distorção harmônica. No Brasil, a ANEEL criou procedimentos que não somente calculam o intervalo e a duração de interrupções de fornecimento de energia, mas também índices que monitoram a tensão fornecida aos consumidores [17]. Na transmissão, a fiscalização fica por conta da Superintendência de Fiscalização dos Serviços de Eletricidade (SFE) [18], que atribui responsabilidade à transmissora pela qualidade de energia segundo procedimentos definidos pelo Operador Nacional do Sistema (ONS) [19]. Na distribuição, os Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) [20] determinamos requisitos de qualidade.

O monitoramento eficiente de sistemas de grande porte ainda não está implantado no Brasil, o que justifica o interesse da ANEEL pela definição de padrões para análise e controle de qualidade, tanto para a transmissão quanto para a distribuição. Internacionalmente, o Instituto de Engenheiros Eletrônicos e Eletricistas (IEEE) estabelece padrões de qualidade [21].

Alguns aspectos sobre o monitoramento de sistemas [22], [23] são fundamentais, como tipos de equipamento, decisão sobre a alocação (onde e quando), forma de conexão e aplicabilidade. O ideal seria alocar equipamentos de monitoramento mais robustos e precisos em todos os pontos relevantes do sistema, porém, esta opção é inviável devido ao custo elevado de investimento. Adicionalmente, conforme pesquisas na área, não há a necessidade de

alocação de monitores em toda a rede, pois algumas medidas de tensão e corrente, juntas com o conhecimento da topologia, podem permitir a observabilidade de pontos não diretamente monitorados. Este processo é conhecido como estimação de estados e motiva a investigação pela alocação ótima de equipamentos de monitoramento a fim de garantir a observabilidade do sistema e a eficácia do estimador de estados, aliada à minimização dos custos de investimento associados [24]-[37].

Sobre os equipamentos utilizados para monitoramento de sistemas de transmissão e distribuição, destacam-se os Medidores Inteligentes (MI) e as unidades de medição fasoriais (UMF), que têm sido incluídas entre as opções de investimento para a estimação de estados, visando a uma resposta rápida e eficiente diante de diversas condições operativas [38].

2.2 UNIDADES DE MEDIÇÃO FASORIAL

As UMF são uma realidade e de suma importância futura para o gerenciamento de sistemas de energia, devido à capacidade de amostragem de formas de onda de tensão e de corrente, com sincronização por meio de um sistema de geoprocessamento por satélite. Desta forma, estas unidades permitem definir uma referência comum para que sinais provenientes de locais geograficamente distantes possam ser utilizados em ações de detecção e controle de forma coordenada. O número de amostragens de uma UMF é de 10, 12, 15, 20, 25, 30, 50 ou 60 amostras por segundo [39], o que permite um acompanhamento em tempo real dos sistemas elétricos com confiabilidade nos processos de estimação de estados, controle e proteção, mesmo com as mudanças constantes de comportamento da rede que ocorrem, por exemplo, em um SDE.

A versatilidade da UMF permite o monitoramento de forma eficiente tanto para análises estáticas quanto para análises dinâmicas, passando a ser um fator motivacional visto que os sistemas baseados em tecnologia SCADA baseiam-se em constantes análises de fluxo de potência para obter suas informações, não permitindo assim observar características dinâmicas [40].

2.2.1 Sistema de Medição Fasorial

A composição de um sistema de medição fasorial sincronizado pode ser descrita através dos componentes da Figura 2.1, conforme padronizado pela norma IEEE C37.118.1-2011 [39].

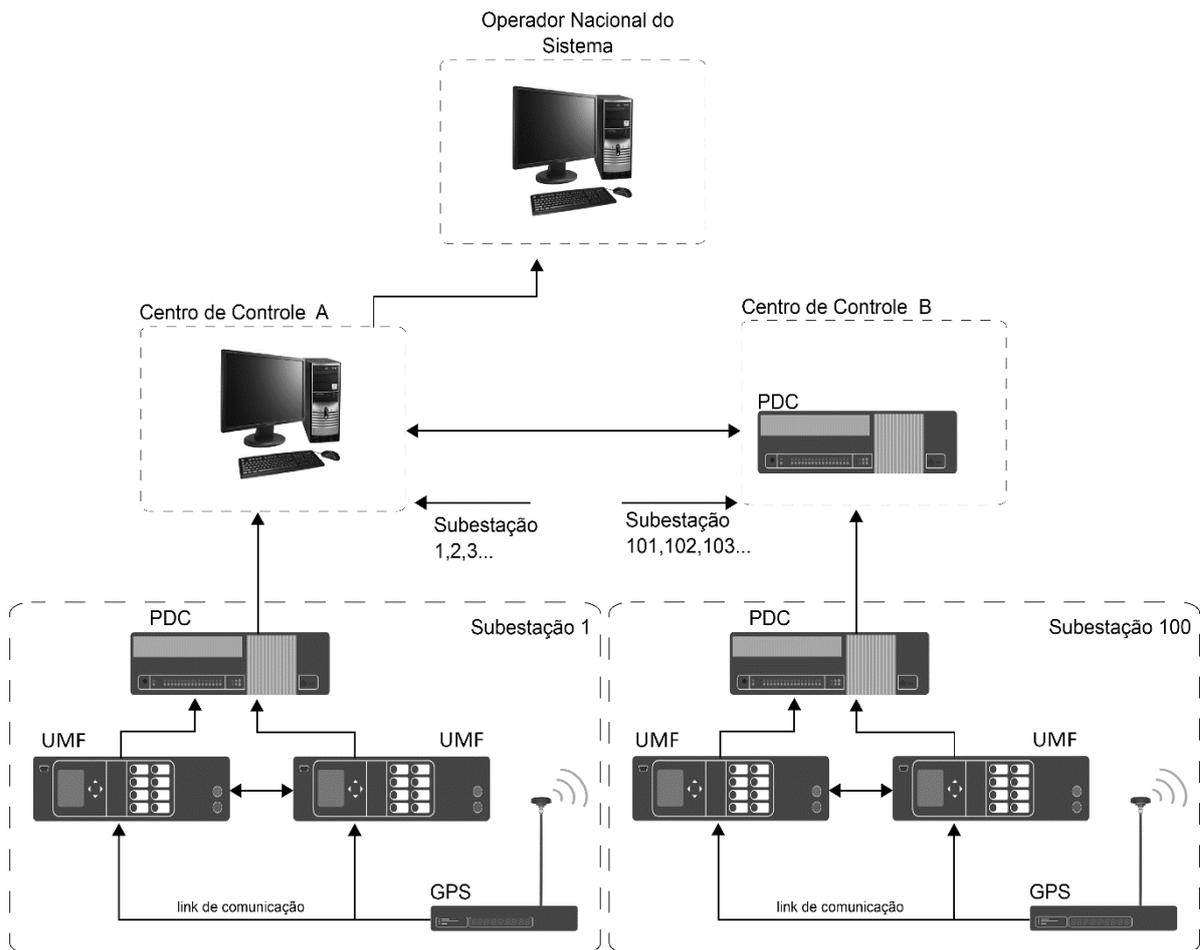


Figura 2.1. Sistema de medição fasorial sincronizado.

Os componentes do sistema da Figura 2.1 são descritos a seguir.

- **UMF**: equipamento de medição de grandezas fasoriais de tensão e de corrente, ou seja, das formas de onda sinusoidais em regime permanente (valor eficaz e ângulo de fase), bem como das potências, ativa e reativa, e da frequência fundamental das grandezas. Os fasores são medidos por amostragem da forma de onda sinusoidal em intervalos de tempo apropriados. A qualidade de um dado amostrado refere-se ao grau de aproximação da onda original e é proporcional à taxa de amostragem do sinal. A estrutura simplificada de uma UMF, apresentada na Figura 2.2, consiste basicamente de um sistema de aquisição de dados formado por transformador e filtros de suavização ou *anti-aliasing*, um módulo que converte sinal analógico em digital, um microprocessador que realiza o tratamento matemático de amostras e uma interface de comunicação [41].

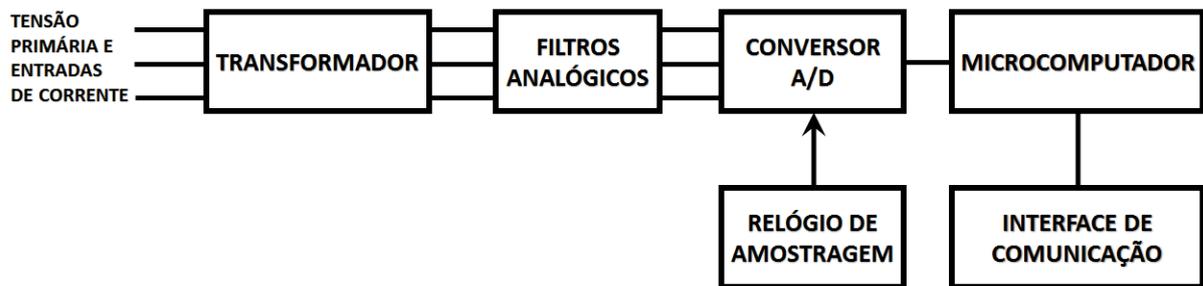


Figura 2.2. Estrutura básica de uma UMF.

- PDC (Phasor Data Concentrator): o concentrador de dados fasoriais tem uma série de funcionalidades, destacando-se: (i) receber, organizar, disponibilizar e distribuir as medidas fasoriais enviadas em tempo real; (ii) armazenamento de dados;
- Centro de Controle: (i) análise de perturbações pós-falta, análise de contingências *off-line*; (ii) monitoramento de segurança, análise de contingências *on-line*; (iii) troca de informações entre PDCs.
- GPS (Global Positioning System): os sistemas de posicionamento global viabilizam a sincronização dos dados obtidos através das UMFs. A frequência dos pulsos emitidos pelo satélite através do sistema GPS confere elevada precisão, sendo o erro atribuído ao pulso de sincronização da ordem de $1\mu\text{s}$.
- Link de comunicação: um canal de comunicação efetua a transferência de dados entre uma UMF e um PDC e a transmissão de informações entre PDCs de diferentes áreas do sistema. A forma de transmissão de dados pode ser por linhas telefônicas, redes elétricas de baixa e média tensão, sistemas modernos baseados em tecnologia sem fio (*wireless*) e cabos de fibra ótica.

2.2.2 Medida Fasorial

As UMFs atuais apresentam configurações distintas, pois são produzidas por vários fabricantes, com variações, por exemplo, no número de canais para a medição de fasores de

tensão e corrente. Dessa forma, algumas UMFs dispõem de vários canais e permitem a medição do fasor de tensão da barra onde estão instaladas, bem como dos fasores de corrente em todos os ramos adjacentes. Porém, outras UMFs dispõem apenas de um par de canais, permitindo a medição da tensão terminal e de uma das correntes dos ramos adjacentes [42].

O procedimento de obtenção de fasores é geralmente por transformada de Fourier [31]. Um fasor consiste em uma representação matemática de uma forma de onda senoidal, que considera a referência angular definida pelo instante de início da amostragem e a frequência constante, como ilustrado na Figura 2.3.

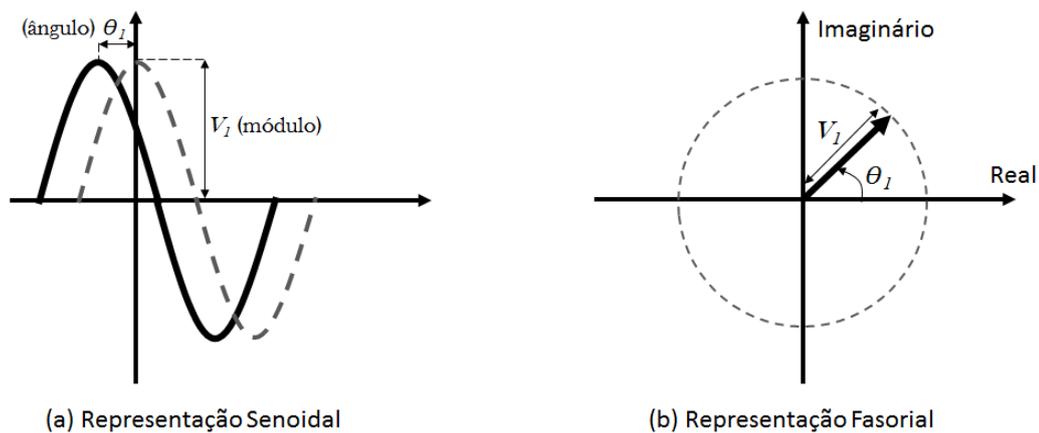


Figura 2.3. Representação fasorial de um sinal senoidal.

No caso de fasor com variação de frequência, como visto na prática, a análise de resultados torna-se complexa devido a diferentes interpretações. Para contornar tal inconveniente, normas definem limites para os erros permissíveis em termos da variação constante da frequência bem como do módulo do sinal medido [39].

Destaca-se que para uma estimação precisa do estado de um sistema elétrico, é importante que as grandezas fasoriais, como de tensão e de corrente, sejam tratadas sob uma mesma referência angular, justificando a necessidade de sincronização dos respectivos sinais e, portanto, a aplicação de UMFs.

2.2.3 Norma IEC 61850

O processo de comunicação permite a troca primária de informações entre a SE e os dispositivos de monitoramento do sistema de distribuição por meio da norma IEC 61850 [43] que permite a centralização dos sistemas de automação. Em particular, as UMFs onde as funções necessárias, permitem amostragem de tensão e corrente, filtragem, sincronização e comunicação, são distribuídas em diferentes pontos do sistema, e estão sujeitas a falhas típicas como erros nos sensores, nos dispositivos eletrônicos inteligentes, nas unidades de fusão ou em inglês *Intelligent Electronic Devices (IEDs)* e *Merging Units (MU)*, respectivamente, falhas de sincronismo e problemas de comunicação.

A infraestrutura de rede nas UMFs é utilizada para transferir os dados de amostragem dentro de uma margem de tempo preciso por meio do protocolo de tempo de precisão via IEEE 1588 [44]. A arquitetura de interconexão, Ethernet, é o gargalo da confiabilidade do sistema e assim, a Ethernet com dados redundantes tem um impacto direto na análise de falhas bem como no tempo de identificação da mesma.

Uma UMF, inspirada na norma IEC 61850, transfere as informações dos sensores de tensão e corrente para os *IEDs*, onde as informações são processadas e elaboradas para estimar os fasores de forma sincronizada [45]. A infraestrutura deve ser de alto desempenho, capaz de satisfazer alguns requisitos como: (i) baixa latência de comunicação; (ii) baixa medida de variação do atraso entre os pacotes sucessivos de dados; (iii) alta largura de banda; (iv) alta disponibilidade e confiabilidade; e (v) tempo de sincronização preciso. A alta disponibilidade e confiabilidade da rede é tipicamente obtida adotando uma topologia de rede fisicamente redundante (por exemplo, estrutura em anel) entretanto, para aplicações mais exigentes, como proteções, que exigem um tempo de recuperação zero, devem adotar soluções paralelas que implicam em um aumento relativamente alto dos custos gerais de instalação [43].

Uma solução econômica para melhorar a disponibilidade de informações das UMFs e assim, aumentar a qualidade na infraestrutura de comunicação, é por meio de um link sem fio IEEE 802.11 recentemente investigado em indústrias de energia [46]. Assim, em cada barra com a UMF alocada a comunicação sem fio que serve como um caminho paralelo para a troca de informações. A Figura 2.4 da referência [43] traz a arquitetura aprimorada do processo de medição em SDE.

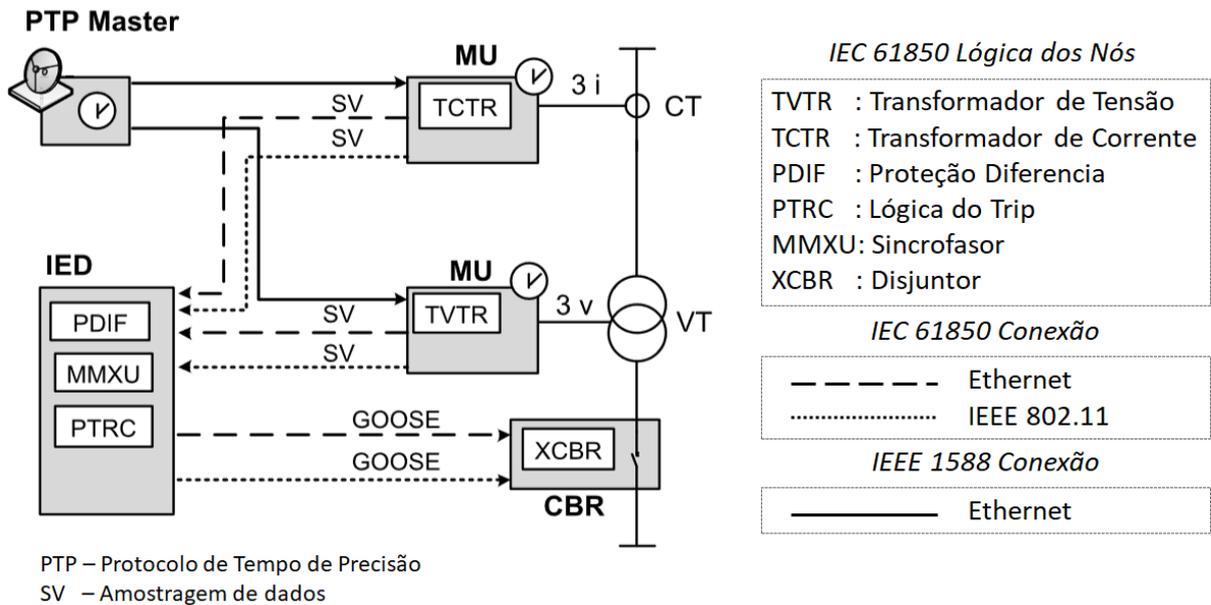


Figura 2.4. Comunicação via norma IEC 61850 em paralelo com link IEEE 802.11.

2.3 MEDIDORES INTELIGENTES

Recentes avanços tecnológicos possibilitaram a integração de novas funções para os medidores de energia tradicionais, utilizados basicamente para medição de consumo e informações adicionais como interrupções de energia em tempo real e flutuações de tensão. A partir das necessidades dos sistemas modernos de distribuição, novas funcionalidades foram acopladas a esses medidores, destacando-se a comunicação de dados e a versatilidade na interação entre vários tipos de equipamentos, funções e operações. Tais medidores passaram a ser classificados como inteligentes ou *smart metering* [47].

Os medidores inteligentes têm como função realizar medições de carga ativa e reativa, bem como, de tensão em intervalos de tempo pré-definidos, e os dados referentes a estas medidas são transmitidos a um servidor central. Embora os medidores possam amostrar em taxas acima de 1 MHz, a maioria das implementações na distribuição de energia dá-se pela amostragem em um período de 15 minutos, ou ainda em intervalos mais longos para assegurar a confiabilidade na transmissão de dados. O aumento da taxa de amostragem devido a uma

maior necessidade de informações coletadas está associado a um aumento no custo de armazenamento [47].

As vantagens da substituição de medidores eletrônicos por inteligentes deparam-se com o excesso de informações armazenadas, processadas e transmitidas. Daí, sistemas de compressão de dados são importantes para a redução da utilização do canal de comunicação e dos requisitos de armazenamento, que são limitados em equipamentos de medição.

2.3.1 Evolução dos Sistemas de Monitoramento

A leitura automática de medidor, em inglês *Automatic Meter Reading (AMR)*, foi precursora dos medidores inteligentes atuais, pois contribuiu principalmente para a redução de custos das distribuidoras, dispensando o uso de mão-de-obra para a leitura de consumo de energia e reduzindo perdas não-técnicas [48]. A evolução dos medidores de energia elétrica beneficia consumidores, que podem analisar o horário de maior consumo em suas residências, e concessionárias, que passam a dispor de dados reais de consumo ao longo do dia, viabilizando o monitoramento dos limites de distorção harmônica, inclusive.

A infraestrutura avançada de medição, ou *Advanced Metering Infrastructure (AMI)*, proporciona benefícios diretos para os processos de atendimento a clientes, tanto em áreas comerciais como em áreas técnicas. Em virtude do avanço tecnológico, o processo de automação da rede traz como benefícios confiabilidade, qualidade e segurança, além de garantir maior eficácia no monitoramento e localização de falhas e no restabelecimento de energia [49].

O foco da rede inteligente está na distribuição, que será constituída por uma grande variedade de sensores, monitores e medidores inteligentes distribuídos para permitir observabilidade em tempo real e oferecer variada gama de benefícios e serviços, como: faturamento em tempo real, eficiência energética, reconfiguração, registro instantâneo de falhas, informação de consumo aos usuários, compreensão e conscientização sobre o consumo. A Figura 2.5 retrata a evolução do processo de integração dos sistemas e equipamentos inteligentes na concepção e operação de sistemas de distribuição [49].

Leitura Manual de Medidores	Leitura Automática de Medidor (AMR)	Infraestrutura Avançada de Medição (AMI)	Medidores Inteligentes (MI)
<ul style="list-style-type: none"> ➤ Leitura mensal kWh 	<ul style="list-style-type: none"> ➤ Uni ou bidirecional ➤ Leitura mensal kWh ➤ Dados por intervalo ➤ Detecção básica de furto ➤ Detecção de Interrupção/restabelecimento 	<ul style="list-style-type: none"> ➤ Leitura sob demanda ➤ Intervalos programáveis de carga ➤ Leitura bidirecional da rede ➤ Tarifas diferenciadas ➤ Controle pelo lado da demanda 	<ul style="list-style-type: none"> ➤ Plataforma eletrônica ➤ Comunicação integrada ➤ Corte/Religa remoto ➤ Qualidade de energia (Leitura de Tensão, Corrente, Frequência, Fator de Potência, Detalhes de Interrupção de energia) ➤ Programável remotamente ➤ Porta interna de expansão ➤ Funcionalidade futuras

Figura 2.5. Evolução do sistema de monitoramento.

Devido aos medidores inteligentes serem diretamente conectados com centrais de distribuição de energia, mesmo que haja perda de comunicação com consumidores, estes equipamentos conseguem identificar os prováveis pontos de falha e informar à central para o devido reparo. Além disso, paralelo a essa operação, tem-se o comportamento dinâmico do sistema, que pode realizar possíveis manobras automaticamente de forma a reduzir o número de consumidores desprovidos de energia, ou seja, reduzir a área desenergizada, gerando benefícios para consumidor e concessionária diante dos índices de confiabilidade requeridos.

2.3.2 Tipos de Plataforma de Comunicação

Além do processo de medição inteligente, outros dois são de suma importância: (i) comunicação; (ii) gerenciamento de dados. Enquanto que o sistema de medição tem a capacidade de monitorar os níveis de tensão ou de reportar uma interrupção, o sistema de comunicação tem a finalidade de enviar as informações necessárias para o software de gerenciamento de dados, que processa tais informações para, por exemplo, localizar uma falta. Grande parte das funções dos medidores inteligentes é baseada em comunicação com a central da empresa distribuidora, que dispõe de várias tecnologias e topologias. Alguns pontos são importantes e necessários para a escolha da melhor plataforma de comunicação, devendo-se considerar: qualidade da transmissão, custo, capacidade do sistema para suportar um número elevado de conexões simultâneas, quantidade de erros na transmissão, entre outros pontos. Algumas plataformas de comunicação são listadas a seguir:

- *Power Line Communication* (PLC);
- Rede Serviço de Rádio de Pacote Geral (GPRS);
- Comunicação via Ondas de Rádio;
- Transmissão Ponto-a-Ponto;
- *Zig Bee*;
- Transmissão Concentrada.

2.4 ESTUDOS ENVOLVENDO UMF E MI NA TRANSMISSÃO

A alocação de equipamentos de monitoramento para a observabilidade de um sistema de energia tem sido amplamente proposta para redes de transmissão [50]-[64] e comprovada como uma opção promissora para melhorar o desempenho do sistema. Alguns requisitos são considerados na análise para a alocação destes equipamentos [50]: (i) confiabilidade; (ii) estimação de estados; (iii) minimização do número de equipamentos necessários. Basicamente, no processo de estimação de estados, o vetor de variáveis de estado do sistema deve ser calculado com a maior precisão possível, o que significa um valor mínimo para o erro da medição.

A maioria dos estudos tradicionais sobre alocação de equipamentos de medição concentra-se na determinação da localização dos equipamentos. Em [51], teoria de grafos é utilizada para suporte à alocação do número mínimo de UMFs e observabilidade do sistema. Esse processo é otimizado ao se considerar como candidatas as barras com maior número de conexões. Teoria de grafos também é utilizada para a alocação de UMFs visando à otimização do processo de estimação de estados, juntamente com um algoritmo heurístico denominado *greedy algorithm* [52]. Com o mesmo propósito, programação inteira é aplicada em [53] e técnicas heurísticas tais como recozimento simulado, busca tabu e algoritmo genético em [54].

Estudos recentes avaliam a alocação de equipamentos de monitoramento considerando-se mais de um objetivo e diferentes restrições [55]-[64]. Do ponto de vista da confiabilidade, o problema de alocação deve levar em conta a probabilidade de falha do medidor, canais de comunicação e falha de uma ou mais linhas de transmissão. De acordo com [55], determinar a localização de equipamentos de medição sem considerar questões de confiabilidade não é suficiente para garantir a observabilidade em condições reais de operação.

Em [56], determina-se alocação do número mínimo de UMFs considerando a indisponibilidade de canais de comunicação, bem como interrupções de energia em determinados ramos. Em [57], é proposto um modelo multiobjetivo que, além de incluir os custos de UMFs na função objetivo, inclui penalidades para as barras não observáveis e restrições que garantem um custo total de projeto inferior ao respectivo orçamento.

Teoria de grafos é usada em [58] para um modelo que considera número de canais disponíveis e interrupções de ramos. Em [59], programação inteira binária é utilizada considerando-se a existência de medidas em uma UMF e de falhas em uma linha de transmissão. Através de abordagem similar, em [60], determina-se a alocação de UMFs contemplando o tratamento de vários requisitos, tais como a observabilidade completa e a otimização do processo de estimação de estados. Para tanto, três casos de contingência são considerados: interrupção de uma linha, falha de uma UMF e limitação de canais.

A referência [61] propõe uma classificação para as barras de uma rede elétrica em dois grupos, sendo um para barras com baixa redundância e outro para barras com baixa precisão quanto aos valores estimados. Daí, a alocação ótima de UMFs é determinada com base nesta classificação.

Métodos baseados em inteligência artificial e metaheurísticas têm sido sugeridos para a resolução do problema multiobjetivo associado à alocação de UMFs. A técnica de otimização por enxame de partículas foi utilizada em [62] visando alocar UMFs para obter precisão no processo de estimação de estados. Uma matriz de covariância é usada para avaliar a diferença entre os valores reais e estimados. Em [63] e [64], o algoritmo de Gauss-Newton é aplicado para o processo de estimação de estados.

2.5 ESTUDOS ENVOLVENDO UMF E MI NA DISTRIBUIÇÃO

As redes de distribuição de energia elétrica estão passando por mudanças fundamentais principalmente pela estruturação mais dinâmica e complexa do sistema. Alguns aspectos deste processo podem ser destacados [65], [66]:

- (i). Integração de fontes de Geração Distribuída (GD);
- (ii). Novos equipamentos como os *IEDs*, *MI*s e *UMF*s;
- (iii). Entidades com comportamento duplo de carga-geração;
- (iv). Mudanças na topologia de radial para malhada;
- (v). Utilização de fontes renováveis.

Um sistema de distribuição deve ter objetivo próprio para o investimento em MIs ou UMFs e as restrições são diferentes das estabelecidas para a transmissão, devido a características como o desequilíbrio de cargas entre fases, a tendência de inserção crescente de GD e a configuração radial das redes de distribuição [67].

Portanto, dado aos requisitos específicos, diferentes estratégias devem ser consideradas para a alocação de UMF se MIs em um sistema de distribuição, pois os métodos tradicionalmente implementados na transmissão podem ser ineficientes quando aplicados à distribuição.

Este cenário cria novos desafios para a operação das redes de distribuição e o monitoramento avançado, controle e proteção devem se basear nas condições do sistema. Como a implantação completa de instrumentação é economicamente inviável, processos de estimação de estados são fundamentais para o controle da operação. Tais processos têm sido amplamente estudados no que diz respeito a problemas de precisão da estimação e à alocação de MIs [24]-[28].

Nestes estudos, medidas tradicionais, como de potência ativa e reativa e de tensão de subestações, além de pseudo-medidas com baixa precisão baseadas em dados históricos [32], são utilizadas para a estimação de estados a fim de compensar a fraca disponibilidade de medições diretas. Porém, como consequência da utilização de pseudo-medidas, a incerteza que se propaga para a estimação do estado de uma rede pode ser elevada e até inaceitável.

Devido à dinâmica e à mudança de comportamento das redes de distribuição, monitoração em tempo real está se tornando cada vez mais importante, o que requer uma infraestrutura de medição ainda não implementada [68]. Entre as medidas necessárias para o acompanhamento e o controle de uma rede de distribuição, as medidas fasoriais fornecidas por UMFs, de tensão e de correntes sincronizadas em tempo real, são de grande interesse. A aplicação de UMF em redes de distribuição é investigada em [33]-[36]. Em [36], avalia-se a utilização de UMFs em barras próximas a fontes de geração distribuída.

Recentemente, um crescente número de dispositivos de medição inteligente que proporcionam alta precisão e funcionalidade associada a uma comunicação avançada está disponível para a aplicação em redes de média e baixa tensão, tais como equipamentos de medição multifuncional e em especial os sistemas de medição inteligente [69]-[71]. A alocação ótima destes equipamentos em SDE visa a um monitoramento eficiente e ao aumento de

precisão do processo de estimação de estados em relação a pseudo-medidas [24]-[26] com minimização de custos [32] e [37]. Esta alocação pode constituir-se, portanto, em opção atrativa sob o ponto de vista da relação custo-benefício. Estimação de estados a partir de dados fornecidos por MI como, por exemplo, tensão e carga em transformadores de distribuição, é investigada em [72] e [73]. O desempenho da aplicação de MIs para a estimação de estados e a melhoria da observabilidade de um sistema são avaliados em [74]-[76].

As referências [77]-[79] abordam o tema de alocação de medidores para a estimação de estados considerando-se dispositivos heterogêneos como medições em subestações, pseudo-medidas, MIs e UMFs. Em [80], faz-se uma comparação entre um sistema de transmissão em malha e um sistema de distribuição radial no que concerne à estimação de estados, considerando-se estimativas nas três fases. Para tanto, utiliza-se o algoritmo heurístico *greedy algorithm* e programação inteira.

2.6 ETAPAS DO PROCESSO DE ESTIMAÇÃO DE ESTADOS

O processo de estimação de estados [81]-[83] tem como objetivo obter informações da forma mais precisa possível sobre o estado de um sistema de energia, a partir de medições sujeitas a erros ou ruídos. As informações obtidas a partir das variáveis de estados estimadas constituem uma base de dados para execução de funções associadas à operação e à segurança de um sistema. O estimador deve atuar em tempo real, através do processamento de dados de medidas analógicas (tensões, fluxos e injeções de potência), provenientes de um sistema SCADA, juntamente com parâmetros da rede, como sua topologia.

Outra característica do estimador de estados é que este pode ser estático ou dinâmico. Um estimador estático tem aplicação potencial na etapa de planejamento de sistemas de transmissão ou distribuição, enquanto que um estimador dinâmico tem aplicação na operação e considera as relações entre grandezas em diferentes instantes de tempo.

As etapas do processo de estimação de estados podem ser observadas no diagrama da Figura 2.6. Basicamente, o estimador requer a análise de observabilidade do sistema, que é possível com base na topologia de rede dada pelo configurador em função de dados em tempo real. Daí, as variáveis de estado são estimadas em um processo que envolve o tratamento de erros grosseiros a fim de aumentar a qualidade da estimação [84].

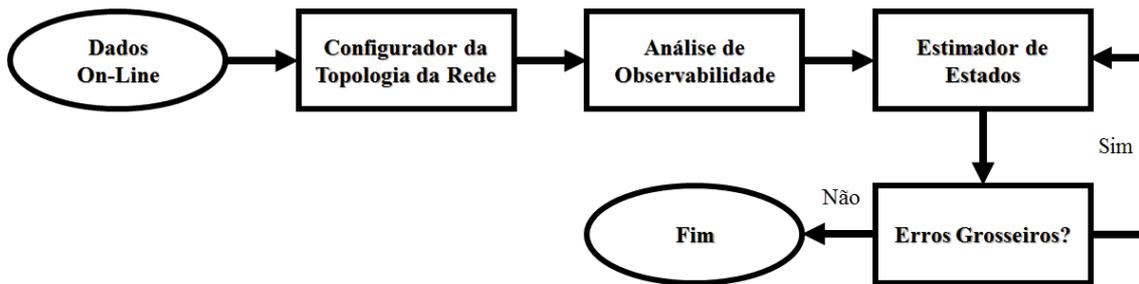


Figura 2.6. Etapas básicas do processo de estimação de estados.

No configurador, a topologia da rede de distribuição é convertida do modelo de seção barramento-dispositivos, Figura 2.7(a), que representa o sistema no nível dos estados das chaves e disjuntores, para o modelo simplificado barra-linha da Figura 2.7(b).

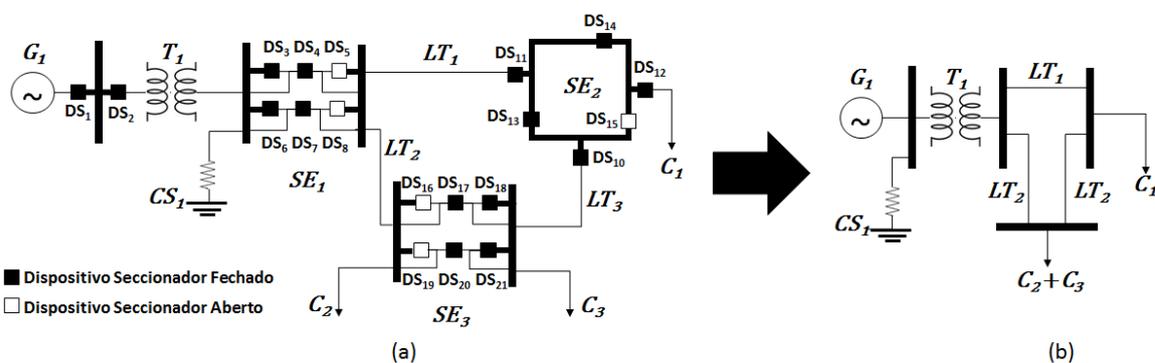


Figura 2.7. Modelo seção barramento-dispositivos seccionadores e modelo barra-linha (G_n – gerador, T_n – Transformador, LT_n – Linha de Transmissão, SE_n – Subestação, CS_n – Condensador Síncrono, C_n – Carga, DS_n – Dispositivo Seccionador)

Obtida a topologia pelo modelo barra-linha da Figura 2.7(b), o próximo passo consiste na análise de observabilidade, que consiste na observação de todas as variáveis de estado por meio das medidas analógicas disponíveis. Se isto for possível, o sistema pode ser dito observável. Caso contrário, a falta de medidas pode ser suprida por pseudo-medidas (como dados de previsão de carga e de geração e dados históricos provenientes dos centros de operação) a fim de tornar o sistema observável em sua totalidade. A partir das medidas analógicas e das pseudo-medidas, realiza-se a estimação de estados, cujo sucesso depende dos dois aspectos a seguir.

- (i). Redundância: Definida como a razão entre a quantidade de medições disponibilizadas e o número de variáveis a serem estimadas. Depende da quantidade, tipo e localização de medidores, sendo importante não apenas para garantir a observabilidade do sistema, mas também para possibilitar o tratamento de medidas portadoras de erros grosseiros. A redundância deve variar entre os valores típicos de 1,7 a 2,2, porém, os custos associados aos equipamentos de medição limitam o seu valor, afetando diretamente a qualidade da estimação. O sistema é dito minimamente observável se a redundância for igual a “1” e for observável [85].

- (ii). Qualidade: Depende da precisão dos equipamentos envolvidos na medição e da disponibilização das medidas no centro de operação. Vale ressaltar que pseudo-medidas são valores a princípio imprecisos, o que torna a qualidade do estimador de estados baixa [85].

Por fim, o tratamento de erros é de suma importância no processo de estimação de estados, pois consiste em detectar e identificar medidas com grau de imprecisão elevado a fim de evitar que prejudiquem a qualidade dos valores estimados. Dentre as possíveis causas de erros, podem-se destacar:

- Má calibração de aparelhos;
- Erros em equipamentos de medida e de transmissão;
- Falta de leituras;
- Falta de sincronismo de medidas obtidas pelo sistema *SCADA*;
- Modelos matemáticos imprecisos;
- Medidas efetuadas durante fenômenos transitórios.

Existem algumas ferramentas baseadas em métodos matemáticos para o processo de estimação de estados, destacando-se:

- (i). Método dos mínimos quadrados ponderados, ou *Weighted Least Squares (WLS)* [81];
- (ii). Método do mínimo valor absoluto, ou *Least Absolute Value Method (LAVM)* [82];
- (iii). Estimador de Máximo de Verossimilhança ou *Maximum Likelihood (ML)* [83];
- (iv). Método de processamento de dados afetados por erros [74].

No presente trabalho, utiliza-se uma nova abordagem, apresentada no Capítulo 3 e, para efeitos de comparação, utiliza-se o *WLS*, discutido no Apêndice A, com o processo iterativo de Newton-Raphson [74], [86].

2.6.1 Método do mínimo valor absoluto

O método *LAVM* proposto por [82] foi utilizado na resolução do problema da estimação de estados. A função objetivo de minimização deste método, consiste no somatório da diferença entre os valores absolutos das grandezas estimadas com as grandezas medidas com restrições de equações de medidas. Para tal pressuposto, técnicas de programação linear foram utilizadas para formular e resolver o processo de estimação de estados como um problema de programação linear. Através da introdução de restrições de igualdade e desigualdade no resíduo de medida

[87] propuseram, para resolver o problema *LAVM* por meio do método Simplex de programação linear, a adequação das restrições de igualdade e desigualdade no resíduo de medida melhorando o desempenho bem com a eficiência computacional do algoritmo proposto. Já em [88] foi aplicado o método dos pontos interiores (MPI) para a resolução do problema de programação linear ao problema da estimação de estados *LAVM* no qual demonstrou ser mais eficiente em termos de convergência e tempo computacional em comparação com o abordado em [87] por meio do Simplex.

2.6.2 Estimador de Máximo de Verossimilhança

Estimadores de Máximo Verossimilhança ou M-Estimadores tem como objetivo a minimização da função objetivo que é expressa a partir da diferença entre os valores estimados e medidos com restrições impostas à equação pelas medidas. Sendo assim, [83] introduziram funções objetivo baseadas em três pontos: (i) na constante quadrática; (ii) na constante linear quadrática; e (iii) e na raiz quadrada. Dentro do processo iterativo da solução do problema de estimação de estados, esse método tem como característica, suprimir os dados afetados. A saída de possui os módulos e ângulos de fase das tensões nas barras do sistema e os valores estimados das medidas e assim, através desses valores a informação adicional acerca do sistema pode ser calculada.

2.6.3 Método de processamento de dados afetados por erros

As fontes de erros nas medidas fornecidas para a resolução do processo de estimação de estados consistem nas interferências nos sistemas de comunicação, nos dispositivos que executam leituras incorretas, na não simultaneidade das medidas entre outros pontos. Daí, o processamento de dados afetados de erros [74], consiste é uma ferramenta capaz de avaliar e solucionar tais problemas no problema de estimação de estados. No método *WLS* o processamento de erros de medidas é realizado na etapa de pós-processamento no qual o teste do chi-quadrado, ou seja, a soma ponderada dos quadrados dos resíduos bem como uma probabilidade de erro limiar, que é utilizado após a estimação para detectar e eliminar erros nas medidas. O teste do maior resíduo normalizado [89], calculado por meio da divisão o valor absoluto do resíduo pelo elemento corresponde da diagonal da matriz de covariância (R). O maior entre os resíduos normalizados é escolhido e assim, é comparado com valor limiar de detecção. A medida ruim é então removida caso o correspondente resíduo normalizado ultrapassar o limiar de identificação. Verificado tal procedimento, o algoritmo *WLS* para estimação de estados é novamente executada com vista a obter um melhor desempenho.

2.7 ALTERNATIVAS PARA APERFEIÇOAMENTO DO PROCESSO DE ESTIMAÇÃO DE ESTADOS

2.7.1 Filtro de Kalman

A função de medição e o modelo de sistemas não lineares são aproximados para o modelo linear no processo de estimação de estados por meio do processo iterativo. Entretanto, em função das constantes mudanças de carga e/ou geração, as não linearidades tendem a se tornar excessivas comprometendo o desempenho do estimador de estados [90]. De forma a contornar tal problema, [91] propuseram a incorporação das não linearidades através do filtro de Kalman em que as iterações locais são realizadas durante o cálculo dos resíduos de medição fornecendo uma melhorar estimativa na presença de não linearidades, ou manter a expansão da série de Taylor na forma retangular até a segunda ordem, o que ajuda na retenção total das não linearidades. Em [92] e [93] é proposto a transformação não linear das medições tornando o processo de estimação de estados linear. A vantagem dessa técnica é que o vetor de estados é

representado por uma matriz constante e não por uma matriz Jacobina. Esta matriz constante é muito esparsa, e assim, os erros devidos à linearização são removidos.

O método de filtro de Kalman tem a desvantagem de não poder manipular grandes mudanças na carga e geração. Para contornar tal problema [94] e [95] propuseram um algoritmo onde o vetor de pesos de medição (W) é substituído pelo termo $We^{-|z-h(\bar{x})|}$ onde z é o vetor de medições, x as variáveis de estados estimadas e $h(x)$ as equações do modelo de rede que relacionam as medidas com as variáveis estimadas. Assim, sempre que houver uma grande diferença nos valores estimados e reais, devido a mudanças repentinas de carga e/ou geração, o peso associado a essa medida será automaticamente reduzido, pois o termo ' $|z-h(x)|$ ' aparece como um termo exponencial negativo. Em condições normais o resíduo ' $z-h(x)$ ' será um valor pequeno, tornando a função de peso muito próxima do valor W original.

2.7.2 M-Estimador

A estimação pelo filtro de Kalman consiste na distribuição gaussiana do ruído das medições porém, a distribuição do ruído, frequentemente desvia-se do modelo, resultando em dados que se diferenciam drasticamente de todos os outros analisados, ou seja, dados inconsistentes, o que degrada significativamente o filtro de Kalman. Para contornar tal problema, [96] e [97] propuseram uma técnica denominada M-Estimador contendo três etapas:

- (i). Modelagem do sistema e medição: baseada na suposição de que a tensão do barramento em um determinado ponto não depende apenas do nível de tensão do estado anterior, mas também da mais recente mudança de tensão disponível nos barramentos aos quais ela está conectada.
- (ii). Filtragem: A técnica M-Estimador reduz o nível de incerteza sob más condições de dados, usando uma técnica de filtragem que é mais eficaz na presença de dados inconsistentes e também de fácil implementação em comparação com as técnicas convencionais baseadas no filtro de Kalman.

2.7.3 Filtro de Raiz Quadrada

A técnica Filtro de Raiz Quadrada proposto em [98] é algebricamente equivalente à técnica de filtro de Kalman, mas é numericamente mais estável que o filtro de Kalman. O filtro consiste na substituição dos vetores de covariância (R) que contemplam a matriz de pesos W

por seus vetores de raiz quadrada correspondentes. O motivo é que o condicionamento numérico das matrizes de raízes quadradas é muito melhor do que a matriz de covariância correspondente. A técnica de Filtro de Raiz Quadrada reduz o nível de incerteza nas medições, economiza tempo computacional e uso memória em comparação com a técnica tradicional de filtro Kalman.

2.7.4 Inteligência Artificial

As Redes Neurais Artificiais (RNA) é uma ferramenta bastante promissora no processo de estimação de estados, visto que tal problema consistem no processo de otimização das variáveis de estado da rede. [99] propuseram uma técnica em RNA associada ao modelo de previsão “*Short Term Load*”, ou seja, método de previsão dinâmica de carga que baseia-se na suposição que o barramento é carregado, as gerações são as que impulsionam a dinâmica do sistema e as cargas seguem um padrão e, portanto, podem ser previstas. Neste método, uma RNA é usada para prever as cargas ativas e reativas em todos as barras do sistema. As gerações não podem ser previstas, pois dependem diretamente das cargas e são ajustadas pela variação das cargas. Assim, as gerações das barras são calculadas adaptando as variações de carga a gerações usando fatores de precipitação de geração. Definida as injeções de potência nas barras, esta são transformadas em tensões de barra complexas através da solução de fluxo de carga, pois são mais adequadas para a etapa de filtragem. Esses vetores de estado previstos são, por sua vez, usados no estágio de filtragem para obter uma melhor previsão das variáveis de estado e melhores estimativas dos vetores de estado com mesmo tempo computacional que os métodos convencionais.

2.8 CONSIDERAÇÕES FINAIS

Este capítulo apresentou características de equipamentos de monitoramento de redes de energia elétrica, envolvendo medidores inteligentes e unidades de medição fasorial. Na sequência, foi realizada uma revisão sobre a aplicação de unidades de medição fasorial e de medidores inteligentes em sistemas de transmissão e distribuição, destacando-se as características e desafios concernentes ao segmento de distribuição, cujo tema está inserido na presente proposta de tese de doutorado. Por fim, foi apresentado as etapas do processo de estimação de estados bem como métodos matemáticos e alternativas para resolução e aperfeiçoamento para resolução do processo de estimação de estados.

3 ESTIMAÇÃO DE ESTADOS, CARACTERÍSTICAS E MÉTODOS MATEMÁTICOS PARA RESOLUÇÃO

3.1 CONSIDERAÇÕES INICIAIS

São descritas neste capítulo as principais características de processos de estimação de estados utilizando modelos de fluxo de potência linearizados (DC) e não lineares (AC). Primeiramente, o conceito de variável de estado é introduzido. Em seguida, são apresentados modelos de estimação. Por fim, apresenta-se as principais características da matriz Jacobiana associada às equações do método de estimação de estados *WLS*, baseado em um modelo de rede não linear, bem como o modelo para a representação de equipamentos de medição.

3.2 COMPOSIÇÃO DO ESTIMADOR DE ESTADOS DC

O problema de estimação de estados DC [86] é comumente formulado através de um sistema de equações lineares, que pode ser resolvido pelo método dos mínimos quadrados ponderados ou *WLS*. O modelo de estimação de estados relaciona medidas disponíveis com variáveis de estado conforme equação (3.1).

$$x^* = H\hat{x} + e \quad (3.1)$$

Em que:

- x^* Vetor de medidas, que podem ser de ângulo de fase de tensão nodal, potências ativas injetadas nos barramentos e/ou fluxos de potência ativa em trechos;
- H Conjunto de funções lineares que relacionam medições com as variáveis de estado;
- \hat{x} Vetor de das variáveis de estado; e
- e Vetor de erros aleatórios.

O vetor de resíduos de medição é dado pela diferença entre os valores medidos e as correspondentes estimativas. O problema dos mínimos quadrados ponderados para a equação (3.1) visa determinar o vetor de estados estimados que minimiza o índice J da equação (3.2).

$$J = (x^* - H\hat{x})^T W (x^* - H\hat{x}) \quad (3.2)$$

A matriz W é uma matriz diagonal cujos elementos são os pesos de medição. Dependendo da aplicação, estes pesos podem representar, por exemplo, precisão do medidor, sua confiabilidade ou importância. Mais comumente, W é calculado com base em variância de erro de medição, conforme equação (3.3).

$$W = R_z^{-1} = \begin{pmatrix} \sigma_1^{-2} & & & \\ & \sigma_2^{-2} & & \\ & & \ddots & \\ & & & \sigma_m^{-2} \end{pmatrix} \quad (3.3)$$

Em que:

R_z^{-1} Matriz de covariância de medição com dimensão $m \times m$; e

m Número de medidas.

O procedimento para obter o estado estimado (\hat{x}) do sistema consiste em resolver a equação (3.4) de forma que o desempenho do processo de estimação de estados seja avaliado pelo índice da equação (3.2).

$$\hat{x} = G^{-1} H^T W x^* \quad (3.4)$$

Em que a matriz G é definida como matriz de ganho, calculada pela equação (3.5).

$$G = H^T W H \quad (3.5)$$

Em que:

H Matriz Jacobiana com dimensão $m \times n$, sendo n o Número de variáveis de estado.

3.3 VARIÁVEIS DE ESTADO

Para exemplificar, considera-se como exemplo uma rede de distribuição que apresenta “ nv ” variáveis. Conforme citado anteriormente, aplicando o modelo de fluxo de potência DC,

essas variáveis geralmente envolvem os ângulos de fase de tensão nodais, fluxos de potência ativa em trechos e injeções nodais de potência ativa. Essas variáveis estão ligadas entre si por um conjunto de “ ne ” equações de rede, que expressam o balanço de potência em cada barra da rede e a relação entre ângulos de fase e fluxos de potência. Uma vez que o fluxo de energia DC é linear, o modelo de rede é um conjunto de equações lineares independentes. Normalmente, trata-se de um conjunto de equações indeterminado dado pela diferença entre “ nv ” e “ ne ”. O conjunto de variáveis do problema pode ser dividido em dois subgrupos: um conjunto de $(nv - ne)$ variáveis de estado e um conjunto de variáveis dependentes. O conjunto de variáveis de estado tem duas características principais [86]:

- (i). Descreve o sistema completamente, no sentido de que, se os estados são conhecidos, todas as variáveis restantes podem ser determinadas utilizando as equações do modelo de rede;
- (ii). O conjunto de estados é mínimo, no sentido de que se qualquer uma das variáveis de estado é removido do conjunto, a propriedade (i) não é aplicada.

Para exemplificar e ilustrar essas propriedades, considera-se o sistema com 3 barras mostrado na Figura 3.1.

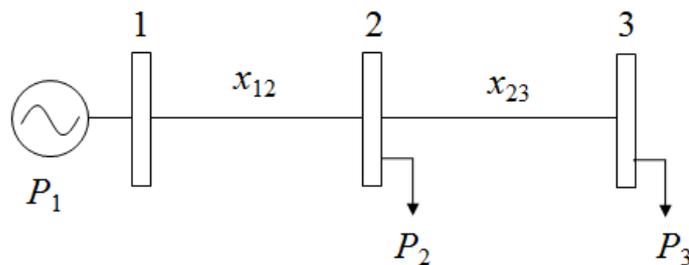


Figura 3.1. Sistema de 3 barras.

O modelo de rede requer a definição das variáveis deste sistema, as equações de balanço de potência ativa das barras 1,2 e 3 e, por fim, a definição das variáveis de estado. Sendo assim, tem-se:

- Variáveis do sistema: Para este sistema, o modelo de fluxo de potência DC tem as seguintes variáveis: $P_1, P_2, P_3, p_{12}, p_{23}, \theta_1, \theta_2$ e θ_3 , em que P_k representa injeção líquida

de potência na barra k , p_{km} representa fluxo de potência no trecho km e θ_k representa ângulo de fase da barra k ;

- É necessário estabelecer um ângulo de referência como, por exemplo, $\theta_1 = 0^\circ$. Logo tem-se $nv = 7$ (as oito variáveis anteriores subtraídas do ângulo de referência);
- Modelo da rede: Representado pelas equações (3.6)

$$P_1 = p_{12} \quad (3.6.a)$$

$$P_2 = p_{23} - p_{12} \quad (3.6.b)$$

$$P_3 = -p_{23} \quad (3.6.c)$$

$$p_{12} = -x_{12}^{-1}\theta_2 \quad (3.6.d)$$

$$p_{23} = x_{23}^{-1}(\theta_2 - \theta_3) \quad (3.6.e)$$

Em que b_{km} representa a susceptância do trecho km , dada por $b_{km} = -x_{km}^{-1}$ e x_{km} é a reatância do trecho km . Verifica-se, portanto, que o modelo de rede para o sistema exemplo em questão tem $ne = 6$ equações;

- Variáveis de Estado: Uma vez que existem oito variáveis do problema e seis equações de rede independentes, duas variáveis ($nv - ne = 7 - 5 = 2$) podem ser selecionadas como variáveis de estado como, por exemplo, $\hat{\theta}_2$ e $\hat{\theta}_3$.

Assim, sendo escolhidos $\hat{\theta}_2$ e $\hat{\theta}_3$ como as variáveis de estado, e aplicando-se um valor inicial as essas variáveis, pode-se determinar \hat{p}_{12} e \hat{p}_{23} através das equações (3.6.d) e (3.6.e). Daí, é possível definir os valores de P_1 , P_2 , P_3 pelas equações (3.6.a) a (3.6.c). Entretanto, definindo-se como variáveis de estado \hat{P}_1 e \hat{p}_{12} , por exemplo, e mesmo conhecendo inicialmente esses valores, as outras variáveis ficam indeterminadas pelo modelo de equações de rede anterior.

3.4 EQUAÇÕES DAS MEDIDAS

A partir do modelo de rede anterior, verifica-se uma ligação direta entre as variáveis do problema com as variáveis de estado por meio de um conjunto de equações de balanço de potência. Entretanto, o processo de estimação de estados é baseado em um conjunto de medidas

que podem ser provenientes de telemetria e/ou pseudo-medidas. Assim, o modelo de medição baseia-se nas relações do modelo de rede entre as variáveis de estado e as variáveis medidas. Existem duas categorias nas quais as medições podem ser divididas [86]:

- (i). Medidas de variáveis de estado: obtidas diretamente de medições;
- (ii). Medidas de variáveis dependentes: obtidas de medições e do modelo de equações que descreve estas variáveis em termos das variáveis medidas.

De forma a exemplificar, considera-se o sistema da Figura 3.1 atualizado na Figura 3.2 com os pontos de medição identificados pelos “quadrados pretos”.

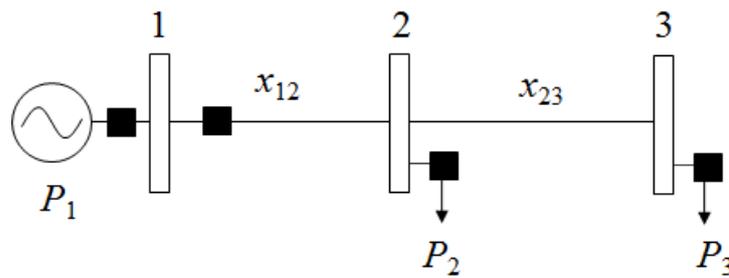


Figura 3.2. Sistema de 3 barras com medições.

O conjunto de medições pode ser constituído pelas medidas de injeção de potência ativa P_1^* , P_2^* e P_3^* pela medida de fluxo de potência ativa p_{12}^* . As variáveis de estado deste problema são $\hat{\theta}_2$ e $\hat{\theta}_3$, visto que $\hat{\theta}_1 = 0^\circ$ (referência). Considerando $x_{12} = 1/3$ pu e $x_{23} = 1/2$ pu, o modelo de rede pode ser atualizado aplicando-se estes valores às equações (3.6). Logo, tem-se as equações (3.7), relacionadas pelas quatro medições citadas.

$$P_1^* = -3\hat{\theta}_2 \quad (3.7.a)$$

$$P_2^* = 2(\hat{\theta}_2 - \hat{\theta}_3) - (-3\hat{\theta}_2) = 5\hat{\theta}_2 - 2\hat{\theta}_3 \quad (3.7.b)$$

$$P_3^* = -2(\hat{\theta}_2 - \hat{\theta}_3) = -2\hat{\theta}_2 + 2\hat{\theta}_3 \quad (3.7.c)$$

$$p_{12}^* = -2\hat{\theta}_2 \quad (3.7.d)$$

As equações anteriores podem ser escritas de forma matricial conforme equação (3.8).

$$\begin{pmatrix} P_1^* \\ P_2^* \\ P_3^* \\ p_{12}^* \end{pmatrix} = \begin{pmatrix} -3 & 0 \\ 5 & -2 \\ -2 & 2 \\ -2 & 0 \end{pmatrix} \begin{pmatrix} \hat{\theta}_2 \\ \hat{\theta}_3 \end{pmatrix} \quad (3.8)$$

Deste modelo matricial, verifica-se três pontos importantes a serem considerados: o primeiro membro envolve as medidas (z), o primeiro fator do segundo membro a matriz Jacobiana (H) e, por fim, o segundo fator compreende as variáveis de estado (x).

3.5 RESOLUÇÃO DO PROBLEMA DE ESTIMAÇÃO DC

A solução, que consiste na estimativa das variáveis de estado \hat{x} , é obtida aplicando-se a equação (3.4). Para tanto, é necessário identificar os principais termos, envolvendo a definição da matriz Jacobiana (H), do vetor de medições (x^*), da matriz de covariância de erros (W) e da matriz de ganho (G). Uma vez que \hat{x} é determinado, os resíduos (r) provenientes do processo de estimação são dados em função dos pontos do vetor de medições (x^*) e do vetor de estados estimados (\hat{x}), ou seja, $r = x^* - H\hat{x}$ [82].

De forma a esclarecer, considera-se o sistema de três barras da Figura 3.2, com o vetor de medições $x^* = [P_1^* \ P_2^* \ P_3^* \ p_{12}^*] = [1,56 \ -0,53 \ -0,96 \ 0,86]$ pu, e as variâncias $\sigma_{P_1}^2 = \sigma_{P_2}^2 = 0,004$ pu, $\sigma_{P_3}^2 = 0,001$ pu e $\sigma_{p_{12}}^2 = 0,002$ pu.

Aplicando-se os valores no modelo de equação (3.7), as variâncias na matriz de covariância (W) da equação (3.3), bem como a matriz de ganho (G), têm-se o seguinte sistema de equações (3.9).

$$\begin{pmatrix} 1,56 \\ -0,53 \\ -0,96 \\ 0,86 \end{pmatrix} = \begin{pmatrix} -3 & 0 \\ 5 & -2 \\ -2 & 2 \\ -2 & 0 \end{pmatrix} \begin{pmatrix} \hat{\theta}_2 \\ \hat{\theta}_3 \end{pmatrix} \quad (3.9.a)$$

$$\begin{pmatrix} \frac{1}{0,004} & & & \\ & \frac{1}{0,004} & & \\ & & \frac{1}{0,001} & \\ & & & \frac{1}{0,002} \end{pmatrix} = \begin{pmatrix} 250 & & & \\ & 250 & & \\ & & 1000 & \\ & & & 500 \end{pmatrix} \quad (3.9.b)$$

$$G = \begin{pmatrix} -3 & 5 & -2 & -2 \\ 0 & -2 & 2 & 0 \end{pmatrix} \begin{pmatrix} 250 & 0 & 0 & 0 \\ 0 & 250 & 0 & 0 \\ 0 & 0 & 1000 & 0 \\ 0 & 0 & 0 & 500 \end{pmatrix} \begin{pmatrix} -3 & 0 \\ 5 & -2 \\ -2 & 2 \\ -2 & 0 \end{pmatrix} \quad (3.9.c)$$

Assim, com todos os valores definidos, é possível obter as estimativas das variáveis de estado através da equação (3.4), obtendo-se, assim, o sistema da equação (3.10).

$$\hat{x} = \begin{bmatrix} 14500 & -6500 \\ -6500 & 5000 \end{bmatrix}^{-1} \begin{pmatrix} -3 & 5 & -2 & -2 \\ 0 & -2 & 2 & 0 \end{pmatrix} \begin{pmatrix} 250 & 0 & 0 & 0 \\ 0 & 250 & 0 & 0 \\ 0 & 0 & 1000 & 0 \\ 0 & 0 & 0 & 500 \end{pmatrix} \begin{pmatrix} 1,56 \\ -0,53 \\ -0,96 \\ 0,86 \end{pmatrix} \quad (3.10)$$

$$\hat{x} = \begin{pmatrix} \hat{\theta}_2 \\ \hat{\theta}_3 \end{pmatrix} = \begin{pmatrix} -0,4833 \\ -0,9593 \end{pmatrix}$$

Por fim, é possível encontrar os valores das injeções de potências e fluxo de potência a partir dos respectivos valores estimados, a fim de se determinar os resíduos associados às medições. Para tanto, aplica-se os resultados do sistema da equação (3.10) na equação (3.9.a), obtendo-se as estimativas inerentes às medições conforme equação (3.11.a), bem como os resíduos conforme equação (3.11.b).

$$\begin{pmatrix} \hat{P}_1 \\ \hat{P}_2 \\ \hat{P}_3 \\ \hat{P}_{12} \end{pmatrix} = \begin{pmatrix} 1,4499 \\ -0,4979 \\ -0,9520 \\ 0,9666 \end{pmatrix} \quad (3.11.a)$$

$$r = x^* - H\hat{x} = \begin{pmatrix} 1,56 \\ -0,53 \\ -0,96 \\ 0,86 \end{pmatrix} - \begin{pmatrix} 1,4499 \\ -0,4979 \\ -0,9520 \\ 0,9666 \end{pmatrix} = \begin{pmatrix} 0,1101 \\ -0,03207 \\ -0,0802 \\ 0,1066 \end{pmatrix} \quad (3.11.b)$$

3.6 COMPOSIÇÃO DO ESTIMADOR DE ESTADOS AC

Para o estimador de estados AC, são identificadas as principais características da matriz Jacobiana associada às equações do modelo de estimação *WLS*, que apresenta, neste caso, características não lineares [86]. Para isto, o modelo de equações não lineares é definido de forma semelhante a equação (3.1) do modelo DC, com alteração no vetor $h(\hat{x})$, neste caso de equações não lineares, que relacionam as medidas com as variáveis de estado conforme equação (3.12). Outro aspecto semelhante refere-se à composição da matriz de covariância (W), que relaciona os erros das medidas conforme equação (3.3).

$$x^* = h(\hat{x}) + e \quad (3.12)$$

Assim como o modelo DC, o modelo de estimação de estados AC consiste na minimização do índice J , reformulado na equação (3.13) para alcançar a melhor estimativa.

$$J(\hat{x}) = \frac{1}{2} (x^* - h(\hat{x}))^T W (x^* - h(\hat{x})) \quad (3.13)$$

Para minimizar o índice $J(x)$ e obter os valores estimados \hat{x} , deriva-se a equação anterior em função de x , igualando o resultado a zero, conforme equação (3.14).

$$\frac{\partial J(\hat{x})}{\partial \hat{x}} = H^T(\hat{x}) W (x^* - h(\hat{x})) = 0 \quad (3.14)$$

Assim, isolando a matriz Jacobiana $H(\hat{x})$, obtém-se a equação (3.15).

$$H(\hat{x}) = \left. \frac{\partial h(x)}{\partial x} \right|_{x=\hat{x}} \quad (3.15)$$

Considerando que o cálculo do índice da equação (3.13) envolve um vetor de equações não lineares, um processo iterativo é utilizado para a determinação dos estados estimados (\hat{x}),

em que as estimativas são atualizadas a cada iteração conforme equação (3.16), onde “ n ” é o índice da iteração.

$$\hat{x}^{n+1} = \hat{x}^n + \Delta\hat{x}^n \quad (3.16)$$

Para a obtenção das correções $\Delta\hat{x}^n$, é preciso linearizar as equações não lineares $h(x)$ em torno do ponto x^n , obtendo-se a equação (3.17).

$$h(\hat{x}^{n+1}) = h(\hat{x}^n) + H(\hat{x}^n)\Delta\hat{x}^n \quad (3.17)$$

Assim, reescrevendo a equação (3.12) com as aproximações para $h(x)$ de modo a linearizar o sistema original de equações, tem-se as equações (3.18.a) e (3.18.b), em que $\Delta z(x^n)$ é o vetor de resíduos de medição.

$$x^* = h(\hat{x}^n) + H(\hat{x}^n)\Delta\hat{x}^n + e \quad (3.18.a)$$

$$\Delta x^*(\hat{x}^n) = x^* - h(\hat{x}^n) = H(\hat{x}^n)\Delta\hat{x}^n + e \quad (3.18.b)$$

Atualizando o índice J de avaliação do processo de estimação, equação (3.13), tem-se a equação (3.19).

$$J(\Delta\hat{x}) = \left[\Delta x^*(\hat{x}^n) - H(\hat{x}^n)\Delta\hat{x}^n \right]^T W \left[\Delta x^*(\hat{x}^n) - H(\hat{x}^n)\Delta\hat{x}^n \right] \quad (3.19)$$

Por fim, derivando o índice $J(\Delta\hat{x})$ em relação $\Delta\hat{x}$ e igualando o resultado a zero, conforme equação (3.20.a), obtém-se a expressão final para o cálculo de $\Delta\hat{x}^n$ na equação (3.20.b).

$$\frac{\partial J(\Delta\hat{x})}{\partial \Delta\hat{x}} = H(\hat{x}^n)^T W \left[\Delta x^*(\hat{x}^n) - H(\hat{x}^n)\Delta\hat{x}^n \right] = 0 \quad (3.20.a)$$

$$\Delta\hat{x}^n = \left[H(\hat{x}^n)^T W H(\hat{x}^n) \right]^{-1} H(\hat{x}^n)^T W \Delta x^*(\hat{x}^n) \quad (3.20.b)$$

Analisando a equação (3.20.b), é possível definir a matriz de ganho G^n como sendo $H(\hat{x}^n)^T W H(\hat{x}^n)$. Reescrevendo esta equação com G^n definido e utilizando (3.18.b), tem-se a expressão final de atualização conforme equação (3.21).

$$\Delta \hat{x}^n = [G(\hat{x}^n)]^{-1} H(\hat{x}^n)^T W [x^* - h(\hat{x}^n)] \quad (3.21)$$

O processo iterativo tem início a partir de uma estimativa inicial definida como x^0 . Durante este processo, o vetor de correção $\Delta \hat{x}^n$ é encontrado pela equação (3.21), atualizando o vetor de estimativas por meio da equação (3.16), até que o critério de parada, dado por uma tolerância (ε) para o resíduo máximo, seja alcançado, conforme equação (3.22).

$$\max |\Delta \hat{x}_i| \leq \varepsilon \quad (3.22)$$

3.7 FUNÇÃO NÃO LINEAR PARA O SEP

No processo de estimação de estados, as medidas convencionalmente utilizadas são as injeções nodais de potência ativa e reativa, fluxos de potência ativa e reativa, e as medidas referentes ao módulo da tensão. Considerando o modelo π equivalente visto pela Figura 3.3, as equações que relacionam as medições com as variáveis de estado são dadas por [86]:

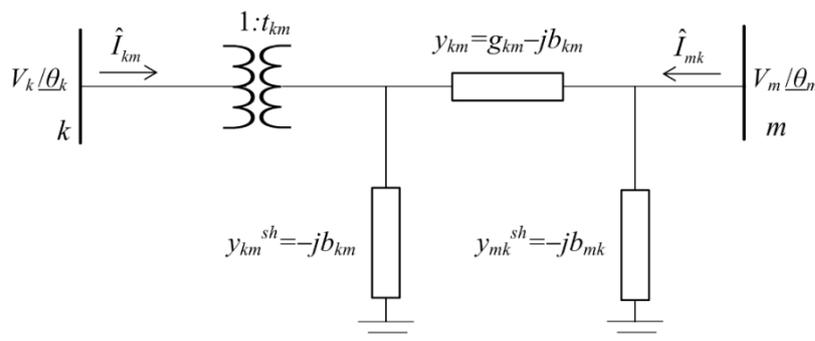


Figura 3.3. Modelo π equivalente da rede.

$$P_k = V_k \sum_{j \in Nb} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (3.23.a)$$

$$Q_k = V_k \sum_{j \in Nb} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (3.23.b)$$

$$p_{km} = V_k^2 (g_k^{sh} + g_{km}) - V_k V_m (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) \quad (3.23.c)$$

$$q_{km} = -V_k^2 (b_k^{sh} + b_{km}) - V_k V_m (g_{km} \sin \theta_{km} + b_{km} \cos \theta_{km}) \quad (3.23.d)$$

Em que:

- V_k Módulo de tensão da barra k ;
- Q_k Injeção líquida de potência reativa na barra k ;
- q_{km} Fluxo de potência reativa no trecho km ;
- θ_{km} Defasagem angular entre as barras k e m ;
- G_{km}, B_{km} Partes real e imaginária da matriz de admitância nodal, respectivamente;
- b_{km}, g_{km} Susceptância e condutância série do trecho $k-m$, respectivamente; e
- b_k^{sh}, g_k^{sh} Susceptância e condutância shunt na barra k , respectivamente.

3.8 COMPOSIÇÃO DA MATRIZ JACOBIANA H

A matriz Jacobiana (H) consiste na derivada da função não linear $h(\hat{x})$ (composta pelas equações de injeção nodal de potência ativa e reativa, pelos fluxos de potência ativa e reativa, bem como pelo módulo de tensão nodal) em função das variáveis de estado do sistema, formadas pelas tensões nodais em módulo e ângulo de fase. A Tabela 3.1 apresenta a matriz Jacobiana, em que as linhas correspondem a possíveis medidas disponíveis, enquanto que as colunas referem-se às variáveis de estado [74].

Tabela 3.1– Matriz Jacobiana para estimação de estados

	V_k	θ_k
P_k	$\frac{\partial P_k}{\partial V_k}$	$\frac{\partial P_k}{\partial \theta_k}$
Q_k	$\frac{\partial Q_k}{\partial V_k}$	$\frac{\partial Q_k}{\partial \theta_k}$
p_{km}	$\frac{\partial p_{km}}{\partial V_k}$	$\frac{\partial p_{km}}{\partial \theta_k}$
q_{km}	$\frac{\partial q_{km}}{\partial V_k}$	$\frac{\partial q_{km}}{\partial \theta_k}$
V_k	$\frac{\partial V_k}{\partial V_k} = 1$	$\frac{\partial V_k}{\partial \theta_k} = 0$

As derivadas da Tabela 3.1 são formuladas pelas equações (3.24)-(3.28), em que as equações (3.24) e (3.25) são para as injeções de potência ativa e reativa, respectivamente. Para os fluxos de potência ativa e reativa, tem-se as equações (3.26) e (3.27), respectivamente. Por fim, as equações referentes ao módulo de tensão são dadas por (3.28).

$$\frac{\partial P_k}{\partial \theta_k} = \sum_{m=1}^n V_k V_m (-G_{km} \sin \theta_{km} + B_{km} \cos \theta_{km}) - V_k^2 B_{kk} \quad (3.24.a)$$

$$\frac{\partial P_k}{\partial \theta_m} = V_k V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (3.24.b)$$

$$\frac{\partial P_k}{\partial V_k} = \sum_{m=1}^n V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) - V_k G_{kk} \quad (3.24.c)$$

$$\frac{\partial P_k}{\partial V_m} = V_k (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (3.24.d)$$

$$\frac{\partial Q_k}{\partial \theta_k} = \sum_{m=1}^n V_k V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) - V_k^2 G_{kk} \quad (3.25.a)$$

$$\frac{\partial Q_k}{\partial \theta_m} = V_k V_m (-G_{km} \cos \theta_{km} - B_{km} \sin \theta_{km}) \quad (3.25.b)$$

$$\frac{\partial Q_k}{\partial V_k} = \sum_{m=1}^n V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) - V_k B_{kk} \quad (3.25.c)$$

$$\frac{\partial Q_k}{\partial V_m} = V_k (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (3.25.d)$$

$$\frac{\partial p_{km}}{\partial \theta_k} = V_k V_m (g_{km} \sin \theta_{km} - b_{km} \cos \theta_{km}) \quad (3.26.a)$$

$$\frac{\partial p_{km}}{\partial \theta_m} = -V_k V_m (-g_{km} \sin \theta_{km} - b_{km} \cos \theta_{km}) \quad (3.26.b)$$

$$\frac{\partial p_{km}}{\partial V_k} = -V_m (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) + 2V_k (g_{km} + g_k^{sh}) \quad (3.26.c)$$

$$\frac{\partial p_{km}}{\partial V_m} = -V_k (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) \quad (3.26.d)$$

$$\frac{\partial q_{km}}{\partial \theta_k} = V_k V_m (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) \quad (3.27.a)$$

$$\frac{\partial q_{km}}{\partial \theta_m} = V_k V_m (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) \quad (3.27.b)$$

$$\frac{\partial q_{km}}{\partial V_k} = -V_m (g_{km} \sin \theta_{km} - b_{km} \cos \theta_{km}) - 2V_k (b_{km} + b_k^{sh}) \quad (3.27.c)$$

$$\frac{\partial q_{km}}{\partial V_m} = -V_k (g_{km} \sin \theta_{km} - b_{km} \cos \theta_{km}) \quad (3.27.d)$$

$$\frac{\partial V_k}{\partial \theta_k} = 0 \quad (3.28.a)$$

$$\frac{\partial V_k}{\partial \theta_m} = 0 \quad (3.28.b)$$

$$\frac{\partial V_k}{\partial V_k} = 1 \quad (3.28.c)$$

$$\frac{\partial V_k}{\partial V_m} = 0 \quad (3.28.d)$$

3.9 ESTIMAÇÃO DE ESTADOS COM DIVERSIDADE DE MEDIDAS

Como a qualidade do estimador depende da precisão dos dispositivos de medição, equipamentos mais precisos, como UMFs ou MIs, devem ser usados em conjunto no processo de estimação, que pode se valer de duas abordagens [100]. A primeira é baseada no conjunto de medidas a partir de UMFs e medições tradicionais, enquanto que a segunda abordagem apresenta duas etapas. A primeira etapa utiliza medições da subestação, pseudo-medidas, MI e medidas virtuais. Entende-se como medidas virtuais aquelas com alta precisão referentes às injeções nulas de potência ativa e reativa em barras de passagem [84]. A segunda etapa, por sua vez, denominada de pós-processamento, inclui medidas provenientes de UMFs para ajuste dos resultados. A segunda abordagem [77] será descrita com mais detalhes na sequência com ou sem a inclusão de medidas de corrente.

De modo geral, a estimação de estados pelo método dos mínimos quadrados ponderados utiliza o processo iterativo de Newton-Raphson [74] e [86] para minimizar a função objetivo J não linear da equação (3.13), que mensura a distância entre os pontos reais medidos e os estimados. Ou seja, deve-se determinar o vetor de variáveis de estado \hat{x} que minimiza J .

Portanto, o processo de estimação de estados envolve duas etapas: (i) Etapa 1: baseada em medições de equipamentos de menor precisão; (ii) Etapa 2: utilização de equipamentos mais precisos como UMFs para ajustes com a utilização de medidas de tensão e/ou de corrente.

3.9.1 Etapa 1 – Processamento de dados de menor precisão

O vetor de medidas da etapa 1 (z_1) inclui as advindas de subestações e MIs, envolvendo, por exemplo, fluxos de potência em trechos, injeções de potências e tensões, pseudo-medidas e medidas virtuais. Como mencionado anteriormente, dados provenientes de MIs apresentam maior precisão do que as pseudo-medidas, enquanto que medidas virtuais têm alta precisão [84]. Uma primeira estimação de estados é então computada e a função não linear de medidas determinada de forma semelhante à equação (3.12) do modelo AC, reformulada para a Etapa 1 conforme equação (3.29).

$$h_1(\hat{x}^{(1)}) = x_1^* - e_1 \quad (3.29)$$

Em que e_1 é o vetor de erros de medição, representados como variáveis aleatórias gaussianas com matriz de covariância da Etapa 1, denotada por R_1^{-1} . A função objetivo desta (J_1) pode ser escrita pelas equações (3.30).

$$J_1 = \tau_1^T W_1 \tau_1 \quad (3.30.a)$$

$$\tau_1 = \begin{bmatrix} x_{1,s}^* - h_{1,s}(\hat{x}^{(1)}) \\ x_{1,mi}^* - h_{1,mi}(\hat{x}^{(1)}) \\ x_{1,p}^* - h_{1,p}(\hat{x}^{(1)}) \\ x_{1,v}^* - h_{1,v}(\hat{x}^{(1)}) \end{bmatrix} \quad (3.30.b)$$

$$W_1 = R_1^{-1} = \begin{bmatrix} R_{1,s}^{-1} & 0 & 0 & 0 \\ 0 & R_{1,mi}^{-1} & 0 & 0 \\ 0 & 0 & R_{1,p}^{-1} & 0 \\ 0 & 0 & 0 & R_{1,v}^{-1} \end{bmatrix} \quad (3.30.c)$$

Em (3.30.b) e (3.30.c), os índices s , mi , p e v referem-se às medidas de subestações, de MIs, pseudo-medidas e medidas virtuais, respectivamente. Atribuindo valores iniciais para as variáveis de estado e aplicando o processo iterativo do método *WLS*, as variáveis $\hat{x}^{(1)}$ podem ser estimadas conforme (3.31.a), em que G_1 é a matriz de ganho dada em (3.31.b) [74].

$$\hat{x}_{k+1}^{(1)} = \hat{x}_k^{(1)} + G_1(\hat{x}_k^{(1)}) \left[H_1^T(\hat{x}_k^{(1)}) W_1 \right] \left[x_1^* - h_1(\hat{x}_k^{(1)}) \right] \quad (3.31.a)$$

$$G_1(\hat{x}_k^{(1)}) = \left[H_1^T(\hat{x}_k^{(1)}) W_1 H_1(\hat{x}_k^{(1)}) \right]^{-1} \quad (3.31.b)$$

Em que:

$\hat{x}_k^{(1)}$ Vetor de estimativas $\hat{x}^{(1)}$ na iteração k ; e

H_1 Matriz Jacobiana obtida pelas derivadas parciais de h_1 em relação a $\hat{x}_k^{(1)}$.

3.9.2 Etapa 2 – Pós-Processamento de dados de tensão

Na Etapa 2, ou de pós-processamento, supondo-se que o resultado de tensões do estimador de estados na Etapa 1, $\hat{V}^{(1)}$, seja obtido em coordenadas polares, com o módulo $|\hat{V}^{(1)}|$ e o ângulo de fase $\hat{\theta}^{(1)}$, incorpora-se a medição fasorial de tensão $x_{UMF}^* = [|V_{UMF}^*| \theta_{UMF}^*]^T$ a $\hat{x}^{(1)}$, atualizando-se a estimação. Com isto, o vetor de medições pós-processamento (z_2) é dado em (3.32).

$$x_2^* = \begin{bmatrix} |\hat{V}^{(1)}| \\ \hat{\theta}^{(1)} \\ |V_{UMF}^*| \\ \theta_{UMF}^* \end{bmatrix} = \begin{bmatrix} I & 0 \\ 0 & I \\ I' & 0 \\ 0 & I' \end{bmatrix} \begin{bmatrix} |\hat{V}^{(2)}| \\ \hat{\theta}^{(2)} \end{bmatrix} + e_2 = A \begin{bmatrix} |\hat{V}^{(2)}| \\ \hat{\theta}^{(2)} \end{bmatrix} + e_2 \quad (3.32.a)$$

$$W_2 = \begin{bmatrix} W_{\hat{x}^{(1)}} & 0 & 0 \\ 0 & W_{UMF,mod} & 0 \\ 0 & 0 & W_{UMF,\theta} \end{bmatrix} \quad (3.32.b)$$

$$W_{\hat{x}^{(1)}} = \left[H_1^T (\hat{x}^{(1)}) W_1 H_1 (\hat{x}^{(1)}) \right]^{-1} \quad (3.32.c)$$

$$A = \begin{bmatrix} I & 0 & I' & 0 \\ 0 & I & 0 & I' \end{bmatrix}^T \quad (3.32.d)$$

Em que:

- I, I' Matriz identidade e matriz identidade com elementos diagonais associados às tensões não medidas nulas, respectivamente;
- e_2 Erros de medições da etapa de pós-processamento, também representados como variáveis aleatórias gaussianas;
- $W_2, W_{\hat{x}^{(1)}}$ Matrizes de covariância da etapa de pós-processamento e da Etapa 1, respectivamente;
- $W_{UMF,mod}, W_{UMF,\theta}$ Matrizes de covariância associadas às incertezas de medidas de módulo de tensão e de ângulo de fase provenientes de UMFs, respectivamente.

A equação (3.32.a) é linear e a atualização das estimações de estado $\hat{x}^{(2)} = [|\hat{v}^{(2)}|\hat{\theta}^{(2)}]^T$ pode ser obtida usando o método *WLS* linear, conforme (3.33).

$$\hat{x}^{(2)} = [A^T W_2 A]^{-1} [A^T W_2] x_2^* \quad (3.33)$$

3.9.3 Etapa 2 – Pós-Processamento de dados de tensão e corrente

Para a etapa de pós-processamento, assim como descrito na seção anterior, ambas as medições fasoriais de tensão (módulo e ângulo de fase) são condicionadas pela UMF e, neste caso, há também inclusão de medidas de correntes nos trechos. A fim de obter um estimador de estados linear, as medições das UMFs são dadas em coordenadas retangulares [79].

Ao agregar os resultados da Etapa 1 ($\hat{x}^{(1)}$), o vetor de medições fasoriais de tensão e corrente é dado por $x_{UMF}^* = [|V_{UMF}^*| \theta_{UMF}^*]^T$, que pode ser dividido em duas partes: fasor tensão $V_{UMF}^* = [V_{UMF,real}^* \ V_{UMF,imag}^*]^T$ e fasor corrente $I_{UMF}^* = [I_{UMF,real}^* \ I_{UMF,imag}^*]^T$. Estes vetores de fasores são utilizados para atualizar as estimativas. As equações de medida pós-processamento (3.34) correspondem às equações (3.32).

$$x_2^* = \begin{bmatrix} V_{real}^{(1)} \\ V_{imag}^{(1)} \\ V_{UMF,real}^* \\ V_{UMF,imag}^* \\ I_{UMF,real}^* \\ I_{UMF,imag}^* \end{bmatrix} = \begin{bmatrix} I & 0 \\ 0 & I' \\ I' & 0 \\ 0 & I' \\ Y_1 & Y_2 \\ Y_3 & Y_4 \end{bmatrix} \begin{bmatrix} \hat{V}_{real}^{(2)} \\ \hat{V}_{imag}^{(2)} \end{bmatrix} + e_2 = A \begin{bmatrix} \hat{V}_{real}^{(2)} \\ \hat{V}_{imag}^{(2)} \end{bmatrix} + e_2 \quad (3.34.a)$$

$$A = \begin{bmatrix} I & 0 & I' & 0 & Y_1 & Y_3 \\ 0 & I & 0 & I' & Y_2 & Y_4 \end{bmatrix}^T \quad (3.34.d)$$

As matrizes Y_1 , Y_2 , Y_3 e Y_4 são compostas de condutâncias e susceptâncias para os ramos com medições de corrente; e_2 representa o vetor de erros de medição do passo de pós-processamento com a matriz covariância (W_2).

A atualização das variáveis de estado do processo de estimação é dada pela atualização da equação (3.33), que tem como vetor de medições (z_2^*) de tensão os resultados da estimativa da Etapa 1, com a inclusão das medidas provenientes das UMFs em coordenadas polares. Com

a atualização o novo vetor de medidas ($z_2^{*'}$), tem-se os resultados de tensão da Etapa 1, acrescidos das medidas de tensão e corrente das UMFs em coordenadas retangulares. Assim, a equação atualizada passa a ser dada por (3.35) em que $\hat{x}_{ret}^{(2)}$ é o vetor de estimativas da Etapa 2 em coordenadas retangulares.

$$\hat{x}_{ret}^{(2)} = [A^T W_2 A]^{-1} [A^T W_2] x_2^{*'} \quad (3.35)$$

A covariância da estimativa global $\hat{x}_{ret}^{(2)} = [\hat{x}_{real}^{(2)} \hat{x}_{imag}^{(2)}]^T$ é dada pela equação (3.36) e pode ser utilizada, sob a hipótese de Gauss, como uma avaliação de incerteza da estimativa.

$$W_{\hat{x}_{ret}^{(2)}} = [A^T W_2 A]^{-1} \quad (3.36)$$

Note-se que a matriz de covariância de erro da estimativa de estados $W_{\hat{x}_{ret}^{(2)}}$ da equação (3.36) é definida para o vetor de estados em coordenadas retangulares. Como a estimativa de estados é avaliada em termos de módulos e ângulos, a matriz de covariância é transformada para sua forma polar, $(W_{\hat{x}_{polar}^{(2)}})$ e a estimativa global dada pela equação (3.37) [101].

$$\hat{x}_{polar}^{(2)} = \left[\left| \hat{V}^{(2)} \right| \quad \hat{\theta}^{(2)} \right]^T \quad (3.37)$$

Portanto, a diagonal de $W_{\hat{x}_{polar}^{(2)}}$ inclui a variância do módulo de tensão $\sigma_{|\hat{x}_k^{(2)}|}^2$ e a variância do ângulo de fase $\sigma_{\hat{\theta}_k^{(2)}}^2$ para cada barra k .

3.10 CONSIDERAÇÕES FINAIS

Este capítulo teve como objetivo apresentar o processo de estimação de estados, contemplando importantes aspectos como observabilidade, redundância e erros de estimação. Avaliou-se a composição dos estimadores *WLS* DC e AC, as características da matriz Jacobiana e a inclusão de medidas provenientes dos equipamentos de monitoramento da rede. Por fim, foi apresentado o modelo de estimação clássico baseado no método dos mínimos quadrados ponderados, com as etapas de processamento e pós-processamento incluindo dados somente de tensão, bem como medidas de corrente, na etapa de pós-processamento.

4 METODOLOGIA PROPOSTA

4.1 CONSIDERAÇÕES INICIAIS

A metodologia proposta no presente trabalho para o planejamento de sistemas de monitoramento em sistemas de distribuição de energia elétrica envolve a aplicação de uma técnica moderna de otimização metaheurística ao problema e um novo método para estimação de estados, baseado em um modelo modificado de Fluxo de potência Ótimo (FPO), denominado *Extended Optimal Power Flow (E-OPF)*. Uma das inovações deste método consiste na sua aplicabilidade para estimação de estados sem a necessidade de dados históricos de carga precisos, aspecto que se enquadra no contexto de SDE típicos que não dispõem de sistemas de medição em toda a rede elétrica ou na maior parte desta, caracterizando falta de dados precisos para a estimação. Outra inovação é a função objetivo do *E-OPF*, que combina índices de desempenho das estimativas baseados no método *WLS* com índices adicionais inerentes às variáveis de estado, visando melhoria do processo de estimação de estados. O problema de planejamento envolve a determinação dos locais e tipos de sistemas de medição envolvendo unidades de medição fasorial e medidores inteligentes com o objetivo de maximizar a precisão do processo de estimação de estados. Por fim, a metodologia proposta nesta tese inclui a utilização do método de Pareto para tratar os diferentes objetivos, conflitantes entre si, do processo de planejamento de sistemas de medição a fim de obter uma relação custo-benefício satisfatória entre estes objetivos e prover múltiplas soluções de boa qualidade para o processo decisório. A metodologia considera ainda variações topológicas de rede e comportamento da demanda. Primeiramente, este capítulo apresenta o novo modelo *E-OPF* para estimação de estados. Na sequência, apresenta a abordagem mono-objetivo proposta para o problema multiobjetivo em questão, que combina as parcelas da função objetivo numa única função e, posteriormente, apresenta-se a abordagem multiobjetivo propriamente dita, via método de Pareto. Por fim, um sistema teste é utilizado para um tutorial sobre a metodologia multiobjetivo proposta.

4.2 METODOLOGIA PROPOSTA PARA ESTIMAÇÃO DE ESTADOS

4.2.1 Modelo de Fluxo de Potência Ótimo Modificado (*E-OPF*)

No modelo *E-OPF* proposto, as variáveis de estado da rede elétrica, que se pretende estimar, são definidas em coordenadas polares. Portanto, as variáveis de otimização envolvem as estimativas do estado da rede –“ \hat{x} ”, incluindo módulo e ângulo de fase das tensões nodais, conforme equação (4.1) [102].

$$\hat{x} = [\hat{\theta}_k, \hat{\theta}_{k+1}, \dots, \hat{\theta}_{Nb}, \hat{V}_k, \hat{V}_{k+1}, \dots, \hat{V}_{Nb}] \quad (4.1)$$

Em que Nb é o número de barras da rede elétrica.

O vetor de valores medidos - “ x^* ”, é obtido a partir de pelo menos um dos sistemas a seguir [77]:

- ✓ fasores de tensão e/ou módulo de corrente adquiridos por UMFs;
- ✓ medidas de módulo de tensão e/ou corrente provenientes de MI;
- ✓ medidas tipicamente utilizadas na distribuição, como as realizadas em subestações e associadas ao sistema SCADA;
- ✓ pseudo-medidas, baseadas em dados históricos sem requisito de precisão elevada; e/ou
- ✓ medidas virtuais, inerentes as barras de passagem, ou seja, sem carga.

A partir das medidas disponíveis, o Desempenho da Estimativa de Estado (*DEE*) pode ser calculado através do modelo não linear de estimação descrito no capítulo anterior, conforme método *WLS* conhecido. Este desempenho é reformulado na equação (4.2) [102].

$$DEE = [x^* - h(\hat{x})]^T W^{-1} [x^* - h(\hat{x})] \quad (4.2)$$

Embora a métrica do *WLS* tradicional, equação (4.2), seja amplamente utilizada na literatura, seu desempenho pode ser afetado quando a redundância do sistema de medição é baixa e para sistema não observáveis [102], aspecto que se verifica em SDE típicos [103]. Para melhorar a precisão da estimativa de estados em tais condições, o modelo proposto nesta tese combina o índice da equação (4.2) com dois termos adicionais para compor a Função Objetivo (*FOB*) do *E-OPF*, que deve ser minimizada.

Os termos adicionais da *FOB* no método de estimação proposta são índices relacionados ao módulo e ao ângulo de fase das tensões nodais, I_{MVD} e I_{AFD} , respectivamente, conforme propostos em [77] e formulados a seguir com pequenas modificações.

$$I_{MVD} = \max_k \left| \frac{|\hat{V}_k| - |V_k^*|}{|V_k^*|} \right| \quad (4.3.a)$$

$$I_{AFD} = \max_k \left| |\hat{\theta}_k| - |\theta_k^*| \right| \quad (4.3.b)$$

Destaca-se que nas equações (4.3.a) e (4.3.b), $|V_k^*|$ e $|\hat{V}_k|$ são os valores medidos e estimado do módulo de tensão da barra k , respectivamente, enquanto que $|\theta_k^*|$ e $|\hat{\theta}_k|$ são os valores medidos e estimado do ângulo de fase da barra k , respectivamente.

Os índices das equações (4.3.a) e (4.3.b) correspondem aos Valores Mínimos Absolutos, ou “*Least Absolute Values*” (*LAV*), dos erros de estimação do estado. Portanto, o procedimento de estimação de estados proposto combina os índices baseados em *DEE* e *LAV* visando melhorar a eficiência do processo para *SDE*. Desta forma, as Equações (4.4.a)-(4.4.g) formulam o *E-OPF* proposto, em que as estimativas $\hat{\theta}$ e \hat{V} são tratadas como variáveis independentes de otimização.

$$FOB = \min \left(DEE^c + I_{MVD}^c + I_{AFD}^c \right) \quad c \in C \quad (4.4.a)$$

Sujeito a:

$$\hat{P}g_k - \hat{P}l_k + \sum_{m \in \Omega_k} \hat{P}l_{km} = 0 \quad (4.4.b)$$

$$\hat{Q}g_k - \hat{Q}l_k + \sum_{m \in \Omega_k} \hat{Q}l_{km} = 0 \quad (4.4.c)$$

$$\hat{P}l_{\min_k} \leq \hat{P}l_k \leq \hat{P}l_{\max_k} \quad (4.4.d)$$

$$\hat{Q}l_{\min_k} \leq \hat{Q}l_k \leq \hat{Q}l_{\max_k} \quad (4.4.e)$$

$$0 \leq \hat{P}g_k \leq \hat{P}_{\max_k} \quad (4.4.f)$$

$$\hat{Q}_{\min_k} \leq \hat{Q}g_k \leq \hat{Q}_{\max_k} \quad (4.4.g)$$

Em que:

$\hat{P}g_k, \hat{Q}g_k$	Gerações de potência ativa e reativa na barra k ;
$\hat{P}l_k, \hat{Q}l_k$	Demandas de carga ativa e reativa na barra k ;
$\hat{P}_{km}, \hat{Q}_{km}$	Fluxo de potência ativa e reativa no trecho km ;
\hat{I}_{km}	Corrente no trecho km ;
Ω_k	Conjunto de barras adjacentes, conectadas por trechos de distribuição, à barra k ;
g_{km}, b_{km}	Condutância e susceptância do trecho km , respectivamente;
$\hat{P}_{\min_k}, \hat{P}_{\max_k}$	Limites inferior e superior da variável representativa da demanda de potência ativa da barra k , respectivamente;
$\hat{Q}_{\min_k}, \hat{Q}_{\max_k}$	Limites inferior e superior da variável representativa da demanda de potência reativa da barra k , respectivamente; e
$\hat{P}g_{\max_k}$	Limites superior de da variável representativa da geração de potência ativa na barra k ; e
$\hat{Q}g_{\min_k}, \hat{Q}g_{\max_k}$	Limites inferior e superior da variável representativa da geração de potência reativa da barra k , respectivamente.

Na função objetivo da equação (4.4.a), o sobrescrito “ c ” é utilizado para designar uma determinada configuração ou topologia de rede, dentro de um conjunto “ C ” de configurações consideradas. Esta função combina os índices baseados em *DEE* e *LAV* em um único objetivo, o que permite ao *E-OPF* proposto executar a etapa de filtragem no processo de estimação de estados [74]. Isto porque enquanto o *DEE* consiste em uma estimativa baseada em uma métrica que computa os desvios das medidas de forma agregada, os índices *LAV* computam os piores desvios. Daí, mesmo que o *DEE* indique boa qualidade do processo, uma vez que o cálculo envolve todos os desvios, alguma medida pode apresentar qualidade inaceitável diante de outras boas medidas. Neste caso, os índices *LAV* podem detectar a medida ruim, penalizando a *FOB*. Por outro lado, a utilização do *DEE* também é importante, pois permite ponderar a qualidade

do processo de forma agregada, penalizando a *FOB* caso muitas medidas apresentem erros pequenos, porém relevantes para impactar na estimativa de estado.

As restrições de balanço de potência ativa e reativa do *E-OPF* são dadas pelas equações (4.4.b) e (4.4.c), respectivamente. Os fluxos de potência ativa e reativa em um trecho *km* destas restrições foram formulados no capítulo anterior e são rerepresentados a seguir.

$$p_{km} = V_k^2 (g_k^{sh} + g_{km}) - V_k V_m (g_{km} \cos \theta_{km} + b_{km} \sin \theta_{km}) \quad (4.5.a)$$

$$q_{km} = -V_k^2 (b_k^{sh} + b_{km}) - V_k V_m (g_{km} \sin \theta_{km} + b_{km} \cos \theta_{km}) \quad (4.5.b)$$

As restrições anteriores, juntamente com (4.4.b) e (4.4.c), são derivadas das equações de potência para uma seção de uma rede de distribuição, ilustrada na Figura 4.1, referentes ao modelo não linear completo de uma rede elétrica para sistemas de alta/média tensão.

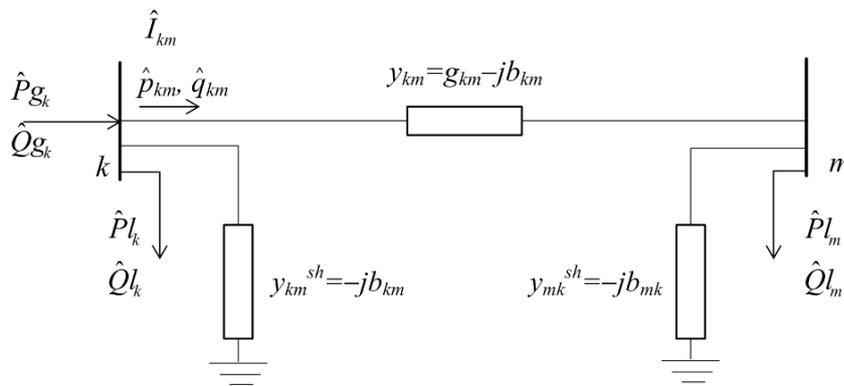


Figura 4.1. Modelo da rede não linear.

Em que y_{km}^{sh} é a susceptância em derivação do trecho *km*. As não linearidades relacionadas a um SDE devem-se aos afundamentos de tensão que ocorrem em trechos de alimentadores e à natureza de suas cargas. Outras não linearidades como, por exemplo, inerentes a dispositivos modernos como sistemas de transmissão flexível AC ou “*Flexible AC Transmission System*” (*FACTS*) próprios para SDE, bem como a geração distribuída baseada em diferentes fontes primárias, não são abordadas nesta tese, embora possam ser incorporadas ao modelo de rede utilizado devido à sua flexibilidade para representar dispositivos adicionais. Portanto, apenas as não linearidades relacionadas aos elementos básicos de um SDE tradicional são representadas neste trabalho, haja vista que o mesmo visa ao planejamento de medição para a melhoria do processo de estimação de estados de uma rede generalizada.

Pode-se ressaltar que os fluxos de potência \hat{p}_{km} e \hat{q}_{km} são variáveis dependentes estimadas, pois são funções das variáveis de estados estimadas $\hat{\theta}_k$ e \hat{V}_k , definidas como variáveis de otimização independentes do *E-OPF*.

A estimativa da corrente \hat{I}_{km} , por sua vez, também é obtida a partir dos valores estimados $\hat{\theta}_k$ e \hat{V}_k , através da Equação (4.6.a) referente ao modelo de rede da Figura 4.1. A estimativa de \hat{I}_{km} permite monitorar violações de capacidade dos trechos da rede. Adicionalmente, em caso de medidas de correntes disponíveis, esta estimativa é necessária para aferir o desempenho do estimador, conforme Equação (4.2). Para obter a expressão da corrente I_{km} , parte-se das Equações (4.6.b) e (4.6.c), conforme descrito a seguir.

$$\hat{I}_{km} = \sqrt{(g_{km}^2 + b_{km}^2) (\hat{V}_k^2 + \hat{V}_m^2 - 2\hat{V}_k \hat{V}_m \cos(\hat{\theta}_k - \hat{\theta}_m))} \quad (4.6.a)$$

$$I_{km} = S_{km} / V_k \quad (4.6.b)$$

$$S_{km} = \sqrt{p_{km}^2 + q_{km}^2} \quad (4.6.c)$$

Em que S_{km} representa o módulo da potência complexa no trecho km . Substituindo-se as expressões de p_{km} e q_{km} , equações (4.5.a) e (4.5.b), em (4.6.c), obtém-se a Equação (4.7). Substituindo esta equação em (4.6.b), obtém-se I_{km} da Equação (4.6.a).

$$S_{km} = \sqrt{(g_{km}^2 + b_{km}^2) V_k^2 (V_k^2 + V_m^2 - 2V_k V_m \cos \theta_{km})} \quad (4.7)$$

Em suma, o modelo anteriormente descrito consiste em um fluxo de potência ótimo [104] com modificações, em que as variáveis de otimização são as variáveis de estado estimadas. As modificações propostas estão listadas a seguir:

- A *FOB* compreende a minimização dos índices baseados em *DEE* e *LAV* para o processo de estimativa de estados;
- As potências de carga, $\hat{P}l_k$ e $\hat{Q}l_k$ e as potências de geração, $\hat{P}g_k$ e $\hat{Q}g_k$, também são variáveis de otimização no *E-OPF*, dentro dos limites das restrições (4.4.d) e (4.4.e), de modo que a carga também é estimada pelo modelo proposto. Os detalhes sobre esta representação são descritos adiante.

Para facilitar a convergência do processo de otimização, limitando a busca em regiões viáveis, são definidos limites de tensão, \hat{V}_{min} e \hat{V}_{max} que são relaxados e devem ser ajustados para valores de limite de tensão viáveis para SDE, dependendo de cada topologia do sistema analisando. Deve-se enfatizar que os limites de tensão, permitem e aceleram a convergência, mesmo para uma única medida de módulo da tensão e ângulo de fase, o que torna o *E-OPF* uma ferramenta robusta para conduzir o processo de estimação de estados de SDE, com poucas medidas disponíveis. No entanto, apesar do bom desempenho do *E-OPF* proposto, este varia com o número e a qualidade das medidas disponíveis, bem como com a localização de equipamentos de medição, por exemplo, UMF.

O modelo formulado em (4.4.a)-(4.4.g) trata-se de um problema de programação não linear, contínuo e não-convexo, devido a diversos pontos de ótimos locais, que pode ser resolvido com algoritmos conhecidos na literatura [104] e, portanto, pode incorporar não linearidades adicionais como mencionado anteriormente.

4.2.2 Representação da Carga

Conforme descrito anteriormente, as potências das cargas são representadas no *E-OPF* proposto como variáveis de otimização que podem variar dentro de intervalos relaxados, dados pelas equações (4.4.d) e (4.4.e). O propósito deste modelo relaxado é permitir a estimação de estados mesmo para ausência de dados históricos precisos, como tradicionalmente ocorre na distribuição. Neste caso, os limites são definidos a partir de dados de carga históricos de baixa precisão e, portanto, com uma margem de variação maior, justificando o relaxamento.

Em outras palavras, mesmo para imprecisão dos dados de potência das cargas (dados históricos com grande variação percentual de erro) ou falta de dados em tempo real, o *E-OPF* torna-se adequado para SDE com escassez de medidas. As informações de carga histórica podem ser consideradas como pseudo-medidas que auxiliam o processo de estimativa de estado em condições de redundância precárias. Portanto, o *E-OPF* proposto requer:

- Dados históricos de potência de carga ativa e reativa, utilizados como pseudo-medidas, com alta taxa de erro;
- Pelo menos uma UMF alocada na subestação, fornecendo a medida de módulo e ângulo de fase de tensão nodal (referência angular), dado por $x^* = [\theta_k^*, V_k^*]$.

Observe que o *E-OPF* apresenta quatro variáveis de otimização independentes para cada barra além das potências de geração na SE ($\hat{P}g_k, \hat{Q}g_k$): (i) o ângulo de fase estimado de tensão ($\hat{\theta}_k$), (ii) o módulo estimado de tensão (\hat{V}_k), (iii) a potência ativa da carga ($\hat{P}l_k$) e (iv) a potência reativa da carga ($\hat{Q}l_k$). Portanto, as potências das cargas são estimadas dentro de um intervalo determinado pelo seu comportamento histórico. As barras sem carga, chamados de barra de injeção zero, têm $\hat{P}l_k$ e $\hat{Q}l_k$ ajustados em zero e não incluem erros no processo de estimação de estados. Destaca-se que o *E-OPF* fornece os valores de carga otimizados que maximizam o desempenho do estimador, ou seja, minimizar *DEE* na Equação (4.2).

Os intervalos relaxados para as potências das cargas e os limites de módulo de tensão, dados pelas restrições (4.4.d)-(4.4.g), tornam a convergência do *E-OPF* proposto fácil e robusta, o que permite a sua aplicação para variações topológicas de rede, dentro do conjunto *C*, e fornece uma representação mais realista da operação de um SDE.

4.3 METODOLOGIA DE PLANEJAMENTO DE MEDIÇÃO – ABORDAGEM MONO-OBJETIVO

O problema de alocação de equipamentos de medição envolve variáveis inteiras para representar a opção de investimento em cada ponto ou barra do SDE. Na abordagem mono-objetivo proposta, a função objetivo é formada por dois grupos de parcelas, um dado pelo custo de investimento em equipamentos e o outro por índices que expressam a precisão do processo de estimação de estados descrito na seção anterior. Este processo é estocástico, ou seja, faz-se uma abordagem probabilística para índices de desvio de tensões fasoriais [77]. Primeiramente, o desempenho do estimador, *DEE* via equação (4.2) é avaliado por meio dos equipamentos alocados e que fornecem as medidas. Posteriormente avalia-se a *FOB* associando os custos relativos aos equipamentos alocados e os dois índices das equações (4.3.a) e (4.3.b), que representam o módulo de tensão (I_{MVD}) e o ângulo de fase (I_{AFD}), respectivamente avaliados por meio dos valores estimados de $\hat{\theta}_k$ e \hat{V}_k , via *DEE*. Vale ressaltar, que os índices utilizados para o “modelo de planejamento”, não utilizam os valores medidos, mas, sim, os valores verdadeiros via Fluxo de Potência Convencional (FPC) dados por θ_k e V_k para a comparação com os valores estimados $\hat{\theta}_k$ e \hat{V}_k . Destaca-se que o problema original é multiobjetivo, porém, a abordagem

apresentada nesta seção é mono-objetivo, pois modela uma única função que inclui todas as parcelas anteriormente citadas.

O erro do módulo de tensão é expresso através de valor relativo conforme (4.3.a), pois é o parâmetro mais significativo da estimativa. O erro do ângulo de fase, por sua vez, é expresso em valor absoluto conforme (4.3.b). A função objetivo do problema global de planejamento de equipamentos de medição é formulada na equação (4.8) [77].

$$FOB = \text{Min} \left[\gamma \cdot \left(\sum_{k=1}^{Nb} c_{UMF_k} \cdot x_{UMF_k} + \sum_{k=1}^{Nb} c_{MI_k} \cdot x_{MI_k} \right) + \alpha \cdot \sum_{c \in C} I_{MVD}^c + \beta \cdot \sum_{c \in C} I_{AFD}^c \right] \quad (4.8)$$

Em que:

- c_{UMF_k}, c_{MI_k} Custos de investimento em UMF e MI, respectivamente, na barra k ;
- x_{UMF_k}, x_{MI_k} Variáveis inteiras que representam a opção de investimento em UMF e MI, respectivamente, na barra k (1 – investimento, 0 – investimento não indicado);
- α, β, γ Pesos para os desvios de módulo de tensão (relativo), de ângulo de fase (absoluto) e dos custos, respectivamente.

A técnica de alocação de equipamentos utilizada é denominada *Modified Monkey Search* [105] e [106], sendo também implementadas outras duas técnicas para fins de comparação: Algoritmo Genético (AG) [107] e Recozimento Simulado (RS) [108]. A técnica metaheurística *MMS* é descrita de forma genérica no Apêndice A. Nesta técnica, cada indivíduo representa uma solução candidata ao planejamento de equipamentos de monitoramento, sendo codificado em um vetor com duas partes: *a*) parte *A* - valores para as variáveis inteiras de decisão do problema, ou seja, x_{UMF_k} e x_{MI_k} ; e *b*) parte *B* - trechos monitorados pelos equipamentos alocado de acordo com a parte *A*. A Figura 4.2 apresenta a codificação adotada no algoritmo *MMS*.

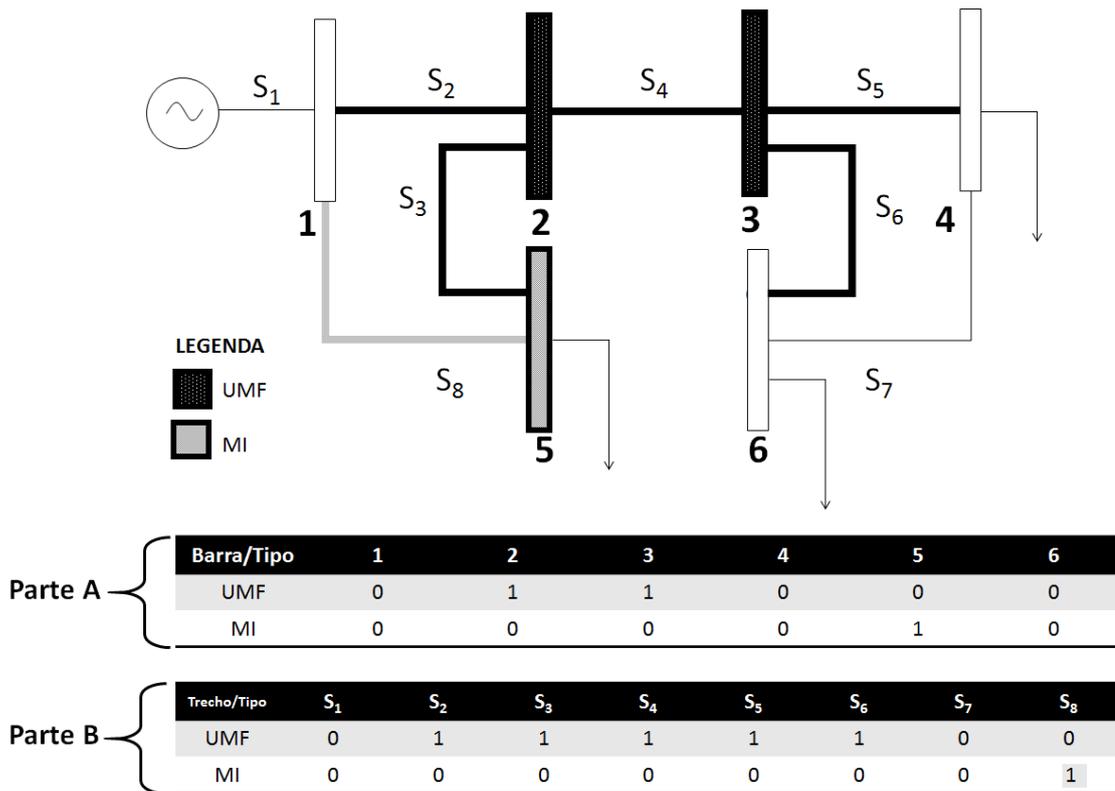


Figura 4.2. Codificação de uma solução candidata no *MMS* proposto.

No exemplo da Figura 4.2, o sistema apresenta seis barras, sendo a barra ‘1’ referente à subestação, as barras ‘2’ e ‘3’ de passagem e as barras ‘4’, ‘5’ e ‘6’ de carga. Neste caso, o limite de equipamentos, UMF e/ou MI, é cinco, pois a SE já conta com medição própria. Ou seja, outra restrição para o modelo de otimização é $N_{UMF} + N_{MI} \leq Nb - 1$, em que N_{UMF} e N_{MI} representam, respectivamente, os números de UMF e de MI no sistema. Esta restrição não foi incluída no modelo de FPO proposto, pois é preestabelecida para a técnica metaheurística *MMS*.

A codificação proposta para a parte *A* é binária, em que o valor “1” em uma posição determina a alocação do equipamento na barra associada a esta posição, enquanto que o valor “0” representa ausência de investimento na barra correspondente. Ainda, cada solução candidata é representada por dois vetores, sendo um para UMF e outro para MI. Na ilustração da Figura 4.2, o vetor superior armazena as decisões de investimento em UMF e o inferior sobre MI. Portanto, neste exemplo, há a alocação de UMF nas barras ‘2’ e ‘3’ e de MI na barra ‘5’.

A codificação da parte *B*, também apresenta código binário em que “1” indica que o trecho foi devidamente medido e “0” significa a ausência de medição conforme Figura 4.2. Assim, a parte superior indica o monitoramento do(s) trecho(s) pelas UMF da Parte *A* sendo estes destacados na Figura 4.2 como S_2 , S_3 , S_4 , S_5 e S_6 , enquanto que a parte inferior, tem-se a representação do(s) trecho(s) monitorados pelos MI da Parte *A* que para o exemplo em questão, o MI monitorou o trecho de corrente S_8 .

Cabe então destacar que a composição da parte *B* nas soluções candidatas atende à possibilidade de monitoramento dos equipamentos da parte *A*, a fim de consistência da solução, bem como o alcance destes equipamentos em termos de elementos de rede a se monitorar. Por exemplo, na Figura 4.2, as UMF das barras '2' e '3' podem monitorar os trechos S_2 , S_3 , S_4 , S_5 e S_6 , tendo em vista suas localizações e/ou canais de monitoramento e/ou infraestrutura de comunicação.

As soluções candidatas que não atendem às restrições operativas, como os limites de precisão, são penalizadas pelo processo de busca. Diferentes configurações são consideradas para o planejamento, cada qual referente a uma topologia de rede, visando ao melhor planejamento contemplando as diferentes condições operativas a que um SDE normalmente está exposto.

Cada configuração candidata é avaliada através da função objetivo em (4.8), que inclui a precisão do processo de estimação de estados e o custo de investimento. Para obter a precisão do estimador, o modelo *E-OPF* proposto, descrito na seção anterior, é executado para cada topologia. A ferramenta de otimização para resolução do modelo de FPO modificado *E-OPF* baseia-se no método primal-dual de pontos interiores [109]. O Apêndice B apresenta a formulação do MPI.

4.4 METODOLOGIA DE PLANEJAMENTO DE MEDIÇÃO – ABORDAGEM MULTI OBJETIVO

Como descrito anteriormente, os objetivos do modelo de planejamento a serem investigados envolvem, a princípio, a maximização da eficiência do processo de estimação de estados do SDE e a minimização dos custos de investimento em equipamentos de

monitoramento [110]. Estes objetivos são conflitantes entre si, ou seja, um aporte mínimo de investimento implica em baixa precisão, e vice-versa. Problemas deste tipo requerem o estabelecimento de um compromisso adequado entre os objetivos conflitantes, o que consiste em uma tarefa complexa para a tomada de decisões. Portanto, metodologias capazes de lidar com problemas multiobjetivo, incluindo objetivos conflitantes entre si, devem ser investigadas e aplicadas para o sucesso do processo de otimização.

4.4.1 Formulação de um Problema Multiobjetivo

Considera-se o vetor de variáveis de decisão x , de dimensão n , na equação (4.9).

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (4.9)$$

A formulação do problema de otimização multiobjetivo pode ser definida como a minimização de um conjunto de k funções como na equação (4.10). No caso de maximização de alguma função, o problema pode ser reformulado para obter uma função de minimização correspondente.

$$\min_x f(x) = \{f_1(x), \dots, f_k(x)\} \quad (4.10)$$

Existem duas abordagens de otimização de multiobjetivo. A primeira consiste em atribuir pesos ou penalizações a cada objetivo individualmente e obter, através de uma soma ponderada, um único objetivo, conforme equação (4.11).

$$\min_x f(x) = \alpha f_1(x) + \beta f_2(x) + \dots + \gamma f_k(x) \quad (4.11)$$

A atribuição dos pesos ($\alpha, \beta, \dots, \gamma$) não é trivial e depende da importância dos objetivos do problema em questão. Geralmente, o peso de cada objetivo é proporcional à sua importância relativa. A dificuldade de ajuste dos pesos é uma desvantagem desta abordagem [111]. Além disto, pode haver funções objetivo cujos valores não se convertam a uma mesma medida, o que impossibilita a atribuição de pesos [112].

Na segunda abordagem, todos os objetivos são tratados como distintos. Na maioria dos casos e problemas reais, tratam-se de objetivos conflitantes, cuja otimização simultânea de cada um é difícil ou até impossível. Assim, a otimização de uma função pode conduzir a um ponto inaceitável para os outros objetivos. Para tanto, o método de Pareto tem sido utilizado [111].

4.4.2 Conjunto Ótimo de Pareto

O método de Pareto visa determinar um conjunto de soluções promissoras sob o ponto de vista de diferentes objetivos, que definem uma superfície denominada superfície de Pareto. Uma solução pertence à superfície de Pareto se não for dominada por qualquer outra solução, ou seja, se não for de pior qualidade do que outra solução com relação a todos os objetivos. Esta solução não pode ser melhorada em relação a um objetivo sem que piore em relação a outro.

Formulando, diz-se que uma solução x domina outra solução y , ou em outras palavras, x é superior a y , se e somente se atender ao pressuposto da equação (4.12) para um problema envolvendo apenas minimização de funções.

$$f_i(x) \leq f_i(y) \quad \forall i \quad \text{e} \quad i \in \{1, \dots, N_{obj}\} \quad (4.12)$$

$$f_i(x) < f_i(y) \text{ para algum } i$$

Em que N_{obj} é o número de funções objetivo a serem minimizadas. A Figura 4.3 ilustra uma superfície de Pareto para um problema de minimização de duas funções objetivo.

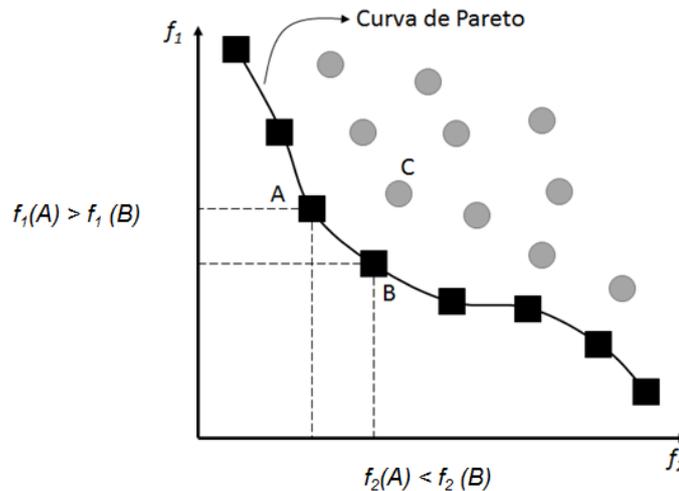


Figura 4.3. Curva ou superfície de Pareto para um problema de minimização de duas funções.

As soluções A e B pertencem à superfície de Pareto, pois não são dominadas por qualquer outra solução. Por outro lado, quando se desloca da solução A para a B (ou vice-versa), há certa degradação do objetivo f_2 (ou f_1) para obter um ganho no objetivo f_1 (ou f_2). A solução C , por sua vez, é dominada tanto pela solução A , pois $f_1(A) \leq f_1(C)$ e $f_2(A) \leq f_2(C)$, quanto pela solução B , pois $f_1(B) \leq f_1(C)$ e $f_2(B) \leq f_2(C)$. Logo, a solução C não pertence à superfície de Pareto.

De forma mais genérica, a caracterização dos objetivos quanto à sua minimização ou maximização define o tipo de curva associada ao conjunto ótimo de Pareto, conforme os quatro tipos ilustrados na Figura 4.4 para um problema de duas funções.

A metodologia proposta nesta tese inclui dois objetivos a serem minimizados na curva de Pareto, ou seja, enquadra-se no caso da curva superior esquerda da Figura 4.4. O primeiro objetivo consiste no custo total de investimento, primeira parcela da equação (4.8), ou seja,

$$f_1 = \gamma \cdot \left(\sum_{k=1}^{Nb} c_{UMF_k} \cdot x_{UMF_k} + \sum_{k=1}^{Nb} c_{MI_k} \cdot x_{MI_k} \right).$$

O segundo objetivo da curva de Pareto a ser minimizado, por sua vez, refere-se aos índices de precisão do estimador de estados, incluindo a segunda e terceira parcelas da FOB ,

$$\text{ou seja, } f_2 = \alpha \cdot \sum_{c \in C} I_{MVD}^c + \beta \cdot \sum_{c \in C} I_{AFD}^c.$$

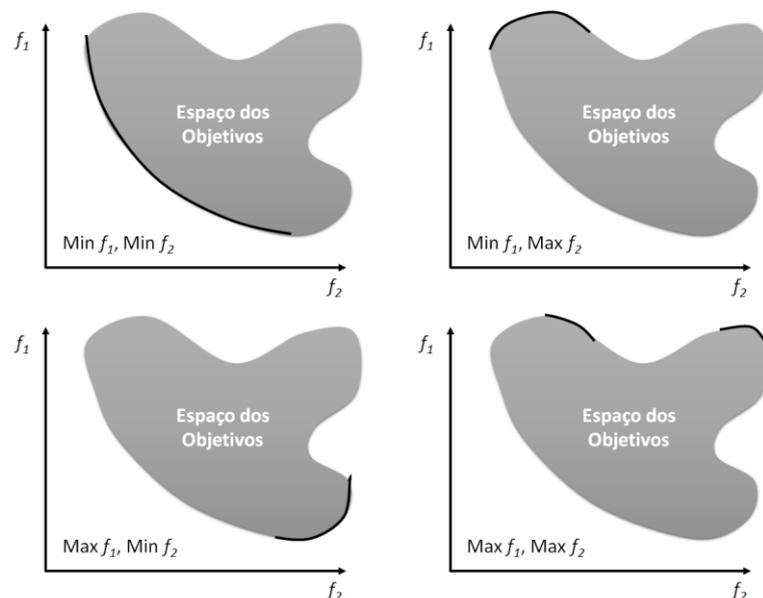


Figura 4.4. Tipos de curvas de Pareto.

4.4.3 Função de aptidão

A função de aptidão para avaliação de soluções que compõem a curva de Pareto é feita pelo algoritmo proposto em [113], denominado *Strength Pareto Evolutionary Algorithm (SPEA2)*. Este método é baseado na evolução de duas populações de soluções candidatas - P e A , cujas inicializações são P_0 e A_0 , respectivamente, e as atualizações em cada iteração t são P_t e A_t , respectivamente. A população P_0 é gerada aleatoriamente com um número predefinido de soluções candidatas, enquanto que A_0 inicia-se vazia. As matrizes A_t e P_t recebem, em cada iteração $t = 1, 2, \dots, n_{iter}$, as soluções não-dominadas e dominadas, respectivamente, encontradas até t , sendo n_{iter} o número máximo de iterações.

A união das matrizes P_t e A_t forma um universo de soluções definidos com U_t , ou seja, $U_t = P_t \cup A_t$. Daí, o valor de aptidão de uma solução candidata i , representado por $forca_i$, é dado pela equação (4.13), em que Di é o conjunto de soluções candidatas dominadas por i .

$$forca_i = \sum_{i=1:Di} 1 \quad (4.13)$$

O valor de aptidão $forca_i$ representa o número de soluções em U_t que são dominadas pela solução i . Assim, soluções i que não dominam qualquer outra recebem $forca_i = 0$.

Outro parâmetro utilizado consiste no somatório dos valores de aptidão das soluções candidatas que dominam uma candidata i , representado por $sforca_i$ e formulado na equação (4.14), em que SDi é o conjunto de soluções que dominam i .

$$sforca_i = \sum_{j=1:SDi} forca_j \quad (4.14)$$

Ou seja, as soluções não-dominadas recebem $sforca_i = 0$, enquanto que $sforca_i$ elevado significa que a candidata i é dominada por muitas soluções do universo U_t . Para exemplificar, a Figura 4.5 traz uma curva de Pareto do tipo (Min x Min) para duas funções objetivo f_1 e f_2 , com algumas soluções representadas por pares ordenados codificados como $(forca_i, sforca_i)$.

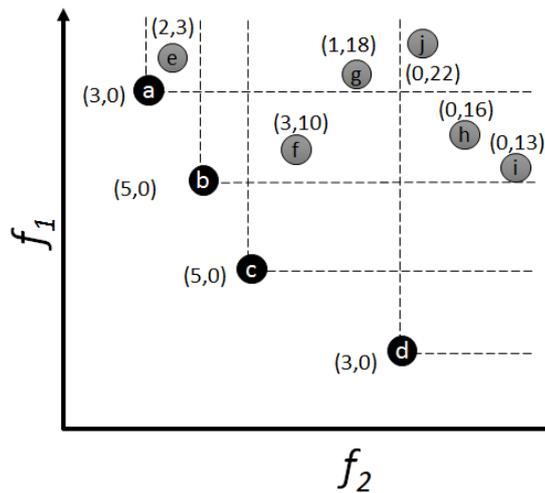


Figura 4.5. Curva ilustrativa dos parâmetros associados à aptidão no método de Pareto.

Para exemplificar a Figura 4.5, observe a solução ‘a’ e a solução ‘b’. Entre essas soluções há uma relação de compromisso, ou seja, quando segue de ‘a’ para ‘b’ reduz-se f_1 mas aumenta f_2 . Porém, quando compara-se a soluções ‘a’ e ‘e’ não há uma relação de compromisso pois quando segue de ‘a’ para ‘e’ aumenta-se f_1 e f_2 . Assim pode-se afirmar que a solução ‘a’ domina a solução ‘e’ acumulando $forca_i = 3$. A solução ‘a’ domina as soluções ‘e’, ‘g’ e ‘j’ totalizando $forca_i = 3$. Em compensação, como a solução ‘a’ pertence a fronteira ótima de Pareto, ela não é dominada por nenhuma solução e assim, sua $sforca_i = 0$. Em contrapartida, a solução ‘j’ não domina nenhuma solução na Figura 4.5 e assim possui $forca_i = 0$ e além disso, é dominada pelas soluções ‘a’, ‘b’, ‘c’, ‘d’, ‘e’, ‘f’ e ‘g’ que possuem cada uma $forca_i$ igual ‘3’, ‘5’, ‘5’, ‘3’, ‘2’, ‘3’ e ‘1’, respectivamente, totalizando um $sforca_i = 22$.

Uma desvantagem do mecanismo de ordenação anteriormente descrito surge quando o sistema gera muitas soluções candidatas não-dominadas, conforme descrito em [113], pois, neste caso, fica difícil definir vantagens ou prioridades entre as mesmas. Para tratar esta desvantagem, o algoritmo *SPEA2* utiliza uma informação sobre densidade populacional em uma região do espaço de busca, com base em comparações entre cada solução e suas soluções vizinhas. Para cada solução i em U_t , obtém-se as distâncias euclidianas em relação as soluções $j \in U_t$ e $j \neq i$. A partir das distâncias coletadas, o algoritmo ordena as soluções em ordem decrescente e utiliza-se da informação da distância referente a posição gerada pelo coeficiente k formulado em (4.15.b) para calcular a densidade. Mais especificamente, a equação (4.15.a)

formula a relação entre a densidade de uma solução candidata i ($densidade_i$) e a distância ($distancia_{ij}^k$) gerada na posição k especificada entre esta solução e aquelas que pertencem à mesma fronteira da primeira, ou seja, suas soluções candidatas "vizinhas".

$$densidade_i = \frac{1}{distancia_{ij}^k + 2} \quad (4.15.a)$$

$$k = \sqrt{|U^i|} \quad (4.15.b)$$

Observa-se na equação (4.15.a) que a densidade de uma solução candidata i é inversamente proporcional à sua distância para seus vizinhos. Por fim, a função aptidão para cada solução i no universo U_i é calculada por meio da equação (4.16).

$$aptidao_i = 1 / (sforca_i + densidade_i) \quad (4.16)$$

Da equação (4.16), depreende-se que quanto menor $sforca_i$, melhor é a aptidão da solução candidata i , pois menor é o número de candidatas que dominam i , indicando, portanto, sua boa qualidade. Adicionalmente, quando menor a $densidade_i$ maior a $distancia_{ij}^k$ e melhor é a aptidão, priorizando assim, soluções candidatas de mesma fronteira mais distantes do aglomerado, a fim de priorizar a introdução de diversidade no conjunto de soluções candidatas.

4.4.4 Aplicação do Método de Pareto para o Problema de Planejamento Proposto

Na metodologia de planejamento de sistemas de medição proposta, abordagem multiobjetivo via Pareto, tem-se as duas funções objetivo a seguir, conforme descrito anteriormente.

$$f_1 = \gamma \cdot \left(\sum_{k=1}^{Nb} c_{UMF_k} \cdot x_{UMF_k} + \sum_{k=1}^{Nb} c_{MI_k} \cdot x_{MI_k} \right) \quad (4.17.a)$$

$$f_2 = \alpha \cdot \sum_{c \in C} I_{MVD}^c + \beta \cdot \sum_{c \in C} I_{AFD}^c \quad (4.17.b)$$

Conforme descrito, a função f_1 refere-se ao custo total de investimento, enquanto que f_2 é relativa aos índices de precisão do estimador de estados $E-OPF$ proposto. Quanto menor o custo total - f_1 , melhor é a solução, e quanto menor o somatório dos índices de estimação - f_2 ,

melhor é a qualidade do processo. Portanto, no problema de planejamento em questão, busca-se minimizar ambas as funções, f_1 e f_2 .

Estas duas funções são conflitantes entre si, pois quanto maior o investimento, pior a otimização sob o ponto de vista de f_1 , porém, melhor sob o ponto de vista de f_2 , haja vista que, neste caso, um maior aporte de investimento implica em maior número de medidores e/ou equipamentos de maior qualidade e, portanto, em melhor estimador. A Figura 4.6 ilustra a característica conflitante entre os objetivos do problema, em que se pode observar que quanto menor o custo de investimento f_1 , pior tende a ser o desempenho do estimador de estados, ou seja, maior tende a ser f_2 , o que ocorre no ponto “2”. Por outro lado, quanto maior o custo f_1 , melhor tende a ser o desempenho do estimador e, portanto, menor f_2 , situação representada no ponto “1”. O ponto “3”, por sua vez, é uma solução dominada ou de baixa qualidade, pois implica em alto investimento e baixo desempenho do estimador. Por se tratarem de objetivos de diferentes naturezas e conflitantes entre si, custo e qualidade do estimador, a aplicação de técnica de otimização, como o *MMS-Pareto* proposto, é justificada.

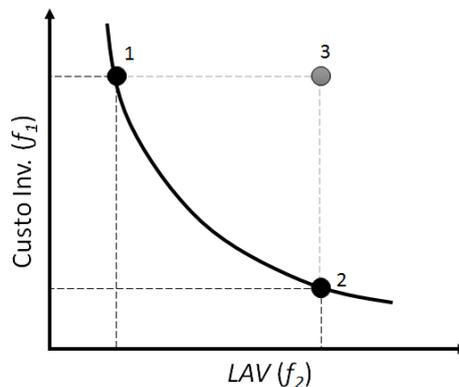


Figura 4.6. Fronteira de Pareto para o problema de planejamento proposto.

Em termos de formulação, as diferenças da abordagem multiobjetivo em relação à mono-objetivo são: (i) na abordagem mono-objetivo, minimiza-se a função global do problema de planejamento dada pela Equação (4.8), enquanto que na abordagem multiobjetivo, define-se f_1 e f_2 , de (4.17.a) e (4.17.b), respectivamente, que devem ser utilizadas para a construção das fronteiras de Pareto, (ii) na abordagem mono-objetivo necessita definir os pesos que relacionam os objetivos, enquanto na abordagem multiobjetivo não há necessidade de definir os pesos. As restrições são as mesmas nas duas abordagens.

4.5 FLUXOGRAMA DA METODOLOGIA DE PLANEJAMENTO PROPOSTA

A Figura 4.7 apresenta a metodologia proposta nesta tese de doutorado para a alocação de equipamentos de medição em SDE, organizada na forma de um fluxograma. Os passos deste fluxograma são descritos na sequência.

Passo 1 (Início):

Inicialização do algoritmo de otimização, envolvendo leitura dos dados do SDE, inicialização dos parâmetros da metodologia de busca *MMS* proposta e geração de uma população inicial de soluções candidatas, envolvendo a alocação de equipamentos de medição - UMF e/ou MI, em barras candidatas da rede elétrica. Cada indivíduo do *MMS* define de forma aleatória o tipo de equipamento (UMF ou MI) e o local (barras do sistema e trechos de corrente) bem com o Custo de Investimento associado ao(s) equipamentos alocados.

Conforme descrito anteriormente, uma solução candidata é codificada através de um número de vetores igual ao número de equipamentos (n_{equip}) diferentes para avaliação, conforme Figura 4.2, e, portanto, para n_{equip} vetores no caso de diferentes modelos comerciais de UMF e/ou MI. A dimensão (L) de cada vetor é dada por $L = (Nb + Nt).n_{equip}$ conforme descrito na explicação da Figura 4.2, em que Nt equivale ao número de trechos do sistema em análise.

Na abordagem multiobjetivo, definem-se ainda o número de objetivos, dois no caso da metodologia proposta, f_1 e f_2 previamente definidas, o número de soluções candidatas n_A que compõem a população de não-dominadas A e o número n_P que compõem a população dominadas P .

Passo 2 (Caso Base):

Cálculo de fluxo de potência, considerando-se as demandas conhecidas, a fim de se obter os valores exatos das variáveis de estado do sistema. Este caso de análise é denominado Caso Base e serve para avaliar a qualidade dos resultados obtidos com o estimador proposto.

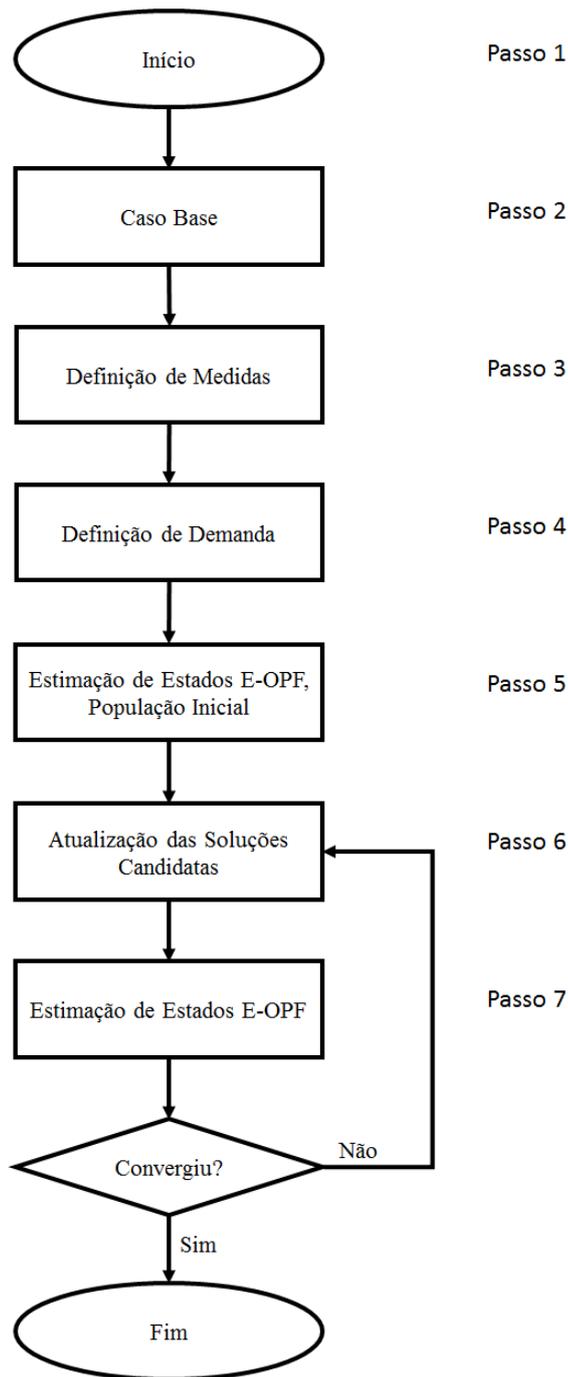


Figura 4.7. Fluxograma da metodologia proposta.

Passo 3 (Definição de Medidas):

Definição das faixas para os erros máximos das medidas fornecidas por cada tipo de monitoramento, relativas a módulo e ângulo de fase de tensão nodal, e módulo de corrente. Neste passo, são definidas as medidas virtuais, ou seja, aquelas associadas a barras de passagem e que têm elevada precisão, com base na topologia do sistema conhecida a partir do Passo 1.

Passo 4 (Definição de Demanda):

Definição das faixas de variação de demanda em cada barra k , $\hat{P}l_{min_k}, \hat{P}l_{max_k}, \hat{Q}l_{min_k}, \hat{Q}l_{max_k}$, devido ao seu comportamento estocástico e, portanto, sujeito a incertezas, conforme formulado em (4.4.d) e (4.4.e). Estas faixas representam a variação máxima verificada a partir de dados históricos de demanda. Portanto, na ausência de tais dados, considera-se para a faixa de demandas uma variação percentual em relação à demanda do Caso Base, conforme modelado a seguir:

$$Pl_{min_k} = (1 - p) \cdot P_{b,k}, \quad Pl_{max_k} = (1 + p) \cdot P_{b,k} \quad (4.18.a)$$

$$Ql_{min_k} = (1 - p) \cdot Q_{b,k}, \quad Ql_{max_k} = (1 + p) \cdot Q_{b,k} \quad (4.18.b)$$

Em que:

- $P_{b,k}$ demanda de potência ativa considerada no Caso Base, para o nível de carga nominal;
- $Q_{b,k}$ demanda de potência reativa considerada no Caso Base, para o nível de carga nominal; e
- p margem percentual predefinida de variação da demanda devido ao seu comportamento estocástico.

Vale lembrar que a margem ‘ p ’ pode ser obtida a partir de dados históricos quando disponíveis. O modelo permite avaliar níveis de carga diferentes do nominal, definidos por um fator multiplicativo α_u , como, por exemplo, carga leve e pesada. Neste caso, a demanda $P_{b,k}$ é multiplicada por α_u . Esta flexibilidade é importante para incorporar a variação da carga ao longo do dia, de acordo com as curvas diárias do sistema, no processo de estimação.

Passo 5 (Estimação de Estados- E-OPF, População Inicial):

No Passo 5, cada elemento do conjunto inicial de soluções candidatas, que define uma solução completa no que se refere à definição dos locais e dos tipos dos equipamentos de monitoramento, é avaliado sob o aspecto de qualidade do estimador de estados. Para tanto, para cada elemento, executa-se o processo de estimação de estados através do modelo de otimização E-OPF proposto, equações (4.4.b)-(4.4.g) e por meio do DEE da equação (4.2), solucionado via MPI primal-dual utilizando a toolbox *fmincon* [114]. Destaca-se que um problema de

otimização (4.4.b)-(4.4.g) é definido e solucionado para cada solução candidata do método de busca *MMS* proposto. Após a convergência do processo de estimação de estados pelo critério de Karush-Kuhn-Tucker via MPI [109], com as medidas fornecidas pelos equipamentos de medição, é possível obter as variáveis de estado $\hat{\theta}_k$ e \hat{V}_k .

Na abordagem mono-objetivo, este Passo 5 permite calcular as parcelas referentes a I_{MVD} e I_{AFD} da função objetivo do problema global de planejamento, equação (4.8). Na abordagem multiobjetivo, por sua vez, este passo permite determinar a função objetivo associada à qualidade do estimador, ou seja, a função f_2 da equação (4.17.b).

Destaca-se que tanto a primeira parcela composta de custos da equação (4.8), na abordagem mono-objetivo, quanto a função f_1 da abordagem multiobjetivo, equação (4.17.a), já são previamente definidas a partir dos equipamentos determinados por cada solução candidata e seus respectivos custos de aquisição, não sendo, portanto, necessário executar o *E-OPF* para obter estas parcelas e função.

Passo 6 (Atualização das Soluções Candidatas):

O conjunto de soluções candidatas inicialmente gerado no Passo 1 evolui segundo os mecanismos de busca do algoritmo *MMS*, sendo, portanto, atualizado após a aplicação destes mecanismos. Em outras palavras, as alocações de UMF e MI inicialmente propostas podem variar neste passo entre as barras candidatas da rede elétrica, no sentido de minimizar a função objetivo do problema global de planejamento, equação (4.8) na abordagem mono-objetivo, ou a função de aptidão da equação (4.16) na abordagem multiobjetivo.

Na abordagem multiobjetivo, a melhor solução candidata não-dominada da árvore inicial do *MMS*, referente à população inicial de soluções candidatas, é determinada com base na função de aptidão da equação (4.16). Esta solução é submetida aos mecanismos de evolução da metaheurística *MMS*, gerando uma quantidade de novas soluções candidatas igual ao número de ramos que cada árvore subsequente apresenta. Detalhes deste mecanismo são descritos no Apêndice A.

A evolução da solução candidata não-dominada através da geração de novas candidatas conforme citado guia-se pela função de aptidão da equação (4.16). Quando uma nova solução candidata gerada apresenta aptidão superior, esta passa ser a solução “raiz” do processo de

busca na próxima iteração do algoritmo. O Apêndice A descreve maiores aspectos sobre a solução “raiz” e suas derivações pelos mecanismos do *MMS*.

Passo 7 (Estimação de Estados- *E-OPF*):

Após a atualização do conjunto de soluções candidatas no Passo 6, em que cada elemento do conjunto define uma solução completa no que se refere à definição dos locais e dos tipos dos equipamentos de monitoramento, executa-se, para cada solução candidata, o processo de estimação de estados através do modelo de otimização *E-OPF* proposto, Equações (4.4.b)-(4.4.g) e via DEE, equação (4.2), solucionado via MPI primal-dual utilizando a toolbox *fmincon*. Destaca-se que um problema de otimização (4.2) e (4.4.b)-(4.4.g) é definido e solucionado para cada solução candidata do método de busca *MMS* proposto.

Após a execução do Passo 7, o critério de convergência do algoritmo de busca *MMS* é verificado. Este critério é descrito no Apêndice A. Caso o mesmo seja atendido, o algoritmo de planejamento é encerrado; caso contrário, retorna ao Passo 6 para a atualização do conjunto de soluções candidatas à alocação de equipamentos de monitoramento (locais e tipos).

Na abordagem multiobjetivo, após a convergência, uma quantidade de soluções não-dominadas e mais distantes de aglomerados, conforme aptidão da equação (4.16), compõem um conjunto de alternativas viáveis de investimento, que aliam os requisitos de custo e qualidade de estimação de estados. Estas soluções são, portanto, fornecidas como uma lista de opções para o planejador, a ser avaliada mediante condições de investimento da empresa de distribuição e necessidades do SDE.

4.6 SISTEMA TUTORIAL

O sistema de 14 barras de [115], amplamente utilizado na literatura em estudos sobre SDE, foi modificado a fim de evidenciar a aplicabilidade da metodologia multiobjetivo proposta, ou seja, a fim de justificar a aplicação de sistemas de monitoramento nesta rede elétrica de pequeno porte, sob a forma de tutorial. O sistema original tem 1 SE, da qual saem três alimentadores, e tensão nominal de 23 kV. Os alimentadores partem das barras de números ‘1’, ‘6’ e ‘11’. A modificação efetuada nesta topologia original consiste na abertura das conexões diretas da SE com as barras ‘6’ e ‘11’, conectando-as de forma radial ao alimentador

que parte pela barra '1'. Ou seja, a modificação inclui a abertura das chaves S_5 e S_{10} . Com isto, a modificação implica em apenas um alimentador, iniciando na barra '1' e atendendo a todo o sistema, conforme ilustrado na Figura 4.8.

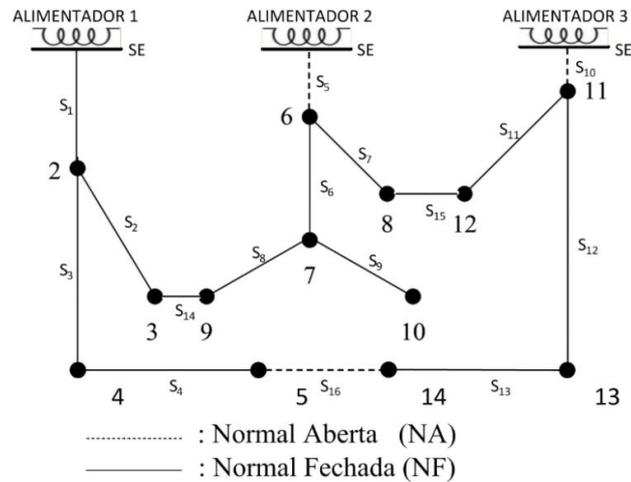


Figura 4.8. Sistema 14 barras modificado.

O Passo 1 efetua a leitura de dados do sistema, conforme disponíveis em [115]. A Tabela 4.1 apresenta os dados de barras deste sistema. Observa-se nesta tabela que não há barras de passagem, ou seja, barras sem demanda, excetuando-se a SE. Logo, não há medidas virtuais nos estudos realizados para este sistema.

Tabela 4.1 – Dados de barras do sistema 14 barras modificado.

Barra	Carga (MW)	Carga (MVar)	Shunt (MVar)
1	0,00	0,00	0,00
2	2,00	1,60	0,00
3	3,00	1,50	1,10
4	2,00	0,80	1,20
5	1,50	1,20	0,00
6	4,00	2,70	0,00
7	5,00	3,00	1,20
8	1,00	0,90	0,00
9	0,60	0,10	0,20
10	4,50	2,00	3,70
11	1,00	0,90	0,00
12	1,00	0,70	1,80
13	1,00	0,90	0,00
14	2,10	1,00	1,80

Este estudo tutorial considera equipamentos de medição comerciais fornecidos diretamente do fabricante, a fim de demonstrar a metodologia proposta para uma situação realista. O fabricante IMS – Soluções para Energia Ltda de CNPJ: 87.723.474/0001-40, forneceu dados de quatro equipamentos para as análises, apresentados na Tabela 4.2.

Tabela 4.2 – Dados dos Equipamentos de Medição IMS.

Nome do Medidor	Classe de Exatidão		Tipo de Medição		Número de Canais		Preço (R\$)
	Tensão	Corrente	Tensão	Corrente	Tensão	Corrente	
PowerNET P-300 G4	0,35%	-	Módulo	-	1	-	4.580,00 ¹
PowerNET P-600 G4	0,20%	1,20%	Módulo	Módulo	1	1	8.895,00 ²
PowerNET PQ-600 G4	0,35%	1,35%	Fasor	Fasor	3	3	15.145,50 ²
PowerNET PQ-700 G4	0,35%	0,35%	Fasor	Fasor	3	16	20.375,00 ²

A Tabela 4.2 inclui, basicamente, dois medidores inteligentes, os equipamentos “PowerNET P-300 G4 (P300)” e “PowerNET P-600 G4 (P600)”, uma vez que medem apenas os módulos de tensão e/ou corrente. A diferença básica entre os mesmos é que o “PowerNET P-300 G4” mede apenas módulo de tensão, enquanto que o modelo “PowerNET P-600 G4” mede tensão e corrente, sendo limitado, entretanto, a apenas um canal de corrente. Deste modo, o algoritmo proposto determina os trechos cujas correntes devem ser monitoradas, dentro do conjunto de trechos possíveis, conforme codificação da Figura 4.2.

As unidades de medição fasorial estão representadas pelos modelos “PowerNET PQ-600 G4 (PQ600)” e “PowerNET PQ-700 G4 (PQ700)”, ambos com capacidade de medição de fasores de tensão e de corrente. A semelhança entre os mesmos consiste em suas classes de precisão da resposta de tensão, praticamente as mesmas. A diferença, porém, está na classe de exatidão das medições de corrente, que diferem em 1,0% entre os dois medidores. Além de mais exato nas medições de corrente, o modelo “PowerNET PQ-700 G4” dispõe de número elevado de canais para medição de corrente, 16 no total, se comparado com o modelo “PowerNET PQ-600 G4”, que tem apenas três canais de corrente.

¹ <<http://ims.ind.br/contato/>>. Acesso em: 09 de outubro de 2017

² <<http://ims.ind.br/contato/>>. Acesso em: 01 de março de 2017

A função objetivo da metodologia proposta, equação (4.8), pode ser reescrita de forma específica para os equipamentos comerciais descritos anteriormente, conforme equação (4.19), em que os MIs são representados pelas variáveis x_{P300k} e x_{P600k} , enquanto que as UMFs são representadas por x_{PQ600k} e x_{PQ700k} .

$$FOB = \text{Min} \left[\gamma \cdot \left(\sum_{k=1}^{Nb} c_{P300k} \cdot x_{P300k} + \sum_{k=1}^{Nb} c_{P600k} \cdot x_{P600k} + \sum_{k=1}^{Nb} c_{PQ600k} \cdot x_{PQ600k} + \sum_{k=1}^{Nb} c_{PQ700k} \cdot x_{PQ700k} \right) + \alpha \cdot I_{MVD} + \beta \cdot I_{AFD} \right] \quad (4.19)$$

Em que:

- c_{P300k}, c_{P600k} , Custos de investimento em P300, P600, PQ600 e PQ700, respectivamente, na barra k ; e
- c_{PQ600k}, c_{PQ700k}
- x_{P300k}, x_{P600k} Variáveis inteiras que representam a opção de investimento em P300, P600, PQ600 e PQ700, respectivamente, na barra k (1 – investimento, 0 – investimento não indicado).
- x_{PQ600k}, x_{PQ700k}

Nesse passo, também é avaliado o *E-OPF* para o caso com alocação de uma UMF na SE, conforme equação (4.19), para critérios de avaliação das soluções que serão posteriormente analisadas no plano de investimento. Para o sistema de 14 barras modificado tem-se o valor da $FOB = 13,5337$ dados diretamente pelos índices em *LAV* (segunda parte da equação (4.19)) visto que o Custo de Investimento é igual a zero.

Ainda no Passo 1, são definidos os parâmetros do algoritmo *MMS* proposto para aplicação ao problema de planejamento de sistemas de medição. Esses parâmetros são:

- altura de uma árvore $h = 4$, totalizando $c = 16$ caminhos (ou indivíduos) conforme equação (A.1) do Apêndice A;
- tolerância para a convergência global “0”;
- número máximo de árvores (nt_{max}) igual a “20”; e
- tamanho da memória adaptativa $memo = “8”$, equação (A.2) do Apêndice A.

Maiores detalhes do algoritmo *MMS* podem ser encontrados no Apêndice A desta tese. De acordo com este algoritmo, a população inicial tem 16 soluções candidatas aleatórias, quantidade dada em função do número de caminhos $c = 16$. A Tabela 4.3 apresenta os dados desta população, incluindo as barras terminais dos equipamentos, os trechos de corrente

monitorados, os valores correspondes aos somatórios das duas últimas parcelas da função objetivo da equação (4.19) -LAV, e os custos de investimento associados.

Tabela 4.3 – Dados da população inicial do *MMS*, sistema tutorial.

Solução Candidata	Barras Terminais				Trechos monitorados				LAV	Custo Inv. (R\$)
	P300	P600	PQ600	PQ700	P300	P600	PQ600	PQ700		
1	4, 8, 14	-	-	2, 11, 13	-	-	-	S ₁ , S ₂ , S ₃ , S ₁₁ , S ₁₂ , S ₁₃	1,5251	74.865,00
2	-	2, 5, 9	3	4, 13	-	S ₂ , S ₈	S ₁₄	S ₃ , S ₄ , S ₁₂ , S ₁₃	0,7881	82.580,00
3	9	-	6	-	-	-	S ₆ , S ₇	-	2,2887	19.725,00
4	3, 13	-	6, 9, 11	2, 4, 5	-	-	S ₆ , S ₇ , S ₈ , S ₁₁ , S ₁₂ , S ₁₄	S ₁ , S ₂ , S ₃ , S ₄	0,7908	115.720,00
5	10	2, 6, 8	3, 4	5, 13	-	S ₂ , S ₆ , S ₇	S ₃ , S ₁₄	S ₄ , S ₁₂ , S ₁₃	0,7670	102.305,00
6	4	-	8, 9, 13	3, 7, 14	-	-	S ₇ , S ₁₂ , S ₁₅	S ₂ , S ₆ , S ₈ , S ₉ , S ₁₃ , S ₁₄	1,0733	111.140,00
7	7	4, 6, 9	3, 5	2, 10	-	S ₄ , S ₆ , S ₁₄	-	S ₁ , S ₂ , S ₃ , S ₉	2,8086	102.305,00
8	12, 13, 14	6, 9, 11	-	2, 3	-	S ₇ , S ₈ , S ₁₁	-	S ₁ , S ₂ , S ₃ , S ₁₄	1,3211	81.175,00
9	4, 10	-	5, 6, 13	-	-	-	S ₄ , S ₆ , S ₇ , S ₁₂ , S ₁₃	-	1,1326	54.595,00
10	2, 4, 7	9	-	8, 10, 12	-	S ₈	-	S ₇ , S ₉ , S ₁₁ , S ₁₅	0,9010	83.760,00
11	-	-	-	6, 7, 13	-	-	-	S ₆ , S ₇ , S ₈ , S ₉ , S ₁₂ , S ₁₃	1,5041	61.125,00
12	3, 7, 12	2, 4	-	-	-	S ₁ , S ₄	-	-	3,041	31.530,00
13	8	2	-	-	-	S ₂	-	-	2,8302	13.475,00
14	6, 8, 11	-	4, 7, 13	-	-	-	S ₃ , S ₄ , S ₆ , S ₈ , S ₉ , S ₁₂ , S ₁₃	-	0,7521	59.175,00
15	3, 9, 10	-	8, 11, 14	4, 7	-	-	S ₇ , S ₁₁ , S ₁₂ , S ₁₃ , S ₁₅	S ₃ , S ₄ , S ₆ , S ₈ , S ₉	0,6692	99.925,00
16	2, 8, 9	5, 11	6, 10, -	7	-	S ₄ , S ₁₁	-	S ₆ , S ₈ , S ₉	0,7560	82.195,00

Quanto aos parâmetros para aplicação do método de Pareto, as dimensões das matrizes *P*, de soluções candidatas dominadas, e *A*, de soluções não-dominadas, conforme descrito anteriormente, são $m \times L$, em que $m = c / 2 = 8$ neste caso, conforme codificação do *MMS* apresentada na Figura 4.2. Neste caso, $L = (Nb + Nt) * n_{equip} = (14 + 13) * 4 = 108$. Maiores detalhes do algoritmo *MMS* são fornecidos no Apêndice A. A matriz *A* inicia-se vazia enquanto que a matriz *P* armazena as soluções da Tabela 4.3, porém codificadas conforme Figura 4.2.

No Passo 2, executa-se o fluxo de carga convencional via método de Newton-Raphson para determinar o estado da rede elétrica, sob a condição de carga associada aos dados reais da Tabela 4.1. O resultado do FPC é apresentado na Tabela 4.4, em que o módulo de tensão e o

ângulo de fase na subestação são fixados em 1,0 pu e 0°, respectivamente. As correntes nos trechos correspondentes a este estado via FPC são apresentadas na Tabela 4.5.

Tabela 4.4 – Resultado do fluxo de potência, sistema 14 barras.

Barra	Tensão (pu-kV)	Ângulo (Graus)
1	1,000000	0,000000
2	0,954415	-0,960773
3	0,914188	-1,942118
4	0,947273	-1,246051
5	0,946131	-1,253722
6	0,837372	-3,205409
7	0,856787	-2,768760
8	0,823107	-3,359254
9	0,898635	-2,162634
10	0,849954	-3,032332
11	0,810076	-3,620401
12	0,818844	-3,413063
13	0,804383	-3,786676
14	0,802838	-3,825714

Tabela 4.5 – Valores de correntes, sistema 14 barras.

Barra De (<i>k</i>)	Barra Para (<i>m</i>)	Corrente I_{km} (pu-A)
1	2	0,387514
2	3	0,318289
3	9	0,042579
2	4	0,020303
4	5	0,150423
7	9	0,092816
6	7	0,275544
7	10	0,057938
6	8	0,061671
12	8	0,045259
11	12	0,028971
11	13	0,281772
13	14	0,076578

No Passo 3, as medidas são definidas, conforme dados dos equipamentos apresentados na Tabela 4.2. Para este sistema, não há medidas virtuais, conforme citado anteriormente.

No Passo 4, os dados de demanda associados às pseudo-medidas são definidos. Para tanto, considera-se as pseudo-medidas com uma imprecisão de 50%, ou seja, a faixa de demanda é definida pelo parâmetro $p = 0,5$ das equações (4.18.a) e (4.18.b) para potência ativa e reativa, respectivamente. Assim, tem-se $\hat{P}l_{min k} = (1 - 0,5) \cdot P_{b,k} = 0,5 \cdot P_{b,k}$ e $\hat{P}l_{max k} = (1 + 0,5) \cdot P_{b,k} = 1,5 \cdot P_{b,k}$ para os limites de potência ativa, e os limites de potência reativa dados por $\hat{Q}l_{min k} = (1 - 0,5) \cdot Q_{b,k} = 0,5 \cdot Q_{b,k}$ e $\hat{Q}l_{max k} = (1 + 0,5) \cdot Q_{b,k} = 1,5 \cdot Q_{b,k}$. Vale ressaltar, que as potências de carga também representam variáveis a serem estimadas dentro do problema de otimização do *E-OPF*, determinadas dentro dos limites pré-estabelecidos acima.

O Passo 5 avalia a população P inicial, permitindo determinar os valores da coluna *LAV* da Tabela 4.3 através da execução do novo método de estimação de estados *E-OPF* proposto para cada solução candidata desta tabela, bem como da coluna “Custo Inv.”, a partir dos custos unitários de cada medidor e das decisões de aquisição de cada solução candidata.

A partir desta avaliação, o método de Pareto considera $f_1 = LAV$ e $f_2 = \text{“Custo Inv.”}$ para definir as soluções não-dominadas e dominadas, utilizando para tanto os critérios descritos anteriormente. Além disto, a aptidão formulada na equação (4.16) é determinada para cada solução candidata da Tabela 4.3, bem como as respectivas fronteiras de Pareto (*rank*) ilustradas na Figura 4.9. A Tabela 4.6 apresenta a fronteira ou *rank* de cada solução candidata da Tabela 4.3, com destaque para as soluções incluídas na matriz A conforme descrito na sequência.

Tabela 4.6 – Fronteiras das soluções da população inicial, sistema 14 barras.

Solução Candidata	LAV	Custo Inv. (R\$)	Rank	Distância
1	1,5251	74.865,00	3	$6,00*10^{10}$
2	0,7881	82.580,00	3	$6,00*10^{00}$
3	2,2887	19.725,00	1	$6,31*10^{00}$
4	0,7908	115.720,00	4	$4,00*10^{10}$
5	0,7670	102.305,00	3	$6,00*10^{10}$
6	1,0733	111.140,00	5	$4,00*10^{10}$
7	2,8086	102.305,00	5	$4,00*10^{10}$
8	1,3211	72.175,00	2	$2,97*10^{00}$
9	1,1326	54.595,00	1	$5,83*10^{00}$
10	0,9010	83.760,00	4	$4,00*10^{10}$
11	1,5041	61.125,00	2	$6,93*10^{10}$
12	3,0410	31.530,00	2	$8,00*10^{10}$
13	2,8302	13.475,00	1	$1,00*10^{11}$
14	0,7521	59.175,00	1	$3,69*10^{00}$
15	0,6692	99.925,00	1	$1,00*10^{11}$
16	0,7560	82.195,00	2	$8,00*10^{10}$

Daí, forma-se a matriz A , buscando preenchê-la com as soluções candidatas não-dominadas, conforme fundamento teórico do método proposto, porém, observando-se as seguintes situações:

- (i). Se o número de soluções candidatas da primeira fronteira de Pareto, cujo $rank=1$, for maior que o número de soluções candidatas que a matriz A deve receber, neste caso, $c/2 = 8$, avalia-se a distância do aglomerado da primeira fronteira, priorizando aquelas com as maiores distâncias;
- (ii). Se o número de soluções candidatas da primeira fronteira for igual ao número de candidatas que a matriz A deve receber, então A recebe todas as soluções da primeira fronteira;

- (iii). Se o número de soluções candidatas da primeira fronteira for menor que o número de candidatas que a matriz A deve receber, o restante de A é preenchido pelas soluções candidatas da segunda fronteira seguindo o critério de prioridade da maior distância do respectivo aglomerado, e assim por diante.

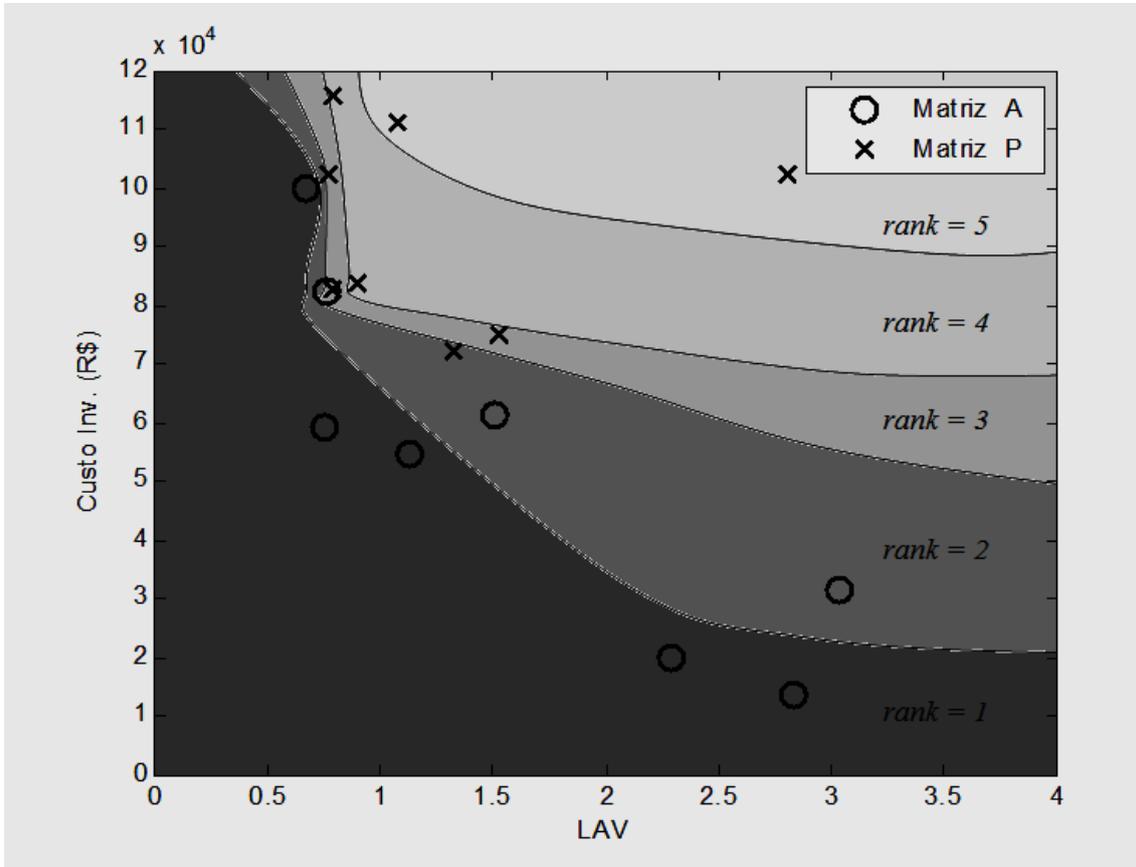


Figura 4.9 – Fronteiras de Pareto para a população inicial, sistema 14 barras.

Para a população inicial da Figura 4.9, a situação descrita no item (iii) é utilizada, pois apenas cinco de suas soluções candidatas são não-dominadas. Portanto, como A deve receber oito soluções neste caso, três soluções candidatas da segunda fronteira são selecionadas, o que é possível uma vez que há quatro candidatas com $rank = 2$, conforme Tabela 4.6. Nesta tabela, pode-se observar que as soluções da segunda fronteira selecionadas para compor A são as que apresentam a maior distância entre as quatro com $rank = 2$.

A Tabela 4.7 apresenta os valores da função de aptidão, formulada na equação (4.16), para as soluções candidatas incluídas na matriz A .

Tabela 4.7 – Matriz A com as funções de aptidão, sistema 14 barras.

Barras Terminais				LAV	Custo Inv. (R\$)	Aptidão
P300	P600	PQ600	PQ700			
9	-	6	-	2,2887	19.725,00	4,14*10 ⁴
4, 10	-	5, 6, 13	-	1,1326	54.595,00	3,49*10 ⁴
-	-	-	6, 7, 13	1,5041	61.125,00	2,00*10 ⁻¹
3, 7, 12	2, 4	-	-	3,0410	31.530,00	2,00*10 ⁻¹
8	2	-	-	2,8302	13.475,00	4,77*10 ⁴
6, 8, 11	-	4, 7, 13	-	0,7521	59.175,00	3,95*10 ⁴
3, 9, 10	-	8, 11, 14	4, 7	0,6692	99.925,00	6,84*10⁴
2, 8, 9	5, 11	6, 10	7	0,7560	82.195,00	2,00*10 ⁻¹

O Passo 6 efetua a atualização das soluções candidatas seguindo os mecanismos evolutivos do método *MMS*. Para tanto, deve-se selecionar a melhor candidata, ou “*ibest*”, da matriz A da Tabela 4.7, associada ao maior valor de aptidão, conforme destacado. Daí, o *MMS* evolui a solução “*ibest*” por meio de variações aleatórias pontuais nas respectivas decisões de alocação. A população resultante desta evolução denomina-se “árvore” subsequente e tem o mesmo número de caminhos da “árvore” inicial, ou seja, 16 para este tutorial. Ou seja, a partir do “*ibest*”, 16 novas soluções candidatas são geradas. Maiores detalhes deste mecanismo evolutivo são dados no Apêndice A.

No Passo 7, o método de estimação de estados *E-OPF* é executado para avaliar o índice composto *LAV* das soluções da nova população ou “árvore” subsequente. Os custos de investimento relativos à nova população também são definidos a partir das novas decisões de alocação.

Na sequência, o critério de convergência do *MMS* é verificado, dado pelo número de “árvores” igual a 20. Caso esta convergência seja alcançada, o algoritmo é encerrado; caso contrário, o algoritmo retorna ao Passo 6 para uma nova evolução populacional. Considerando os 16 caminhos ou alterações pontuais em cada “árvore”, um total de 320 soluções candidatas é investigado até a convergência.

Um detalhe sobre a execução do algoritmo *MMS* é que a solução com melhor aptidão de uma “árvore” subsequente é comparada com a solução “*ibest*” corrente e substitui esta solução no caso de apresentar melhoria em relação à mesma. Caso contrário, a solução “*ibest*” permanece a mesma e novas variações aleatórias são realizadas para uma nova evolução.

A Figura 4.10 apresenta a primeira fronteira de Pareto obtida após a convergência para este caso tutorial, cujas soluções são detalhadas na Tabela 4.8. Estas soluções são de boa qualidade por pertencerem à primeira fronteira e, portanto, podem ser consideradas como opções para o planejamento, cuja decisão final deve ser assistida pelo planejador à luz de prioridades, necessidades e requisitos operacionais da empresa de distribuição.

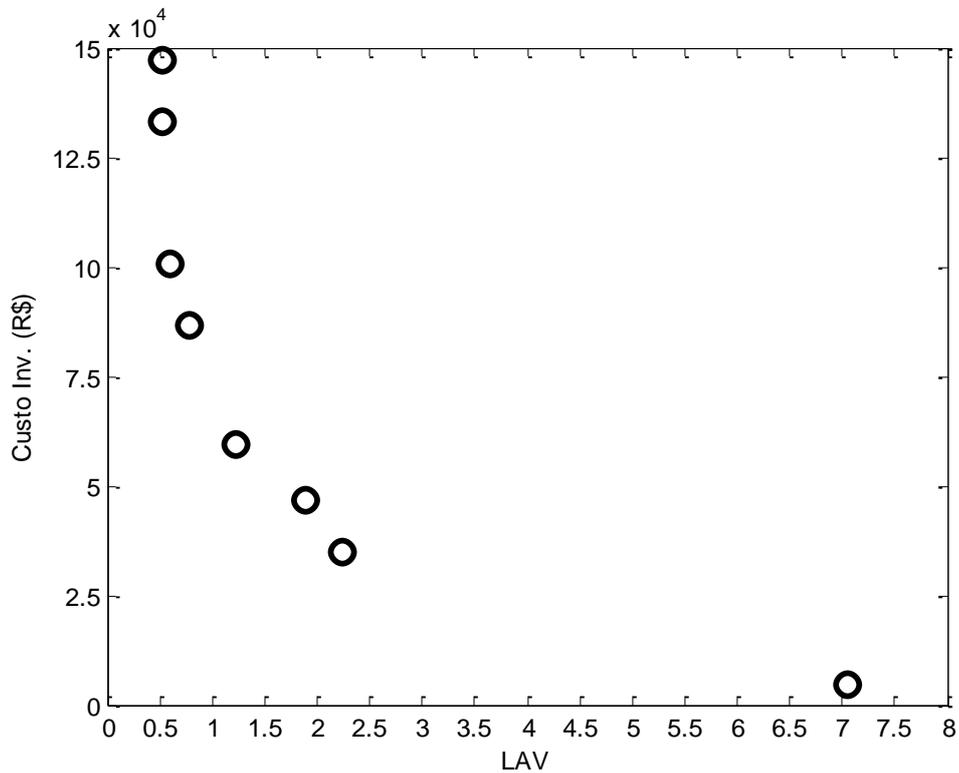


Figura 4.10 – Primeira fronteira de Pareto após a convergência do *MMS*, sistema 14 barras.

Tabela 4.8 – Matriz de Planejamento, sistema 14 barras.

Solução		1	2	3	4	5	6	7	8
Barra Terminal	P300	3, 6, 13	-	3, 11	3, 6	-	3, 6, 11	3	9
	P600	5, 10, 12	5, 10, 12	-	5, 10, 12	12	5, 12	-	-
	PQ600	8, 11, 14	8, 9, 14	8, 14	8, 14	3, 8	10	8, 14	-
	PQ700	2, 4, 7	2, 4, 7	2, 4, 7	2	7	-	-	-
Trechos Monitorados (corrente)	P300	-	-	-	-	-	-	-	-
	P600	S ₁₁	S ₁₁	-	S ₄ , S ₉ , S ₁₁	S ₁₅	S ₄ , S ₁₅	-	-
	PQ600	S ₇ , S ₁₂ , S ₁₃ , S ₁₅	S ₇ , S ₁₃ , S ₁₄ , S ₁₅	S ₇ , S ₁₃ , S ₁₅	S ₇ , S ₁₃ , S ₁₅	S ₂ , S ₇ , S ₁₄	S ₉	S ₇ , S ₁₃ , S ₁₅	-
	PQ700	S ₁ , S ₂ , S ₃ , S ₄ , S ₆ , S ₈ , S ₉	S ₁ , S ₂ , S ₃ , S ₄ , S ₆ , S ₈ , S ₉	S ₁ , S ₂ , S ₃ , S ₄ , S ₆ , S ₈ , S ₉	S ₁ , S ₂ , S ₃	S ₆ , S ₈ , S ₉	-	-	-
LAV	0,5206 (96%)	0,5274 (96%)	0,5925 (96%)	0,7797 (94%)	1,2309 (91%)	1,8907 (86%)	2,2457 (83%)	7,0522 (48%)	
Custo Inv. (R\$)	146.985,00	133.245,00	100.575,00	86.510,00	59.560,00	46.675,00	34.870,00	4.580,00	
Rank	1	1	1	1	1	1	1	1	

4.7 CONSIDERAÇÕES FINAIS

Este capítulo apresentou a metodologia proposta na presente tese de doutorado, para o planejamento de sistemas de monitoramento, envolvendo UMF e MI em redes de distribuição de energia elétrica. A função objetivo e as restrições do modelo global de planejamento foram formuladas e descritas, envolvendo dois objetivos conflitantes. Anteriormente, o novo modelo de estimação de estados baseado em um FPO modificado, *E-OPF*, foi apresentado, pois este é necessário para a avaliação de soluções candidatas na metodologia de planejamento proposta. Duas abordagens são propostas nesta tese, uma mono-objetivo envolvendo pesos para os dois objetivos conflitantes existentes, e outra multiobjetivo baseada na aplicação do método de Pareto. Ambas são organizadas na forma de fluxogramas com passo a passo de aplicação.

5 VALIDAÇÃO DO NOVO MODELO DE ESTIMAÇÃO DE ESTADOS

5.1 CONSIDERAÇÕES INICIAIS

A metodologia proposta para o planejamento de sistemas de monitoramento em SDE requer um passo de estimação de estado da rede elétrica para a avaliação de soluções candidatas sob o enfoque da qualidade do estimador, associada a uma métrica de erro proposta entre os valores verdadeiros e estimados. Neste contexto, um novo método de estimação de estados - *E-OPF* é proposto nesta tese, baseado em um modelo de otimização não linear, adequado para SDE por permitir considerar variações topológicas de rede com tempo de processamento adequado e sem exigir dados precisos da carga. Em outras palavras, o método proposto permite estimar o estado de uma rede de distribuição em condições insuficientes de redundância de medição, com facilidade de convergência e erro de estimação mínimo, o que o torna adequado para SDE.

Este capítulo apresenta os resultados obtidos a partir da aplicação do método proposto de estimação de estados a sistemas de distribuição da literatura. Os estudos consideram medições nas subestações (SE), medidas virtuais, pseudo-medidas ou dados históricos e medidas provenientes de unidades de medição fasoriais, envolvendo variações de erros de medição.

A validação do modelo matemático de estimação de estados *E-OPF* é feita com base nos valores reais correspondentes a cada estimativa, obtidos a partir do cálculo de Fluxo de Potência Convencional (FPC) para condição de pico de carga. Portanto, os resultados do FPC são considerados valores reais para avaliar o *E-OPF* na condição de pico de demanda. As faixas de variação das variáveis de otimização relativas a módulo de tensão dependem da topologia do sistema podendo variar a faixa o que significa maior incerteza ao problema.

O modelo de rede elétrica monofásico não-linear é considerado nos testes realizados. Embora as cargas de um SDE sejam desequilibradas, os testes com um modelo monofásico podem mostrar a eficácia do método proposto no problema de estimação de estados. No entanto, o *E-OPF* pode ser estendido para redes desequilibradas sem exigir valores de potências precisos ou em tempo real por fase, mas apenas dados históricos com incerteza significativa. Nos estudos

de caso apresentados, considera-se a incerteza definida pelo intervalo de -40% a + 40% para todas as potências de carga.

Adicionalmente, para fins de validação do *E-OPF* proposto, os resultados obtidos pelo novo método são comparados, nas mesmas condições de cada simulação, com os provenientes de outra técnica já consolidada para estimação de estados na literatura, o método *Weight Least Square*, desenvolvido nesta tese com este propósito.

A influência da localização de sistemas de medição é avaliada através de uma técnica de Busca Exaustiva (BE) para alocação, associada ao *E-OPF*, envolvendo UMF como opção de investimento. Nesta avaliação, a função objetivo do *E-OPF*, equação (4.4.a), é calculada para diferentes localizações de medição.

Os estudos envolvem dois sistemas, de 14 [115] e 33 barras [116], bem difundidos na literatura em pesquisas sobre SDE. O modelo *E-OPF* é simulado utilizando-se a toolbox *fmincon* [114] do MATLAB®, versão R2013a. O método *WLS* também é desenvolvido e simulado nesta versão do MATLAB®. As simulações são realizadas em um processador Intel Core I7-2600 de 3,40 GHz com RAM de 4,00 GHz.

5.2 SISTEMA DE 14 BARRAS

Primeiramente, o sistema de 14 barras de [115] modificado conforme Figura 4.8 é utilizado a fim de evidenciar a aplicabilidade do método de estimação de estados proposto. O estado da rede elétrica para a condição de carga associada aos dados reais da Tabela 4.1, obtido por cálculo exato de FPC via método de Newton-Raphson, é apresentado na Tabela 4.4, e as correntes nos trechos correspondentes a este estado são apresentadas na Tabela 4.5.

Neste estudo, os limites das variáveis de demanda, $\hat{P}l_{min_k}$, $\hat{P}l_{max_k}$, $\hat{Q}l_{min_k}$, $\hat{Q}l_{max_k}$ são definidos por uma margem de variação de 40% em relação aos dados de $P_{b,k}$ e $Q_{b,k}$ para cada barra k apresentadas na Tabela 4.1. Em outras palavras, a margem percentual de variação da demanda neste caso é predefinida como parâmetro $p = 0,4$ (40%), permitindo calcular os limites $Pl_{min_k} = 0,6P_{b,k}$, $Pl_{max_k} = 1,4P_{b,k}$, $Ql_{min_k} = 0,6Q_{b,k}$ e $Ql_{max_k} = 1,4Q_{b,k}$. Admite-se para o estudo que esta variação corresponda ao comportamento observado a partir de dados históricos para o sistema em questão.

A Tabela 5.1 apresenta as faixas de variação das variáveis de demanda em cada barra, P_{bk} e Q_{bk} , neste caso, de acordo com a margem de 40%. A Figura 5.1 apresenta as curvas de demandas de potência ativa por barra do Caso Base, juntamente com os respectivos valores mínimos e máximos para $p = 0,4$.

Tabela 5.1 – Limites de demanda.

Barra	$(P_{bk}(\text{MW}); Q_{bk}(\text{MVar}))$	$P_{l_{\min k}} \leq P_{bk} \leq P_{l_{\max k}} (\text{MW})$	$Q_{l_{\min k}} \leq Q_{bk} \leq Q_{l_{\max k}} (\text{MVar})$
2	(2,00 ; 1,60)	$1,20 \leq P_{x2} \leq 2,80$	$0,96 \leq Q_{x2} \leq 2,24$
3	(3,00 ; 1,50)	$1,80 \leq P_{x3} \leq 4,20$	$0,90 \leq Q_{x3} \leq 2,10$
4	(2,00 ; 0,80)	$1,20 \leq P_{x4} \leq 2,80$	$0,48 \leq Q_{x4} \leq 1,12$
5	(1,50 ; 1,20)	$0,90 \leq P_{x5} \leq 2,10$	$0,72 \leq Q_{x5} \leq 1,68$
6	(4,00 ; 2,70)	$2,40 \leq P_{x6} \leq 5,60$	$1,62 \leq Q_{x6} \leq 3,78$
7	(5,00 ; 3,00)	$3,00 \leq P_{x7} \leq 7,00$	$1,80 \leq Q_{x7} \leq 4,20$
8	(1,00 ; 0,90)	$0,60 \leq P_{x8} \leq 1,40$	$0,54 \leq Q_{x8} \leq 1,26$
9	(0,60 ; 0,10)	$0,36 \leq P_{x9} \leq 0,84$	$0,06 \leq Q_{x9} \leq 0,14$
10	(4,50 ; 2,00)	$2,70 \leq P_{x10} \leq 6,30$	$1,20 \leq Q_{x10} \leq 2,80$
11	(1,00 ; 0,90)	$0,60 \leq P_{x11} \leq 1,40$	$0,54 \leq Q_{x11} \leq 1,26$
12	(1,00 ; 0,70)	$0,60 \leq P_{x12} \leq 1,40$	$0,42 \leq Q_{x12} \leq 0,98$
13	(1,00 ; 0,90)	$0,60 \leq P_{x13} \leq 1,40$	$0,54 \leq Q_{x13} \leq 1,26$
14	(2,10 ; 1,00)	$1,26 \leq P_{x14} \leq 2,94$	$0,60 \leq Q_{x14} \leq 1,40$

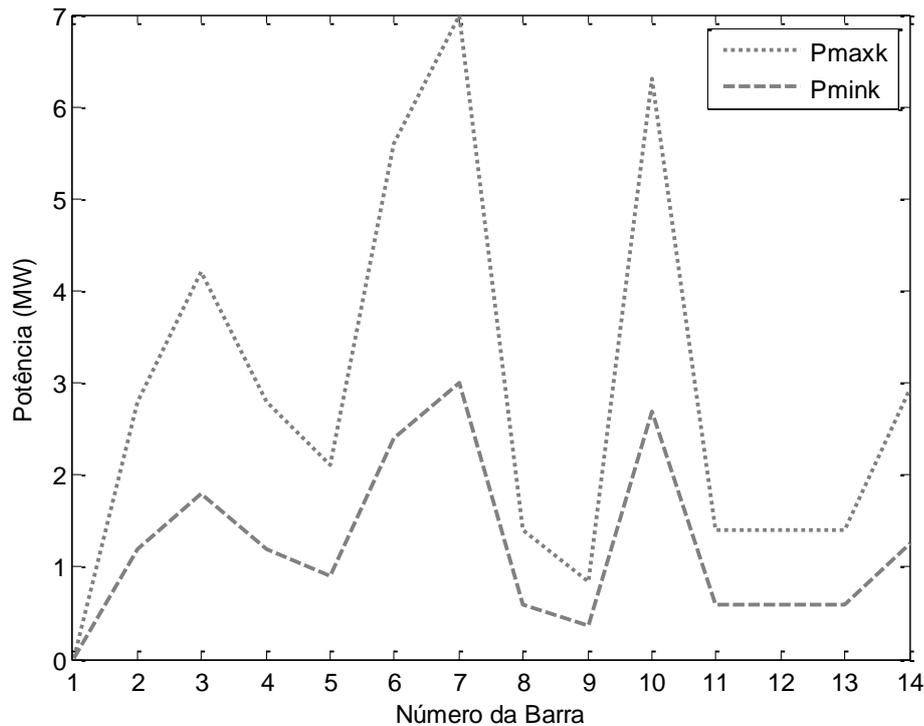


Figura 5.1. Demandas de potência ativa.

Algumas condições são consideradas para este sistema nas simulações realizadas:

- i) Condição 1 - apenas uma UMF na SE;
- ii) Condição 2 - múltiplas UMFs no sistema; e
- iii) Condição 3 - múltiplas configurações de rede.

5.2.1 Sistema 14 barras, Condição 1

Nesta condição, considera-se uma UMF na SE, com a disponibilidade de medidas de módulo de tensão, ângulo de fase e corrente no trecho adjacente, ou seja, o vetor de medidas $x^* = \{V_1^*, \theta_1^*, I_{12}^*\}$, com erros variáveis de $\pm 0,4\%$ para o módulo de tensão e ângulo de fase, e de $\pm 0,8\%$ para o módulo de corrente. Estes erros foram definidos com base na literatura [74]. Vale salientar que o fato de possuir uma UMF na SE serve com base de referência angular, no caso, $\theta_1^* = 0$. Além destas medidas, as pseudo-medidas relativas aos dados históricos de potência ativa e reativa das cargas do sistema também são consideradas com erros de $\pm 40,0\%$. Os valores referentes às demandas de cargas ativas e reativas são sorteados de forma aleatória, dentro da faixa de $\pm 40,0\%$ como observado pela Figura 5.1, ou seja, a demanda real não encontra-se no meio do intervalo. A demanda do Caso Base, servirá apenas para avaliar o desempenho do método obtida, através de um ponto aleatório de operação (P_{bk}), dentro do intervalo histórico definido pelos limites (Pl_{maxk} e Pl_{mink}) conforme pode ser exemplificado na Figura 5.2.

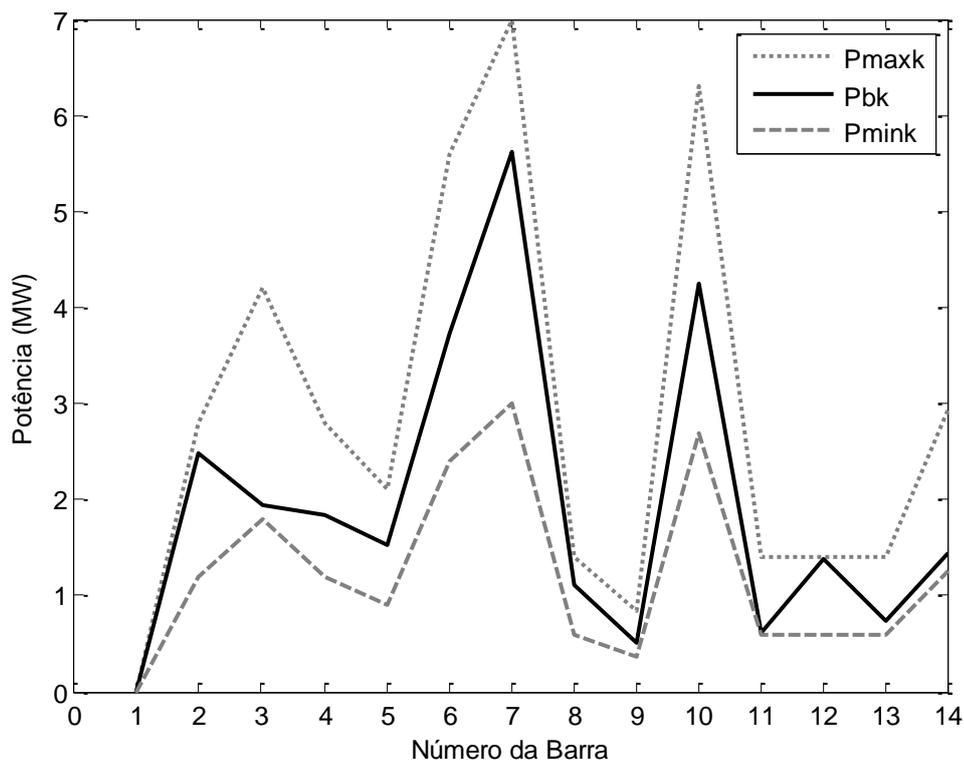


Figura 5.2. Demanda Aleatória Ativa do Caso Base Sistema 14 barras.

Como os erros são variáveis nas faixas definidas anteriormente, um total de 100 simulações do método proposto *E-OPF* e do método *WLS* da literatura foi realizado, a fim de avaliar a robustez do estimador mediante erros aleatórios para tensão e corrente dentro de suas respectivas faixas. Para comparar os dois métodos dentro das mesmas condições, a modelagem para o *WLS* consistiu em incorporar os valores das demandas aleatórias do processo de inicialização do *E-OPF*, como medidas para o *WLS* em cada uma das cem simulações analisadas para o processo de estimação de estados. Assim, para o *E-OPF* as demandas funcionam como variáveis de otimização do fluxo de potência ótimo, enquanto que esses mesmos valores são variáveis de medição para o *WLS*. O peso referente a essas medidas é dado pelo inverso do erro ao quadrado, ou seja, a covariância (σ^{-2}), sendo o erro dessas medidas dado por 40%.

A Tabela 5.2 apresenta os valores máximo, mínimo e médio da FOB definida pela associação do DEE e o LAV, equação (4.4.a), obtidos nestas simulações. A Figura 5.3 apresenta

um comparativo da *FOB* nas 100 simulações para cada método. Os tempos médios requeridos pelo *E-OPF* e pelo *WLS* foram de 1,04 segundos e 0,15 segundos, respectivamente.

Tabela 5.2 – Variações *FOB*, sistema 14 barras, Condição 1.

Valores da <i>FOB</i>	<i>E-OPF</i>	<i>WLS</i>
Máximo	8,9217	26,2260
Mínimo	2,1345	2,2521
Média	5,3092	10,4104

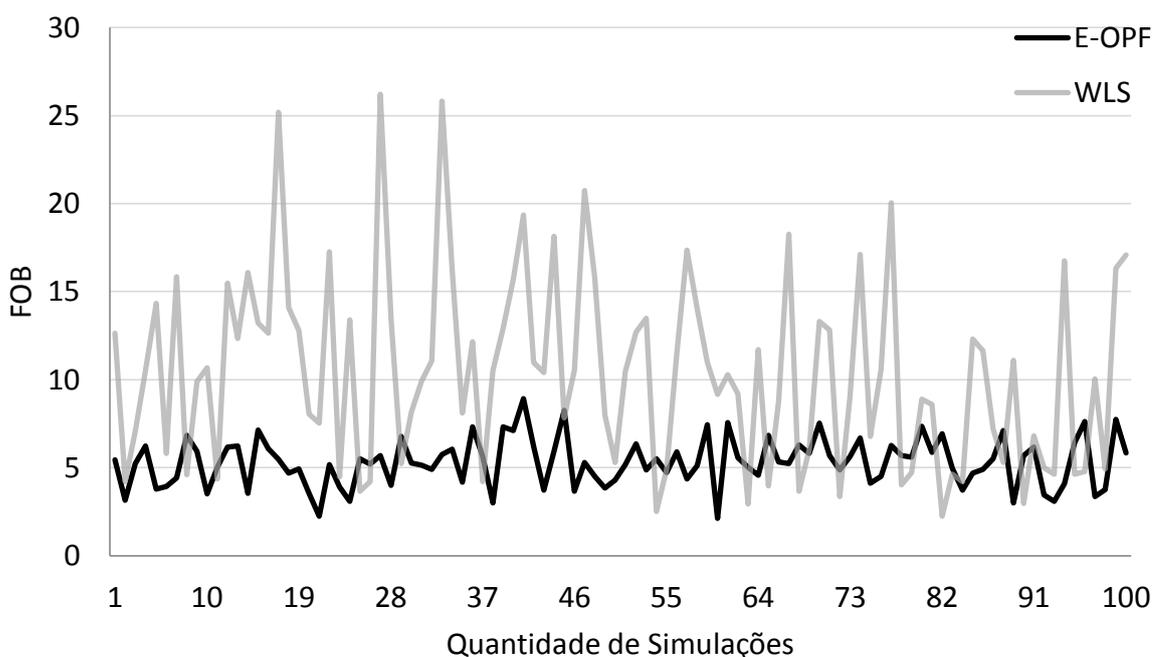


Figura 5.3. *FOB*, sistema 14 barras, Condição 1.

Observa-se na Tabela 5.2 que o *E-OPF* obteve uma faixa de variação de *FOB* inferior à faixa obtida pelo *WLS* e, portanto, maior robustez neste caso, demonstrando sua adequação ao processo de estimação de estados decorrente do tratamento de erros significativos inerentes às pseudo-medidas.

A Figura 5.4 e Figura 5.5 apresentam os módulos de tensão e ângulo de fase por barra, respectivamente, obtidos pelo FPC (valores reais) e estimados pelo *E-OPF* e *WLS*. Embora o *E-OPF* alcance a convergência, pode-se observar um desvio entre os valores estimados e reais, principalmente em pontos distantes do ponto medido, ou seja, da SE, devido à baixa condição

de redundância de medição. No entanto, os valores estimados pelo *E-OPF* são mais próximos dos valores exatos provenientes do FPC em relação ao estimador *WLS*, o que demonstra a eficácia do método proposto. Conforme descrito anteriormente, isto ocorre porque o *E-OPF* pode lidar com a falta de medidas de forma eficiente usando dados históricos, uma vez que não requer informações precisas para estimar o estado da rede. Para melhorar o desempenho da estimativa, é necessário aumentar o número de medidas, embora o resultado demonstre que o *E-OPF* pode ser aplicado a redes parcialmente observáveis.

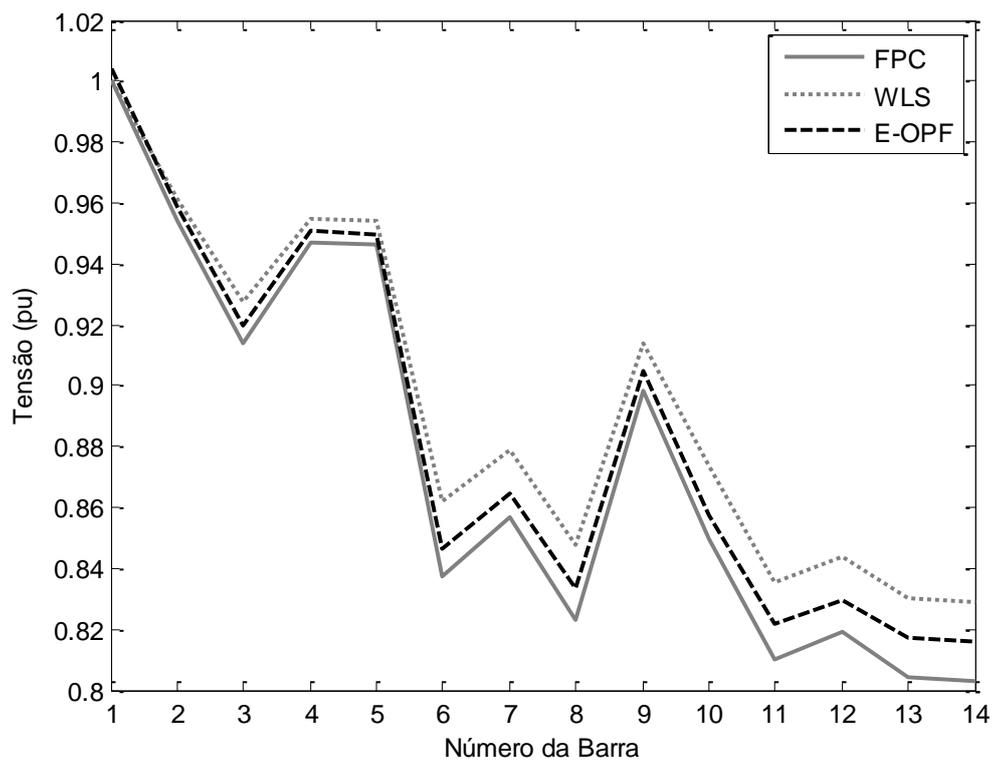


Figura 5.4. Valores reais e estimados de módulo de tensão, 14 barras, Condição 1.

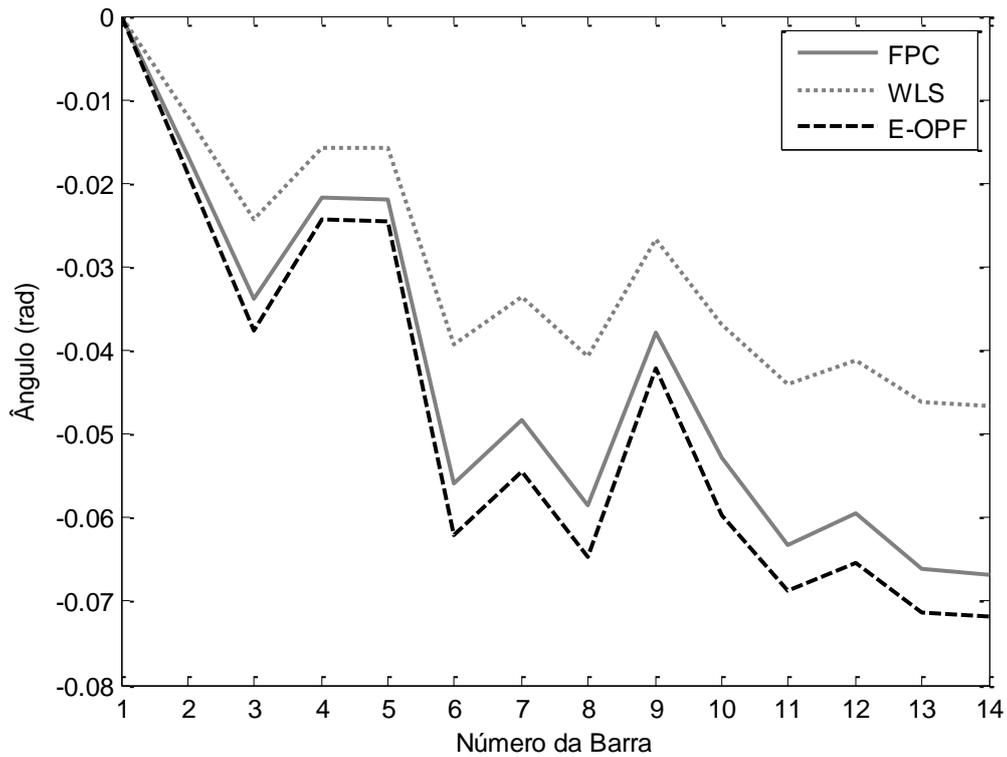


Figura 5.5. Valores reais e estimados de ângulo de fase, 14 barras, Condição 1.

Além da análise gráfica de desempenho, a Tabela 5.3 apresenta os resultados para os índices de estimação da *FOB*, bem como o valor da *FOB*, para os métodos *E-OPF* e *WLS*, onde se pode observar que o *E-OPF* fornece, neste caso, uma estimativa melhor em comparação com o *WLS*. Destaca-se que o índice I_{AFD} é dado em “crad” ($1 \text{ crad} = 10^{-2} \text{ rad}$), por ser uma unidade numericamente mais adequada para comparação [77].

Tabela 5.3 – Resultados, sistema 14 barras, Condição 1.

Estimador	DEE (%)	$IMVD$ (%)	I_{AFD} (crad)	FOB
<i>E-OPF</i>	3,698760	1,594807	0,671878	5,965445
<i>WLS</i>	9,148898	3,233857	2,018977	14,401731

5.2.2 Sistema 14 barras, Condição 2

Esta condição considera a adição de até quatro unidades de medição fasorial no sistema, além da UMF da SE, com o objetivo de melhorar a estimativa de estados e avaliar o efeito de redundância da medição. A alocação das UMF é dada pela técnica BE associada ao estimador *E-OPF*. Duas simulações são realizadas para avaliar a *FOB* proposta nesta tese.

5.2.2.1 Condição 2.1 - Minimização do índice DEE

A Condição 2.1 considera a minimização apenas do índice global *DEE*. A Tabela 5.4 apresenta as soluções obtidas para diferentes números de UMF (N_{UMF} de '1' para '4'), cuja alocação é dada pela BE. A melhor solução do ponto de vista do índice *DEE* corresponde à alocação de 4 UMFs nas barras '2', '3', '4' e '10'. Os índices baseados em *LAV*, I_{MVD} e I_{AFD} , e a *FOB* completa do modelo, equação (4.4.a), também são calculados após a obtenção das soluções. De modo semelhante, houve analisando do ponto de vista da *FOB*, a melhor solução corresponde à alocação de 4 UMFs.

Tabela 5.4 – Resultados sistema 14 barras, Condição 2.1.

N_{UMF}	1	2	3	4
Barras UMF	5	2, 4	2, 4, 5	2, 3, 4, 10
DEE (%)	1,376780	1,243702	1,103734	1,006303
$LAV = I_{MVD} + I_{AFD}$	1,575994	1,349910	1,365794	1,249587
FOB	2,952775	2,593612	2,469529	2,255889
Tempo Computacional = 24,38 min.				

5.2.2.2 Condição 2.2 - Minimização da FOB constituída de DEE e LAV

Esta condição considera a minimização tanto do índice *DEE*, quanto dos índices baseados em *LAV*, na função objetivo do modelo *E-OPF* proposto, equação (4.4.a). A Tabela 5.5 apresenta os resultados obtidos pelo método proposto. Embora as melhores soluções obtidas para as condições 2.1 e 2.2 correspondam a alocação de 4 UMFs, pode-se verificar que o valor de *FOB* da Tabela 5.5 é menor do que o respectivo valor da Tabela 5.4, demonstrando que a inclusão dos índices baseados em *LAV* melhora o desempenho do estimador de estados em relação à utilização isolada do índice *DEE*, especialmente com baixa redundância de medição.

Tabela 5.5 – Resultados sistema 14 barras, Condição 2.2.

N_{UMF}	1	2	3	4
Barras UMF	11	2, 11	2, 5, 11	2, 4, 5, 13
DEE (%)	1,439037	1,296163	1,156020	1,016304
$LAV = I_{MVD} + I_{AFD}$	0,435530	0,442685	0,437326	0,439746
FOB	1,874567	1,738849	1,593347	1,456051
Tempo Computacional = 25,06 min.				

Pode-se verificar que quanto maior o número de unidades de medição alocadas de forma ótima, maior é a melhoria na *FOB*, conforme esperado devido ao aumento na redundância de medição. Avaliando as soluções da Tabela 5.4 e Tabela 5.5 observa-se que, embora o DEE seja ligeiramente mais eficiente na condição 2.1 do que na condição 2.2, os índices baseados em *LAV* são imensamente superiores na condição 2.1 do que na condição 2.2, o que garante uma *FOB* para a condição 2.1 maior, ou seja, com qualidade inferior visto que o objetivo consiste na minimização da *FOB*. Consequentemente, a condição 2.2 tem um equilíbrio melhor entre os objetivos *DEE* e *LAV* favorecendo assim, uma *FOB* menor, ou seja, com qualidade superior. Isso é consequência do DEE realizar um somatório de todas as medidas com as equações que relacionam as variáveis de estados estimados e assim, mesmo que tenha um resultado dentro desse conjunto desfavorável, ainda sim, o resultado final será favorável. A inclusão dos índices em *LAV* visa justamente penalizar as variáveis estimadas desfavoráveis no processo de estimação. A Figura 5.6 evidencia o comparativo das Condições 2.1 e 2.2.

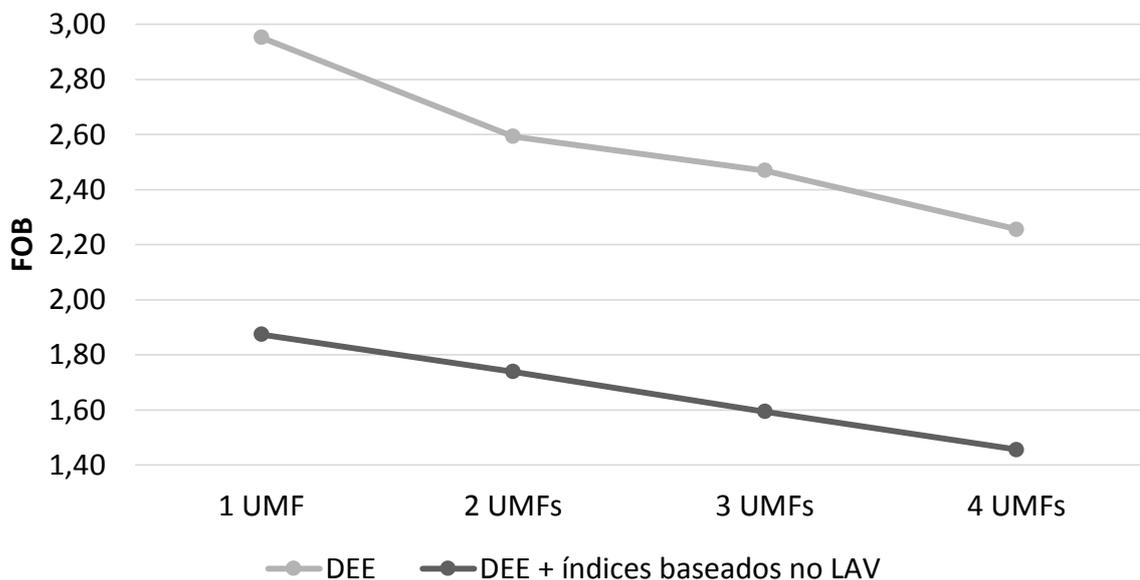


Figura 5.6. Impacto do número de UMF na *FOB*, sistema 14 barras, Condições 2.1 e 2.2.

Para a execução da técnica de BE, que envolve os diferentes números de unidades de medição fasorial, um total de 1051 simulações do *E-OPF* formulado em (4.4) foi executado, demandando um tempo total de 24,56 minutos. Este resultado demonstra a eficácia e a robustez

do método proposto, pois este tempo é aceitável para muitas aplicações *off-line*, como de planejamento, tendo em vista que foi suficiente para avaliar todas as combinações possíveis de alocação com números variados de unidades de medição.

A Figura 5.7 e Figura 5.8 apresentam as estimativas de módulo de tensão e ângulo de fase por barra, respectivamente, para as Condições 2.1 e 2.2. Observa-se que, apesar de os módulos de tensão da Figura 5.7 serem praticamente os mesmos nestas duas condições exceto por uma pequena diferença nas barras '11', '12', '13' e '14', os ângulos de fase da Figura 5.8 apresentam diferenças consideráveis, principalmente para as barras mencionadas.

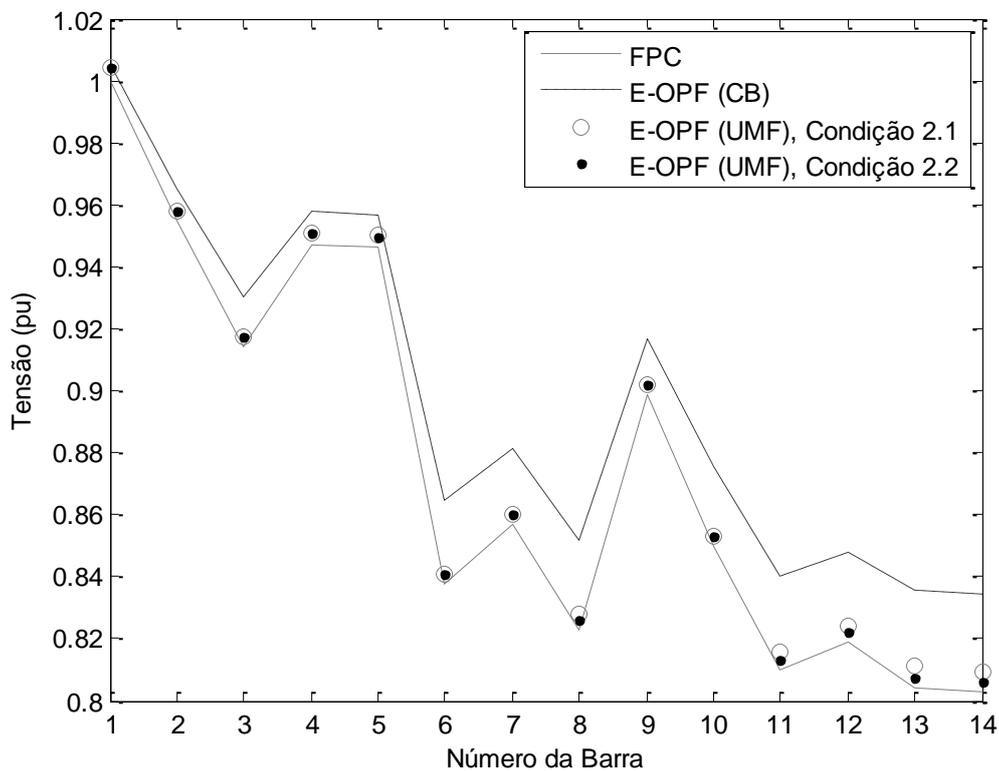


Figura 5.7. Comparativo estimativas de módulo de tensão, sistema 14 barras.

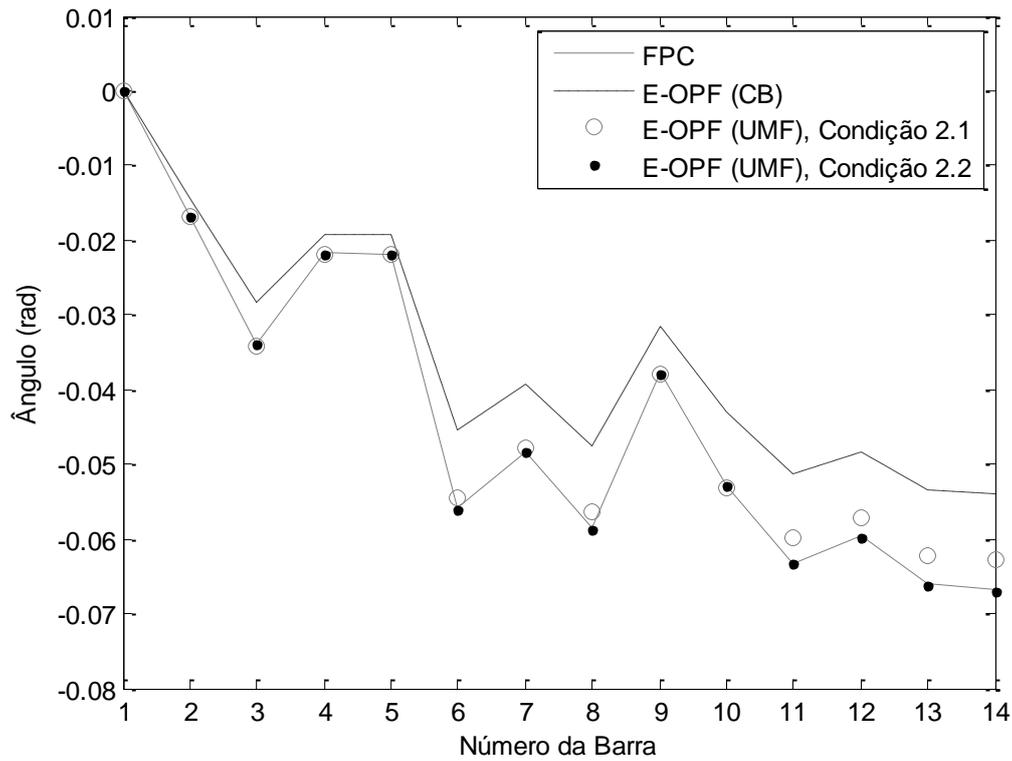


Figura 5.8. Comparativo estimativas de ângulo de fase, sistema 14 barras.

5.2.3 Sistema 14 barras, Condição 3

A Condição 3 considera nove configurações possíveis para o sistema de 14 barras, conforme listadas na Tabela 5.6, em que a primeira topologia é apresentada na Figura 4.8.

Tabela 5.6 – Configurações do sistema 14 barras.

Configuração	Chaves Abertas
1	S ₅ , S ₁₀ , S ₁₆
2	S ₅ , S ₁₀ , S ₁₄
3	S ₅ , S ₁₀ , S ₁₅
4	S ₁ , S ₁₀ , S ₁₆
5	S ₁ , S ₁₀ , S ₁₄
6	S ₁ , S ₁₀ , S ₁₅
7	S ₁ , S ₅ , S ₁₆
8	S ₁ , S ₅ , S ₁₆
9	S ₁ , S ₅ , S ₁₅

A Tabela 5.7 apresenta os resultados do processo de estimação de estados obtidos para medição na SE, ou seja, o vetor de medições é formado por:

- (i) configurações de 1 a 3, SE na barra ‘1’, $x^* = \{V_1^*, \theta_1^*, I_{1,2}^*\}$;
- (ii) configurações de 4 a 6, SE na barra ‘6’, $x^* = \{V_6^*, \theta_6^*, I_{1,6}^*\}$; e
- (iii) configurações de 7 a 9, SE na barra ‘11’, $x^* = \{V_{11}^*, \theta_{11}^*, I_{1,11}^*\}$.

Tabela 5.7 – Resultados sistema 14 barras, Condição 3.

Configuração	DEE (%)	LAV = $I_{MVD} + I_{AFD}$	FOB
1	1,499087	2,290582	3,789669
2	1,150011	4,326509	5,476519
3	1,699343	0,785450	2,484792
4	1,693608	0,583811	2,277418
5	1,576493	1,024468	2,600961
6	1,487499	1,024121	2,511620
7	1,392067	0,788218	2,180284
8	1,642449	0,445876	2,088325
9	1,035589	0,699378	1,734967

O *E-OPF* deve poder estimar o estado da rede para todas as configurações a partir das medidas fornecidas pelas unidades de medição fasorial alocadas no sistema. Daí, a Tabela 5.8 apresenta a *FOB* obtida pelo *E-OPF* para cada configuração, fixando-se o número de unidades como $N_{UMF} = 4$ alocadas nas barras indicadas na Tabela 5.5, ou seja, ‘2’, ‘4’, ‘5’ e ‘13’. Verifica-se na Tabela 5.8 que mesmo analisando de forma desacoplada, ou seja, determinando o ponto ótimo de alocação para uma determinada topologia do sistema analisado e utilizando-a para outras topologias, verificou-se que houve redução para todas as *FOB*. Esta capacidade de estimação sob diferentes configurações pode dar suporte ao estimador para lidar com erros ou imprecisões topológicas que podem ocorrer em SDE.

Tabela 5.8 – Resultados para 4 UMFs no sistema 14 barras e diferentes topologias.

Configuração	<i>FOB</i>	<i>Redução (%)</i>
1	1,456185	61,57
2	1,521073	72,23
3	1,590030	36,01
4	1,644176	27,81
5	1,605834	38,26
6	1,550058	38,28
7	1,471376	32,51
8	1,588094	23,95
9	1,277607	26,36

5.3 SISTEMA DE 33 BARRAS

O sistema de 33 barras, de 12,66 kV, utilizado neste estudo é amplamente investigado na literatura. Sua configuração original é composta por uma subestação, 32 trechos de distribuição e cinco chaves normalmente abertas, S_{33} , S_{34} , S_{35} , S_{36} e S_{37} , conforme ilustrado na Figura 5.9. Seus dados, incluindo de demanda, podem ser encontrados em [116] e seu estado obtido através do FPC é apresentado na Tabela 5.9.

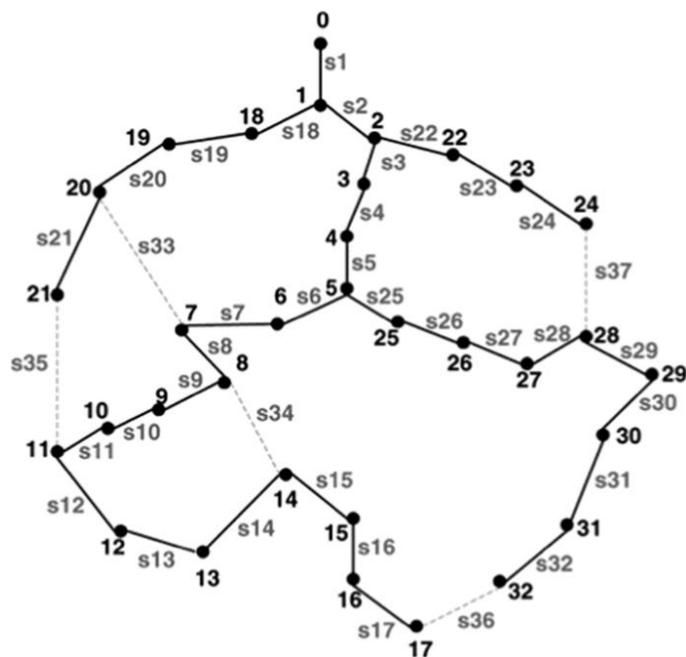


Figura 5.9. Sistema de 33 barras.

Tabela 5.9 – Solução FPC, sistema 33 barras.

Barra	Magnitude (pu)	Ângulo (rad)	Barra	Magnitude (pu)	Ângulo (rad)
0	1,0000	0,0000	17	0,8076	-0,0211
1	0,9936	0,0006	18	0,9926	0,0002
2	0,9631	0,0038	19	0,9853	-0,0022
3	0,9466	0,0064	20	0,9839	-0,0029
4	0,9303	0,0091	21	0,9826	-0,0036
5	0,8895	0,0054	22	0,9557	0,0026
6	0,8817	-0,0040	23	0,9419	-0,0006
7	0,8710	-0,0025	24	0,9350	-0,0023
8	0,8570	-0,0055	25	0,8852	0,0070
9	0,8440	-0,0081	26	0,8795	0,0093
10	0,8421	-0,0078	27	0,8539	0,0127
11	0,8387	-0,0072	28	0,8355	0,0160
12	0,8249	-0,0112	29	0,8276	0,0205
13	0,8198	-0,0146	30	0,8182	0,0168
14	0,8167	-0,0163	31	0,8162	0,0158
15	0,8136	-0,0173	32	0,8155	0,0155
16	0,8090	-0,0207			

As condições de análise deste sistema são:

- i) Condição 1 - apenas uma UMF na SE;
- ii) Condição 2 - múltiplas UMFs no sistema; e
- iii) Condição 3 - múltiplas configurações de rede.

Os erros das diferentes medidas são os mesmos definidos para o sistema de 14 barras, bem como as demais condições de simulação.

5.3.1 Sistema 33 barras, Condição 1

Assim como apresentado no sistema 14 barras, nesta condição, considera-se uma UMF na SE, com a disponibilidade de medidas de módulo de tensão, ângulo de fase e corrente no trecho adjacente, com o vetor de medidas dado por $x^* = \{V_0^*, \theta_0^*, I_{01}^*\}$. A barra “0”, ou seja, a SE é utilizada com referência assim, tem-se $\theta_0^* = 0$. Os erros para as medidas de tensão, corrente e as pseudo-medidas são considerados os mesmos utilizados no sistema 14 barras.

É importante salientar que de forma similar ao sistema 14 barras, os valores referentes às demandas de cargas ativas e reativas servem para avaliar o desempenho do método obtido, através de um ponto aleatório de operação (P_{bk}), dentro do intervalo histórico definido pelos limites (Pl_{maxk} e Pl_{mink}) conforme pode ser exemplificado na Figura 5.10.

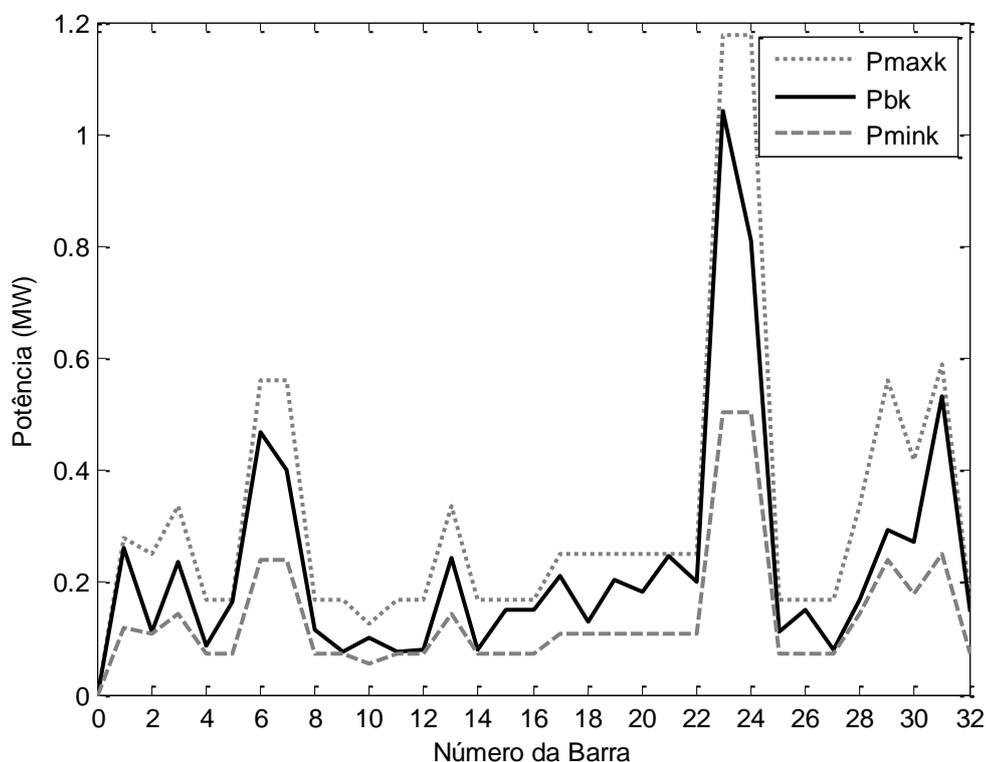


Figura 5.10. Demanda Aleatória Ativa do Caso Base Sistema 33 barras.

A Tabela 5.10 fornece os valores máximo, mínimo e médio da FOB obtidos pelo $E-OPF$ e pelo WLS , em 100 execuções destes algoritmos com erros aleatórios dentro dos respectivos limites predefinidos, para a avaliação de robustez. A Figura 5.11 apresenta as variações da FOB nestas 100 simulações para ambos os algoritmos, cujos tempos foram de 1,79 segundos para o $E-OPF$ e 0,34 segundos para o WLS . Embora o tempo do $E-OPF$ seja superior ao WLS , não é impeditivo para análises *off-line* de planejamento considerando variações topológicas, conforme demonstrado adiante.

Tabela 5.10 – Variações *FOB*, sistema 14 barras, Condição 1.

Valores da <i>FOB</i>	<i>E-OPF</i>	<i>WLS</i>
Mínimo	1,7136	6,6844
Máximo	16,3227	55,7354
Média	6,5951	19,6943

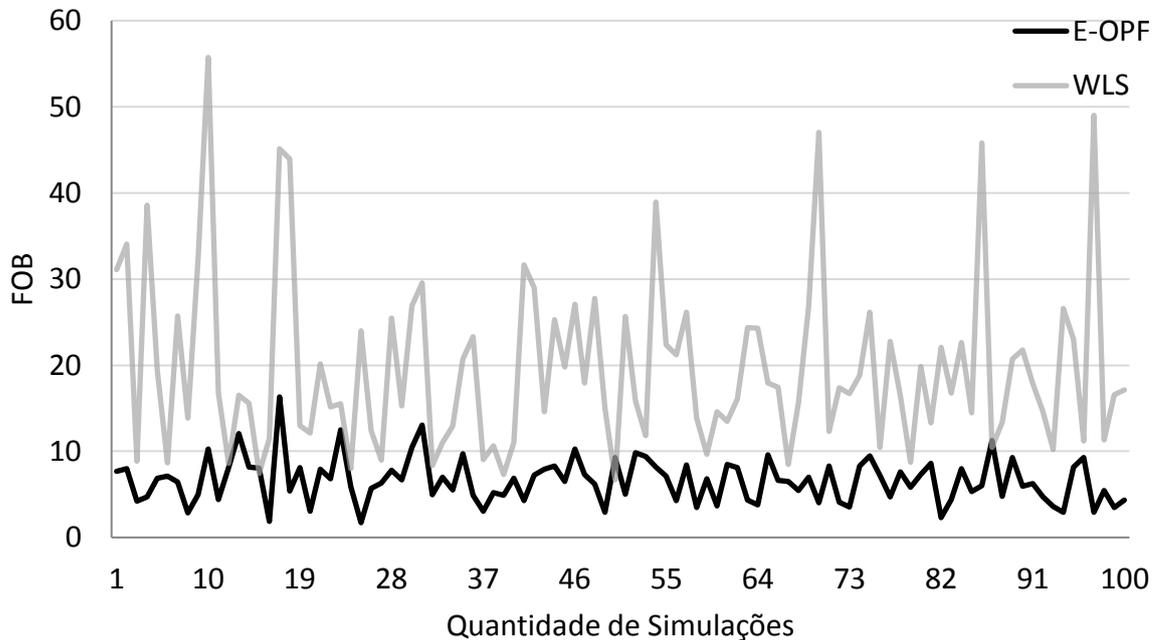


Figura 5.11. Variação da *FOB*, sistema 33 barras, Condição 1.

Novamente, assim como para o sistema de 14 barras, observa-se que o *E-OPF* apresenta menor variação e menor média de *FOB* nas 100 execuções em comparação com o *WLS*, demonstrando sua robustez para erros aleatórios significativos associados às pseudo-medidas (demandas de potência ativa e reativa), bem como eficácia, que é inversamente proporcional à *FOB*, também para o sistema de 33 barras.

A Figura 5.12 e Figura 5.13 apresentam o módulo de tensão e ângulo de fase por barra obtidos pelo FPC (valores reais) e estimados pelos algoritmos *E-OPF* e *WLS*. Neste caso, os maiores desvios ocorrem nos pontos de derivação de seções longas de alimentador, que se estendem da barra ‘6’ à barra ‘17’ e da barra ‘25’ a ‘32’.

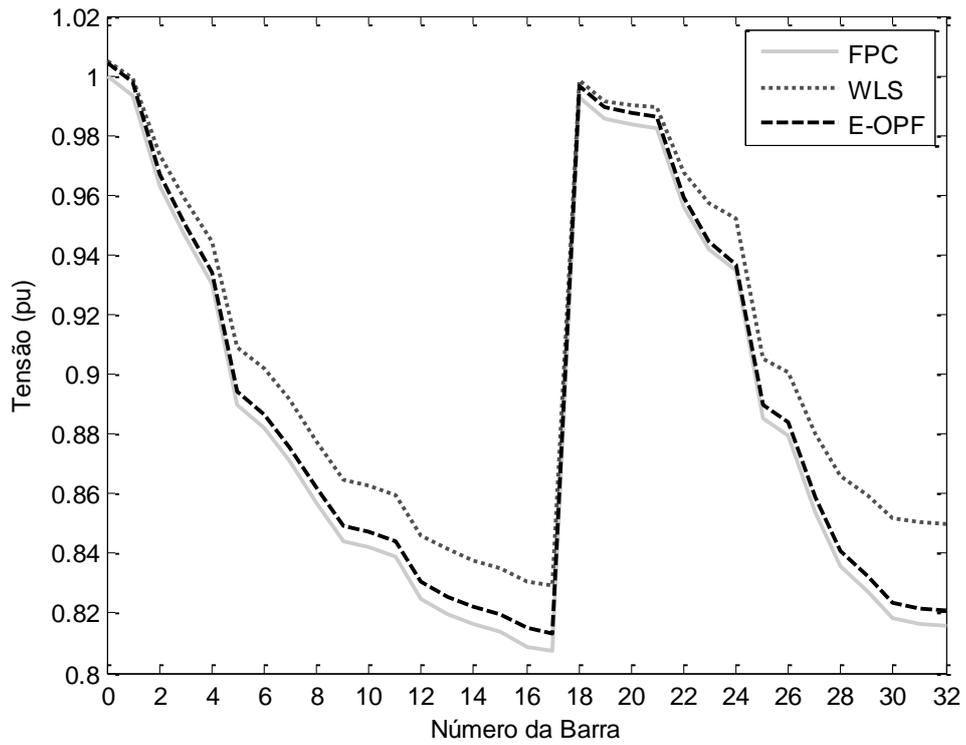


Figura 5.12. Módulo de tensão por barra, sistema 33 barras, Condição 1.

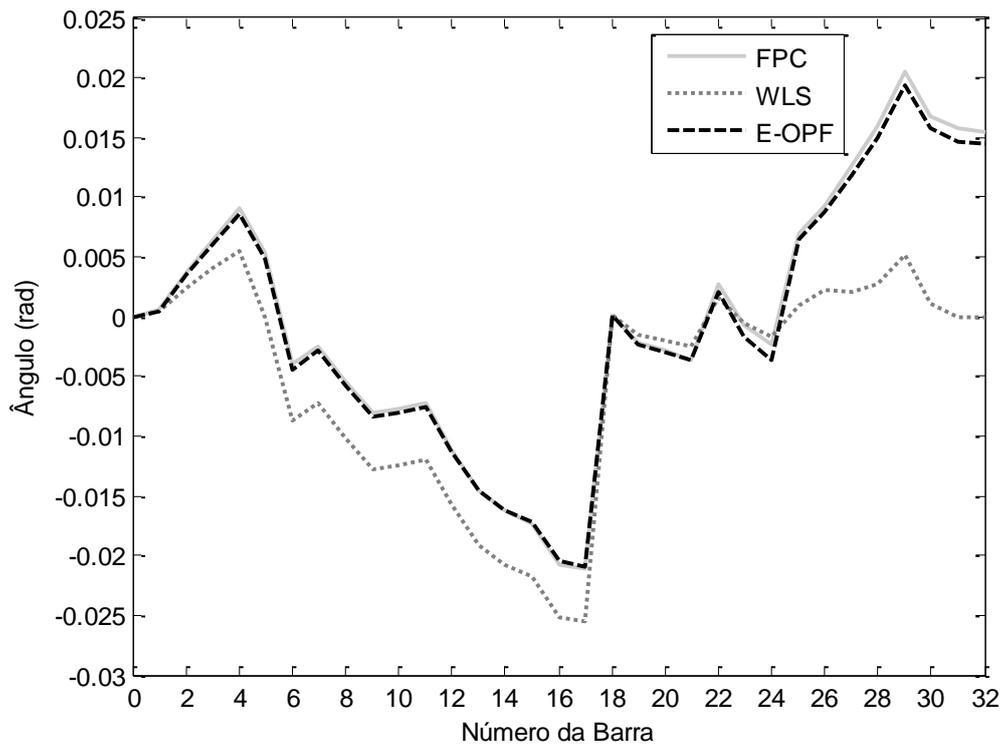


Figura 5.13. Módulo de tensão por barra, sistema 33 barras, Condição 1.

Os resultados obtidos pelos algoritmos *E-OPF* e *WLS* na Condição 1 são apresentados na Tabela 5.11. Verifica-se que o *E-OPF* resultou nos menores índices de estimação e *FOB* em comparação com o *WLS* também para este sistema, confirmando a eficácia do método proposto em condição de baixa redundância de medição.

Tabela 5.11– Resultados, sistema 33 barras, Condição 1.

Estimador	<i>DEE</i> (%)	<i>I_{MVD}</i> (%)	<i>I_{AFD}</i> (crad)	<i>FOB</i>
<i>E-OPF</i>	3,911981	0,729350	0,131148	4,772479
<i>WLS</i>	12,499913	4,193479	1,591022	18,284415

5.3.2 Sistema 33 barras, Condição 2

Com o objetivo de melhorar o resultado da Tabela 5.11, o *E-OPF* é resolvido para um número variável de unidades de medição fasorial no sistema, de ‘1’ a ‘4’, cuja alocação é dada por um procedimento de BE. A Tabela 5.12 apresenta os resultados obtidos pelo *E-OPF* proposto, onde se pode observar que o melhor desempenho do estimador de estados, neste caso, é obtido com ‘4’ unidades. A Figura 5.14 evidencia a evolução da *FOB* para alocação de ‘1’ a ‘4’ UMF.

Tabela 5.12 – Resultados sistema 33 barras, Condição 2.

<i>N_{UMF}</i>	1	2	3	4
Barras UMF	24	17-24	19-24-31	1-21-23-32
<i>DEE</i> (%)	3,800710	3,701423	3,546209	3,400232
$LAV = I_{MVD} + I_{AFD}$	0,597768	0,447040	0,430212	0,455710
<i>FOB</i>	4,398478	4,148464	3,976421	3,855942
Tempo Computacional = 35,97 h				

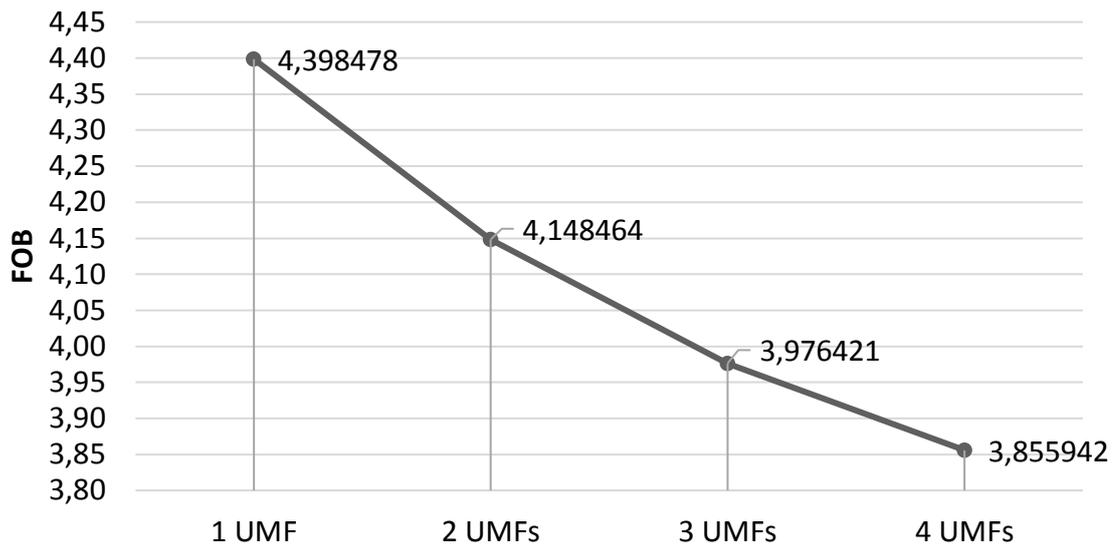


Figura 5.14. Evolução *FOB*, sistema 33 barras, Condição 2.

A Figura 5.15 mostra o número de simulações do *E-OPF* exigidas pelo processo de BE para encontrar as melhores soluções de alocação de ‘1’, ‘2’, ‘3’ e ‘4’ unidades de medição. Deve-se enfatizar que os quatro processos de BE, um para cada número de unidades, associados ao *E-OPF* proposto, foram executados em aproximadamente 36 horas no total. No contexto do planejamento de sistemas de medição e tendo em vista que todas as opções de planejamento para ‘1’, ‘2’, ‘3’ e ‘4’ equipamentos foram avaliadas, este tempo não é proibitivo. Destaca-se que este tempo também pode ser significativamente reduzido se um conjunto limitado de barras candidatas promissoras for previamente selecionado. Estes aspectos mostram que o *E-OPF* proposto é adequado ao problema de estimação de estados em SDE, sob condição de baixa redundância de medição, para muitas aplicações como, por exemplo, o planejamento da medição proposto nesta tese.

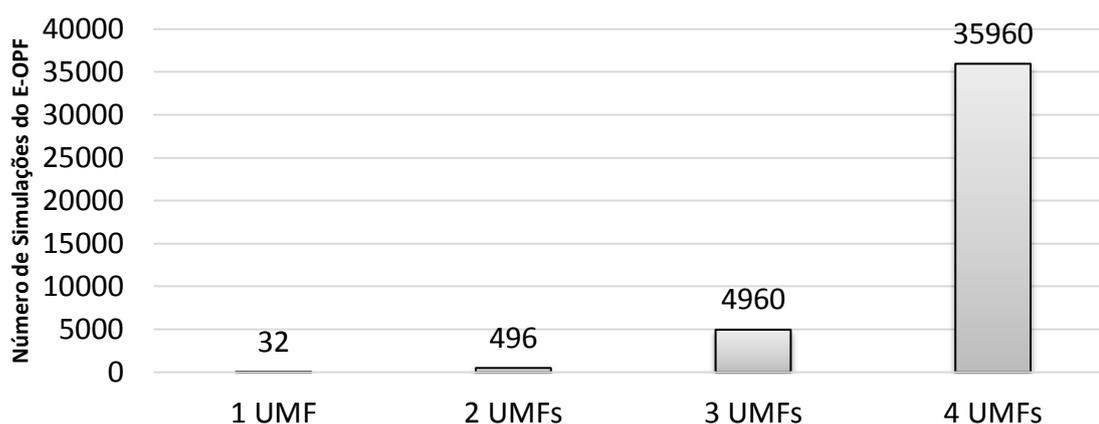


Figura 5.15. Número de simulações do *E-OPF*, sistema 33 barras, Condição 2.

5.3.3 Sistema 33 barras, Condição 3

Nesta condição, a topologia original da Figura 5.9 e duas configurações adicionais, obtidas de [6], são consideradas. A Tabela 5.13 fornece os dados da configuração original e as duas adicionais de [6]. A Tabela 5.14 apresenta os resultados obtidos pelo *E-OPF* proposto considerando-se uma única UMF na SE (Caso Base) e a Tabela 5.15 traz os resultados sobre a avaliação de forma desacoplada, ou seja, considerando a alocação ótima obtida para as 4 UMF, conforme Tabela 5.12 e definida para a configuração original, verificando o impacto dessa alocação para as duas topologias adicionais do sistema de 33 barras.

Tabela 5.13 – Configurações original e adicionais do sistema 33 barras.

Configuração	Chaves Abertas
1 (Original)	S ₃₃ , S ₃₄ , S ₃₅ , S ₃₆ e S ₃₇
2	S ₇ , S ₁₀ , S ₁₄ , S ₃₂ e S ₃₇
3	S ₇ , S ₉ , S ₁₄ , S ₃₂ e S ₃₇

Tabela 5.14 – Resultados, sistema 33 barras, Condição 3 e 1 UMF na SE.

Configuração	DEE (%)	LAV = $I_{MVD} + I_{AFD}$	FOB
1	3,911981	0,860498	4,772479
2	4,291392	0,463782	4,755174
3	4,297887	0,457048	4,754936

Tabela 5.15 – Resultados, sistema 33 barras, Condição 3 e 4 UMFs no sistema.

Configuração	<i>FOB</i>	Redução (%)
1	3,855942	19,20
2	4,291384	9,75
3	4,298499	9,60

Observa-se pela Tabela 5.15 que o desempenho do estimador *E-OPF* não é significativamente afetado pelas mudanças topológicas consideradas, o que demonstra sua robustez e aplicabilidade em SDE com recursos operativos. O melhor resultado ocorre para a configuração ‘1’, pois o resultado da Tabela 5.12 foi obtido para a mesma. Embora, a redução para as duas topologias adicionais não seja tão significativa, conforme valores da Tabela 5.15, ainda sim é válido visto que a alocação utilizada visava otimizar a configuração original. Em relação à Tabela 5.14 para uma única UMF, os resultados da Tabela 5.15 para quatro unidades são melhores, conforme esperado devido ao aumento de redundância de medição.

5.4 CONSIDERAÇÕES FINAIS

Este capítulo apresentou resultados obtidos pelo novo método de estimação de estados proposto no presente trabalho. Estes resultados envolveram a validação do modelo de otimização e análises sobre a alocação de unidades de medição fasorial em sistemas de distribuição. A aleatoriedade devido às incertezas inerentes às medidas provenientes de equipamentos e à demanda é considerada nestas análises. Destaca-se a aplicabilidade do *E-OPF* proposto para a estimação de estados de SDE, pois o mesmo demonstrou alcançar sua convergência mesmo para um único medidor na subestação e pseudo-medidas com alto grau de incerteza. Dois sistemas conhecidos da literatura foram utilizados e os estudos demonstraram que os melhores pontos ou barras da rede não são, a princípio, predefinidos em função de sua localização nos alimentadores ou do número de trechos de distribuição conectados. Este comportamento motivou a presente proposta de desenvolvimento de uma metodologia de otimização para a alocação ótima de equipamentos de medição em redes de distribuição, através de uma abordagem multiobjetivo e de avaliação da relação custo-benefício, através da inclusão dos custos de investimento em diferentes equipamentos de monitoramento.

6 RESULTADOS DA METODOLOGIA PROPOSTA

Este capítulo apresenta os resultados obtidos pela metodologia proposta nesta tese para o planejamento de sistemas de monitoramento em redes de distribuição de energia elétrica, envolvendo o novo método de estimação de estados *E-OPF* proposto. A metodologia de alocação de equipamentos é baseada na técnica de otimização metaheurística *Modified Monkey Search*, que visa determinar o número, locais e tipos de equipamentos de medição.

Para tanto, são considerados medidores inteligentes e unidades de medição fasorial como opções de investimento para a metodologia proposta, que visa maximizar o desempenho do processo de estimação de estados com o mínimo custo de aquisição possível. Além das medidas provenientes dos equipamentos de medição citados, a metodologia também considera medidas adquiridas em subestações, bem como pseudo-medidas a partir de dados históricos.

Os resultados são organizados da seguinte forma: (i) resultados para o modelo de planejamento mono-objetivo, com a finalidade de prover um tutorial da metodologia proposta; (ii) resultados para o modelo de planejamento mono-objetivo e equipamentos comerciais, para fins de uma abordagem mais realista com a representação de medidores disponíveis no mercado e sistemas de maior porte, incluindo uma rede real de concessionária brasileira; e (iii) resultados para o modelo de planejamento multiobjetivo, com o propósito de avaliar a potencialidade da metodologia proposta para prover planos alternativos de medição, também para as condições realistas mencionadas no item (ii).

As condições gerais dos estudos são:

- Representação de carga - Supõe-se uma variação de 50% na demanda de carga devido ao seu comportamento estocástico, ou seja, 50% de erro para pseudo-medidas;
- Parâmetros *MMS* [105] e [106] - (i) altura de uma árvore $h = 8$, totalizando $c = 256$ caminhos conforme equação (A.1) do Apêndice A; (ii) tolerância para a convergência global “0”; (iii) número máximo de árvores “20”; (iv) tamanho da memória adaptativa $memo = “10”$, equação (A.2) do Apêndice A; e (v) número de soluções para iniciar o processo de intensificação $n_{peri} = “100”$. Maiores detalhes do *MMS* podem ser encontrados no Apêndice A;

- Parâmetros AG [105] e [107] - (i) probabilidade de cruzamento “95%”; (ii) probabilidade de mutação “2%”; (iii) tamanho da população “300”; (iv) número de gerações para convergência “100”; (v) taxa de elitismo com sendo “1” indivíduo; (vi) codificação decimal; (vii) seleção da roleta; e (viii) *crossover* de dois pontos; e
- Parâmetros RS [105] e [108] - (i) Constante de Boltzmann “1”; (ii) temperatura inicial “30”; (iii) número máximo de iterações “300”; e (iv) taxa de arrefecimento “0,95”.

Nas simulações da abordagem multiobjetivo, especificamente, as únicas diferenças em relação aos parâmetros do *MMS* definidos anteriormente são: árvore $h = 4$; $c = 16$; número máximo de árvores “10”; $memo = “8”$. A escolha do menor número de árvores na abordagem multiobjetivo visa reduzir esforço computacional pela redução do número de soluções investigadas, tendo em vista o maior porte dos sistemas estudados sob este enfoque. No entanto, esta redução ainda consegue manter um bom desempenho do algoritmo conforme resultados apresentados neste capítulo.

As simulações são realizadas utilizando o software MATLAB versão R2013a e para o *E-OPF*, utiliza-se ainda a ferramenta de otimização não linear denominada *fmincon* [114], baseada no método dos pontos interiores. Os testes são executados em um processador Intel Corei5-4200U de 4 GHz com RAM de 3,20 GHz.

6.1 RESULTADOS PARA O MODELO DE PLANEJAMENTO MONO-OBJETIVO

Esta seção apresenta estudos de caso para o sistema de 33 barras de [116], descrito no capítulo anterior, envolvendo a alocação de UMF e MI. Os parâmetros são listados a seguir.

- Custos de investimento [77] - (i) UMF: 1.0 u.c.; (ii) MI: 0,2 u.c. em que ‘u.c.’ significa “unidade de custo”;
- Erros de medição [77] - (i) 1% para as medidas da SE e UMF; (ii) 10% para MI e; (iii) 50% para pseudo-medidas com base em dados históricos; e
- Número de simulações - Um total de 100 simulações de cada algoritmo metaheurístico, o *MMS* proposto e os algoritmos genético e de recozimento simulado, AG e RS, desenvolvidos para fins de comparação com o *MMS*, com o propósito de avaliar eficácia e robustez da metodologia proposta devido à natureza probabilística do *MMS*.

Para avaliar o impacto de se considerar diferentes cenários no processo de planejamento, duas análises são realizadas. A primeira, Análise A, considera apenas o Caso Base, ou seja, a configuração topológica da Figura 5.9, enquanto que a Análise B inclui mais de um cenário. Em ambos, a pesquisa exaustiva também é realizada para o número de dispositivos de medição obtidos pelo *MMS*, para determinar a solução global correspondente e, portanto, para avaliar a metodologia proposta.

6.1.1 Sistema 33 barras, Análise A

Na Análise A, os pesos α , β e γ da *FOB* da equação (4.8) são iguais a 1,0, assim como em [77], e o número de configurações, N_C , também é igual a '1', o que significa que apenas um cenário é considerado, sendo a configuração da Figura 5.9, em que as chaves S_{33} a S_{36} encontram-se abertas. A Tabela 6.1 apresenta os valores reais para as variáveis de estado obtidas a partir da solução do fluxo de potência convencional, juntamente com os valores estimados apenas com a utilização de pseudo-medidas e medições provenientes da SE, ou seja, sem alocação de equipamentos adicionais como UMF ou MI.

Os índices de estimação baseados em LAV , I_{MVD} e I_{AFD} , obtidos sem alocação de UMF ou MI são apresentados na Tabela 6.2. Pode-se observar que os valores máximos de I_{MVD} e I_{AFD} ocorrem na barra '17', conforme destacado, localizada no final do alimentador. Além disso, a medida da SE também está sujeita a erros, como pode ser observado a partir dos módulos reais e estimados de tensão na barra '0'. Esta medição apresenta um erro de 1,0% (igual ao de uma UMF), refletido no desvio da estimativa de 1,00 pu para 1,01 pu. Neste caso, não há custo de investimento, pois não há alocação de UMF ou MI, e a *FOB* é 15,6938 u.c..

A Tabela 6.3 apresenta os melhores resultados obtidos pelos algoritmos *MMS* proposto e AG e RS desenvolvidos para comparação, em que o "Tempo" refere-se ao tempo de processamento para a convergência. O custo de investimento (Custo Inv.) consiste na soma dos dois primeiros termos da equação (4.8), que estão associados ao investimento em UMF e MI. Pode-se observar que o *MMS* obtém o melhor resultado em comparação com as outras ferramentas de busca metaheurísticas. No entanto, o processo de BE alcança a melhor solução, associada à menor *FOB* neste caso.

Tabela 6.1 –Valores Reais e Estimados sem alocação de UMF e MI, sistema 33 barras.

Barra	Valores Reais Tensão (pu-kV)/ Ângulo (rad)	Valores Estimados Tensão (pu-kV)/ Ângulo (rad)	Barra	Valores Reais Tensão (pu-kV)/ Ângulo (rad)	Valores Estimados Tensão (pu-kV)/ Ângulo (rad)
0 (SE)	1,0000 / 0,0000	1,0100 / 0,0000	17	0,8076 / -0,0211	0,9241 / -0,0084
1	0,9936 / 0,0006	1,0071 / 0,0002	18	0,9926 / 0,0002	1,0065 / 0,0001
2	0,9631 / 0,0038	0,9931 / 0,0016	19	0,9853 / -0,0022	1,0030 / -0,0011
3	0,9466 / 0,0064	0,9857 / 0,0028	20	0,9839 / -0,0029	1,0023 / -0,0014
4	0,9303 / 0,0091	0,9784 / 0,0039	21	0,9826 / -0,0036	1,0017 / -0,0018
5	0,8895 / 0,0054	0,9602 / 0,0023	22	0,9557 / 0,0026	0,9896 / 0,0011
6	0,8817 / -0,004	0,9568 / -0,0016	23	0,9419 / -0,0006	0,9830 / -0,0004
7	0,8710 / -0,0025	0,9520 / -0,0010	24	0,9350 / -0,0023	0,9797 / -0,0012
8	0,8570 / -0,0055	0,9458 / -0,0023	25	0,8852 / 0,0070	0,9583 / 0,0030
9	0,8440 / -0,0081	0,9401 / -0,0033	26	0,8795 / 0,0093	0,9558 / 0,0039
10	0,8421 / -0,0078	0,9392 / -0,0032	27	0,8539 / 0,0127	0,9445 / 0,0053
11	0,8387 / -0,0072	0,9377 / -0,0030	28	0,8355 / 0,0160	0,9364 / 0,0067
12	0,8249 / -0,0112	0,9317 / -0,0046	29	0,8276 / 0,0205	0,9329 / 0,0085
13	0,8198 / -0,0146	0,9294 / -0,0059	30	0,8182 / 0,0168	0,9287 / 0,0070
14	0,8167 / -0,0163	0,9281 / -0,0066	31	0,8162 / 0,0158	0,9278 / 0,0066
15	0,8136 / -0,0173	0,9267 / -0,0070	32	0,8155 / 0,0155	0,9276 / 0,0065
16	0,8090 / -0,0207	0,9247 / -0,0083			

A diferença entre o resultado obtido pelo *MMS* e o processo de BE é de apenas 0,0016 u.c.. Ambos determinam a mesma alocação de UMFs, sendo a diferença entre os mesmos na alocação de MI, na barra ‘23’ (*MMS*) e na barra ‘24’ (BE). A Figura 6.1 apresenta os valores da *FOB* em ordem decrescente obtidos nas 100 simulações do *MMS*, com o modelo *E-OPF* embutido. Observa-se que não há uma variação significativa entre as simulações, demonstrando a robustez da metodologia proposta, sendo o desvio na *FOB* entre a melhor solução (11,0121 u.c.) e a pior (11,7918 u.c.) de apenas 7,08%.

Tabela 6.2 – I_{MVD} e I_{AFD} sem alocação de UMF e MI, sistema 33 barras.

Barra	$I_{MVD}(\%)$	I_{AFD} (crad)	Barra	$I_{MVD}(\%)$	I_{AFD} (crad)
0 (SE)	1,0000	0,0000	17	14,4247	1,2691
1	1,3527	0,0313	18	1,4087	0,0117
2	3,1169	0,2127	19	1,7921	0,1102
3	4,1321	0,3629	20	1,8683	0,1457
4	5,1771	0,5217	21	1,9375	0,1832
5	7,9548	0,3118	22	3,5458	0,1531
6	8,5103	0,2382	23	4,3632	0,0231
7	9,2973	0,1441	24	4,7809	0,1117
8	10,3609	0,3195	25	8,2640	0,4057
9	11,3821	0,4741	26	8,6807	0,5409
10	11,5360	0,4544	27	10,6091	0,7362
11	11,8065	0,4225	28	12,0693	0,9303
12	12,9388	0,6578	29	12,7230	1,2055
13	13,3694	0,8676	30	13,5085	0,9814
14	13,6411	0,9688	31	13,6838	0,9193
15	13,9066	1,0314	32	13,7383	0,8984
16	14,3046	1,2427			

Tabela 6.3 – Resultados Análise A, sistema 33 barras.

Algoritmo	UMF Barras	MI Barras	I_{MVD} (%)	I_{AFD} (crad)	Custo Inv. (u.c.)	FOB (u.c.)	Tempo (min)
MMS	8-14-22-30	23	6,5849	0,2272	4,20	11,0121	5,18
AG	8-14-24-32	31	6,7773	0,2388	4,20	11,2161	17,75
RS	8-13-22-30	12-23	6,5256	0,2273	4,40	11,1529	13,10
BE	8-14-22-30	24	6,5816	0,2289	4,20	11,0105	10 dias

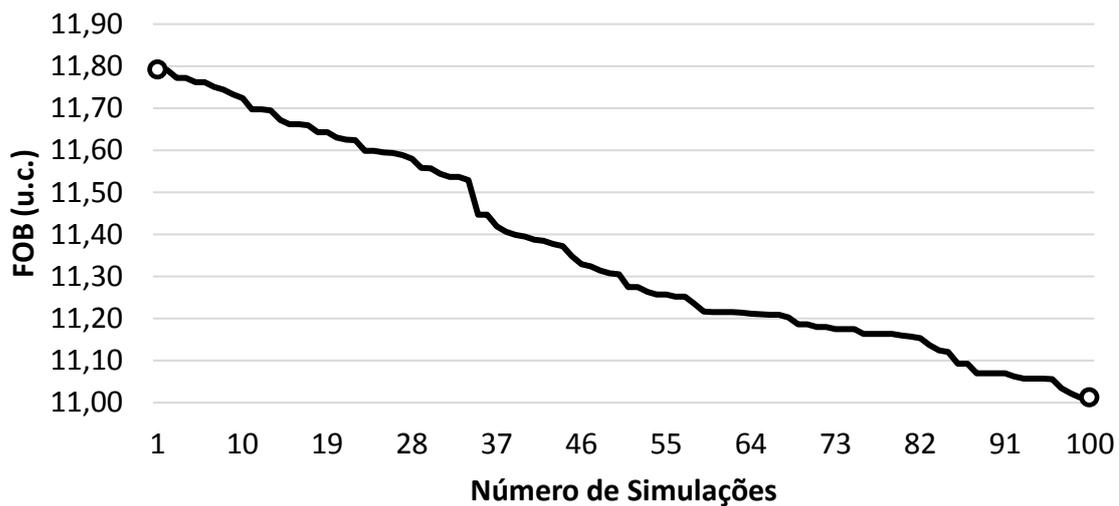


Figura 6.1. *FOB* do *MMS*, sistema 33 barras, Análise A.

A Figura 6.2 e Figura 6.3 apresentam os módulos de tensão e ângulo de fase por barra, respectivamente, para o estado exato obtido via fluxo de potência convencional -FPC, a melhor solução estimada via metodologia proposta -*MMS* e a solução estimada apenas com uma única UMF, localizada na subestação -SE.

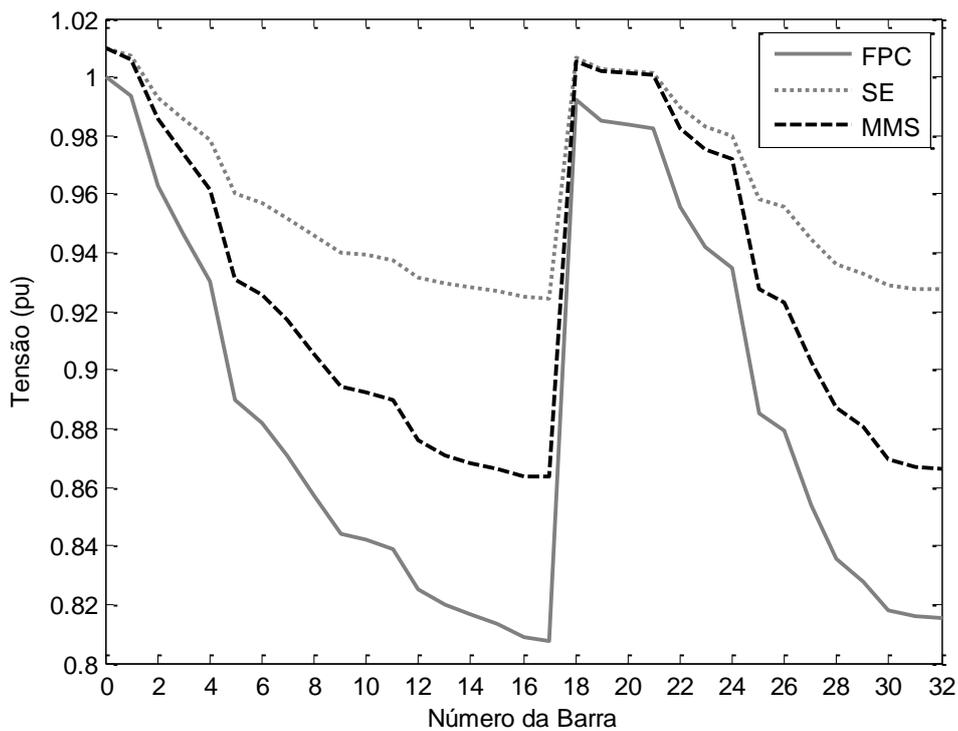


Figura 6.2 – Módulos de tensão, sistema de 33 barras, Análise A.

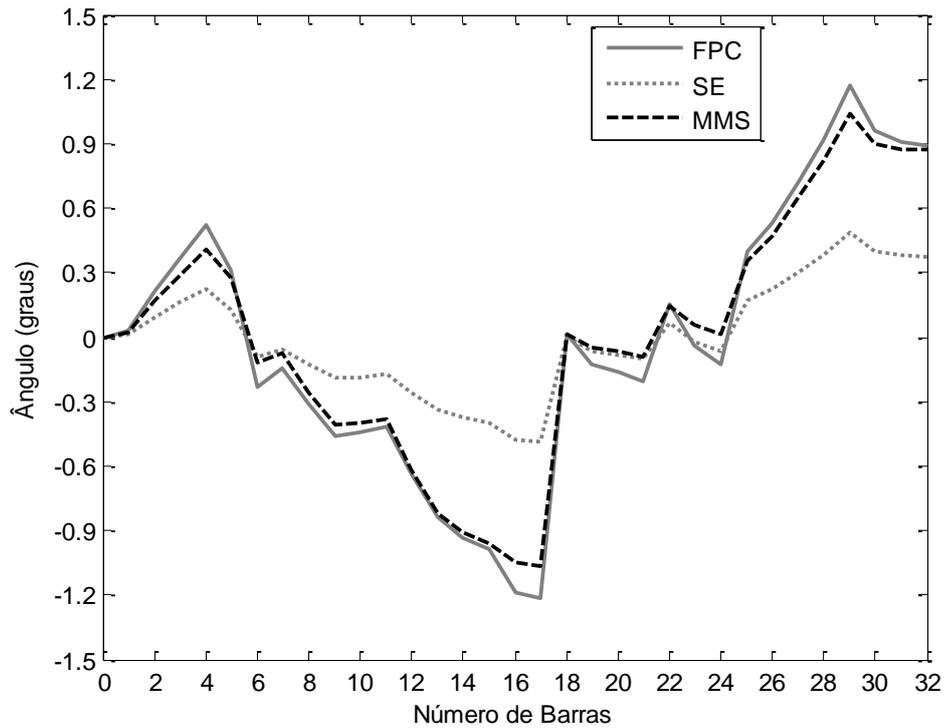


Figura 6.3 – Ângulos de fase, sistema de 33 barras, Análise A.

Embora o *MMS* tenha erros significativos em relação ao *FPC*, na análise de módulo de tensão (Figura 6.2), ainda sim, a evolução da solução em relação ao Caso Base é bastante significativa. A diferença entre o *MMS* e o *FPC*, na análise do módulo, é devido a pequena quantidade de medidas utilizadas, representados pela *SE* e as medidas das *UMFs* previamente definidas conforme Tabela 6.3, além da incerteza das pseudo-medidas com uma faixa considerável de 50%.

Também para fins comparação e análise, os índices de estimação e os custos associados são calculados a seguir para:

- (i). *UMF*, ou *MI*, alocada em todas as barras do sistema, exceto na *SE*, Tabela 6.4; e
- (ii). *UMF* e/ou *MI*, alocada nas barras terminais do alimentador da Figura 5.9, ou seja, nas barras ‘17’, ‘21’, ‘24’ e ‘32’, Tabela 6.5.

Tabela 6.4 – Resultados sistema 33 barras, Análise A, UMF e MI em todas a barras.

Dispositivos em todas as barras	UMF	MI
I_{MVD} (%)	1,0007	10,8256
I_{AFD} (crad)	0,0212	0,8927
Custo Inv. (u.c.)	32,00	6,40
FOB (u.c.)	33,0219	18,1183

Os resultados da Tabela 6.3 e Tabela 6.4 demonstram a presença de objetivos conflitantes na FOB , equação (4.8). Se uma grande quantidade de dispositivos de alta precisão e de elevado custo como UMF são alocados, o custo de investimento e a FOB aumentam em relação aos resultados ótimos da Tabela 6.3. Por outro lado, se apenas o MI for alocado, mesmo que em todas as barras, os índices de estimação se elevam, elevando a FOB , em comparação com o ponto ótimo da Tabela 6.3, devido à menor precisão do MI em relação ao UMF. Portanto, os resultados provam que a solução ótima, que atenda a relação de compromisso entre o desempenho do estimador e custo, não é monitorar todos os pontos da rede.

Tabela 6.5 – Resultados sistema 33 barras, Análise A, UMF e MI nos finais do alimentador.

UMF	MI	I_{MVD} (%)	I_{AFD} (crad)	Custo Inv.(u.c.)	FOB (u.c)
17-21-24-32	-	8,79252697	0,44029631	4,0	13,23282328
17-21-24	32	16,14027249	1,34345148	3,2	20,68372397
17-21-32	24	9,21138102	0,45493964	3,2	12,86632066
17-24-32	21	9,01388566	0,45497962	3,2	12,66886528
21-24-32	17	15,95064363	1,91620142	3,2	21,06684505
17-21	24-32	18,04470559	1,29448142	2,4	21,73918701
17-24	21-32	17,57456086	1,26814276	2,4	21,24270361
17-32	21-24	11,43248750	0,54687259	2,4	14,37936009
21-24	17-32	20,75191557	1,34165122	2,4	24,49356678
21-32	17-24	17,74240748	2,07679302	2,4	22,21920050
24-32	17-21	17,31899756	2,03941367	2,4	21,75841123
32	17-21-24	20,20339162	2,27050212	1,6	24,07389374
24	17-21-32	23,18637149	1,38067102	1,6	26,16704251
21	17-24-32	24,08662435	1,39025568	1,6	27,07688003
17	21-24-32	20,31001956	1,27207354	1,6	23,18209311
-	17-21-24-32	26,56424316	1,41975416	0,8	28,78399732

A partir da Tabela 6.5, por sua vez, pode-se observar que a alocação de UMF e/ou MI somente nos terminais de alimentador também não é a melhor opção, uma vez que os melhores resultados obtidos na Tabela 6.3 (*MMS* e *BE*) têm valores de *FOB* menores e determinam a alocação de uma UMF na barra ‘8’ (meio do alimentador) e nas barras ‘14’, ‘22’ e ‘30’, próximas ao fim do alimentador, porém não exatamente no final do mesmo.

6.1.2 Sistema 33 barras, Análise B

A análise B considera as mesmas condições da Análise A, porém, com a inclusão de dois cenários prováveis de configuração [6]. O objetivo é encontrar uma solução ótima que possa estabelecer uma relação de compromisso adequada entre os diferentes cenários em termos de precisão das estimativas e de custos de investimento. Os cenários considerados são:

- Cenário 1 - Chaves abertas - S_{33} (7-20), S_{34} (8-14), S_{35} (11-21), S_{36} (17-32) e S_{36} (24-28), a configuração original da Figura 5.9;
- Cenário 2 – Chaves abertas - S_7 (7-20), S_{10} (8-14), S_{14} (11-21), S_{32} (17-32) e S_{36} (24-28);
- Cenário 3 – Chaves abertas - S_7 (7-20), S_9 (8-14), S_{14} (11-21), S_{32} (17-32) e S_{36} (24-28), que é a configuração otimizada para perda mínima de [6].

Nesta análise, os pesos da *FOB* da equação (4.8) são iguais a ‘1/3’ para manter a relação de compromisso entre a precisão das estimativas e os custos de investimento. A partir de análises empíricas, pôde-se concluir que uma boa escolha para α e β é dada pelo inverso do número de cenários. Sem alocação de UMF ou MI, a *FOB* total, dada pelo somatório das funções objetivo para todas as configurações, é de 12,8977 u.c.. A Tabela 6.6 apresenta os valores das funções para os três cenários analisados, juntamente com a *FOB* total dada pelo somatório dos cenários conforme equação (4.8). Vale ressaltar que o custo de investimento para aquisição de equipamentos é zero no resultado da Tabela 6.6.

Tabela 6.6– Resultados de *FOB*, sistema 33 barras, Análise B, sem UMF e MI.

Configuração	I_{MVD} (%)	I_{AFD} (crad)	<i>FOB</i>
1	4,8082	0,4230	5,2313
2	3,1268	0,7222	3,8490
3	3,1267	0,6908	3,8175
Total	11,0618	1,8360	12,8977

A Tabela 6.7 apresenta os melhores resultados obtidos pela metaheurística proposta, pelas técnicas usadas como comparação e pelo procedimento de Busca Exaustiva (BE). A BE foi realizada considerando o mesmo número de equipamento do *MMS*, apresentando resultado ligeiramente melhor com diferença de apenas 0,1320 u.c.. No entanto, a BE requer muito mais tempo do que o *MMS* proposto, ou seja, o *MMS* é cerca de 3.000 vezes mais rápido do que a BE, conforme Tabela 6.7.

Tabela 6.7 – Resultados de *FOB*, sistema 33 barras, Análise B, com *UMF* e/ou *MI*.

Algoritmo	UMF Barras	MI Barras	I_{MVD} (%)	I_{AFD} (crad)	Custo Inv. (u.c.)	<i>FOB</i> (u.c.)	Tempo (min)
<i>MMS</i>	12-17-23-30	8	6,9554	0,2885	4,20	11,4439	16,35
AG	12-17-21-23-25-31	5-8-30	5,44206	0,3128	6,60	12,3549	51,60
RS	5-8-12-17-23-31	21-25-30	5,2904	0,2350	6,60	12,1254	39,60
BE	10-16-23-30	7	6,8430	0,2689	4,20	11,3119	34 dias

Em 100 simulações do algoritmo *MMS* (Figura 6.4), o desvio entre o melhor resultado, 11,4439 u.c., e o pior, 12,9912 u.c., é de 13,52%. Os resultados da Análise B em conjunto com a Análise A mostram que a consideração de diferentes cenários topológicos de rede afeta o planejamento dos sistemas de medição em SDE, uma vez que a *FOB* aumenta com o número de cenários devido à representação mais realista neste caso.

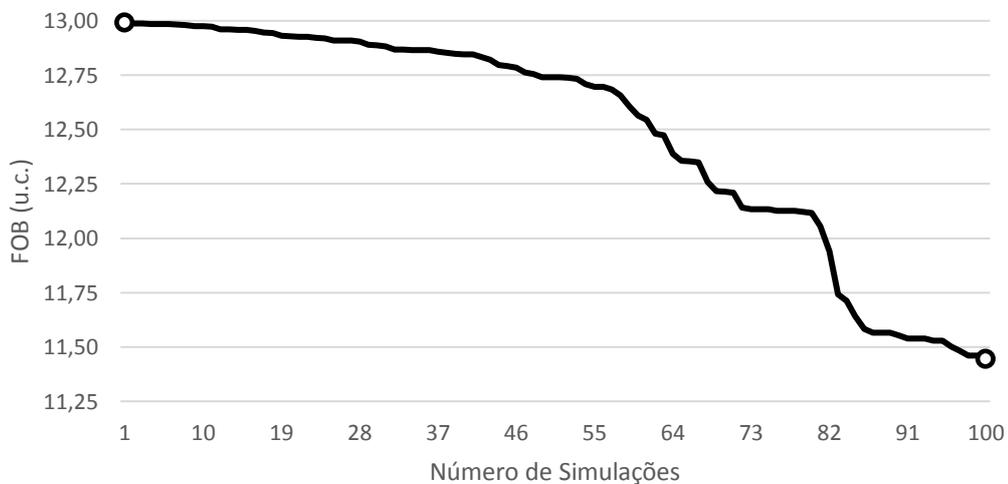


Figura 6.4. *FOB* do *MMS*, sistema 33 barras, Análise B.

6.2 RESULTADOS PARA O MODELO DE PLANEJAMENTO MONO-OBJETIVO E EQUIPAMENTOS COMERCIAIS

Esta seção apresenta análises similares às da seção anterior para dois sistemas de maior porte, de 119 barras [117] e 476 barras [118], sendo este último um sistema real brasileiro. No entanto, a presente seção considera os equipamentos de medição comerciais cujos dados são fornecidos diretamente do fabricante, conforme apresentado na Tabela 4.2 e descritos no Capítulo 4.

Para os estudos de caso, é considerado a utilização dos equipamentos com os canais medindo apenas grandezas de elementos de rede diretamente conectados às respectivas barras terminais. Mais especificamente, um equipamento só pode medir tensão de sua barra terminal e só pode medir corrente de trechos diretamente conectados à sua barra terminal. Sendo assim, a Figura 6.5 ilustra a configuração dos canais de medição para cada equipamento. Além disso, é definido que a SE possui obrigatoriamente uma UMF para garantir a referência angular do sistema.

Observa-se que os equipamentos P300 e P600 podem utilizar todos os canais de medição disponíveis, enquanto que os equipamentos PQ600 e PQ700 apresentarão nesta condição canais de tensão e/ou corrente não utilizados, devido ao número limitado de elementos de rede conectados a cada barra. Vale ressaltar que os sistemas distribuição utilizados para os estudos de caso são monofásicos. O caso mais expressivo ocorre para o equipamento PQ700 que, para um sistema com barras apresentando no máximo três trechos conectados, poderá aferir apenas três correntes, deixando, portanto, de utilizar 13 canais disponíveis, haja vista que poderia efetuar a leitura de até 16 canais de corrente, conforme Tabela 4.2, se a aplicação fosse estendida a sistemas trifásicos.

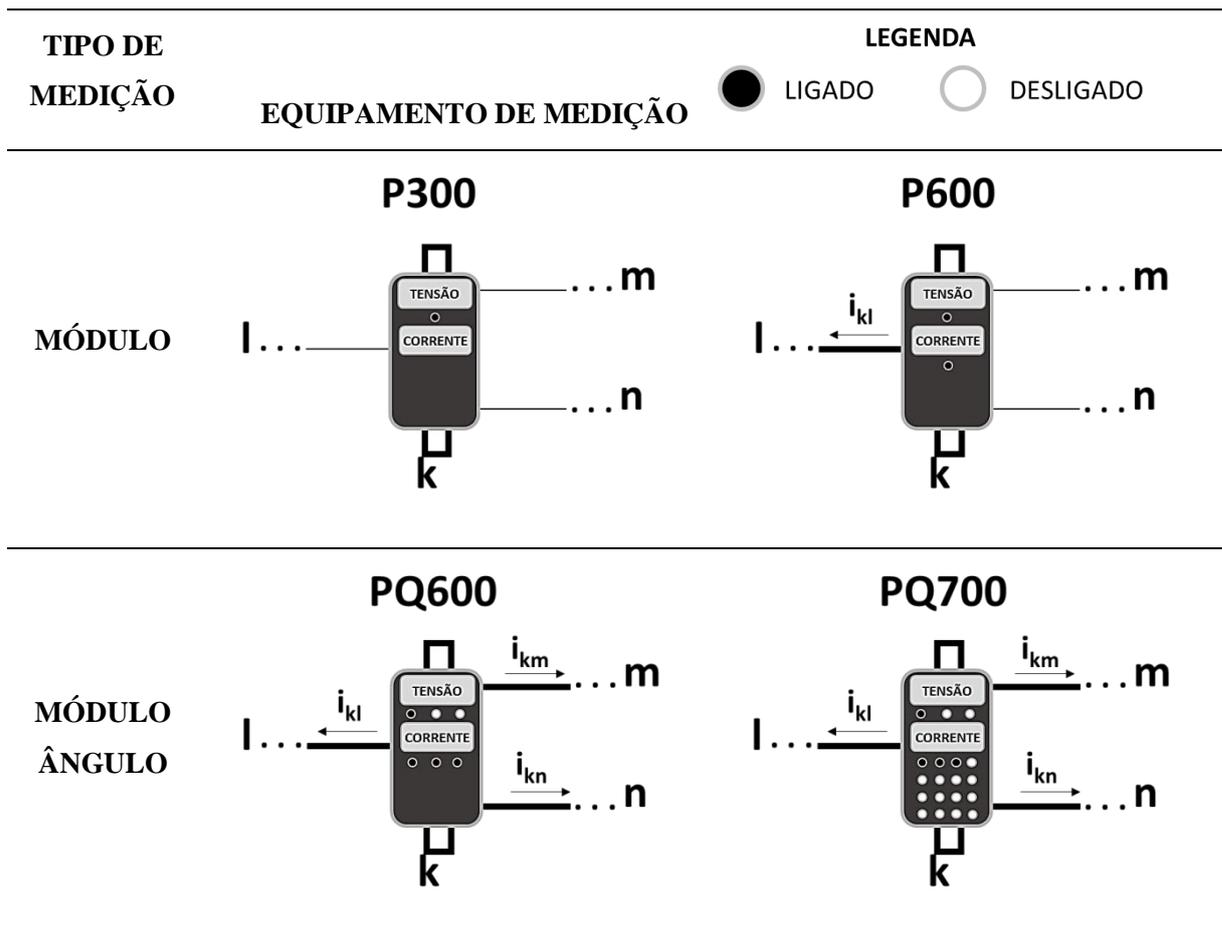


Figura 6.5 – Configuração dos Canais de Medição.

Os aspectos anteriores certamente impactam nos resultados de planejamento, pois o equipamento PQ700, por exemplo, tem número excessivo de canais disponíveis, na ausência de alimentação trifásica da rede, e alto custo. Depreende-se, portanto, de forma preliminar antes da apresentação dos resultados, que o investimento neste equipamento não seja viável nesta condição, já caracterizando de antemão a importância da representação trifásica.

Sobre os parâmetros da *FOB* (equação (4.8)), α , β e γ , como não se encontrou dados na literatura para estudos com os equipamentos comerciais em questão, uma estratégia de definição é proposta neste estudo. A estratégia envolve três passos:

- (a) Simulação sem nenhum equipamento de medição no sistema, fixando os parâmetros $\alpha = \beta = \gamma = 1$;
- (b) Simulação com a alocação do equipamento mais preciso, neste caso o PQ700, em todas as barras da rede elétrica, fixando $\alpha = \beta = \gamma = 1$;

(c) Relacionar os resultados dos passos (a) e (b) conforme formulado a seguir, onde os subscritos (a) e (b) referem-se às grandezas obtidas nos Passos (a) e (b), respectivamente:

$$I_{MVD(a)} \cdot \alpha + I_{AFD(a)} \cdot \beta + CustoInv_{(a)} \cdot \lambda = I_{MVD(b)} \cdot \alpha + I_{AFD(b)} \cdot \beta + CustoInv_{(b)} \cdot \lambda \quad (6.1)$$

para $\alpha = \beta$ e $CustoInv_{(a)} = 0$

$$\begin{aligned} (I_{MVD(a)} + I_{AFD(a)}) \cdot \alpha &= (I_{MVD(b)} + I_{AFD(b)}) \cdot \alpha + CustoInv_{(b)} \cdot \lambda \\ (I_{MVD(a)} + I_{AFD(a)}) \cdot \alpha - (I_{MVD(b)} + I_{AFD(b)}) \cdot \alpha &= CustoInv_{(b)} \cdot \lambda \\ (I_{MVD(a)} + I_{AFD(a)} - I_{MVD(b)} - I_{AFD(b)}) \cdot \alpha &= CustoInv_{(b)} \cdot \lambda \\ \frac{\alpha}{\lambda} &= \frac{CustoInv_{(b)}}{(I_{MVD(a)} + I_{AFD(a)} - I_{MVD(b)} - I_{AFD(b)})} \end{aligned}$$

A aplicação desta estratégia de definição de parâmetros ao sistema de 119 barras, a seguir, elucida e explica a fundamentação para sua concepção.

6.2.1 Sistema de 119 barras

O sistema 119 barras, de 11 kV e ilustrado na Figura 6.6, é composto de uma SE, S1 na figura, e 133 trechos de distribuição, dos quais 15 operam normalmente abertos. Os dados do sistema podem ser encontrados em [117]. Para o estudo de caso em questão, é utilizado apenas a configuração topológica da Figura 6.6 e assim, o sobrescrito “c” da equação (4.8) é dado por $c = 1$.

A Tabela 6.8 apresenta os resultados obtidos nas simulações dos passos (a) e (b) para a definição dos parâmetros α , β e γ , conforme descrito anteriormente.

Tabela 6.8 – Resultados dos Passos (a) e (b), sistema 119 barras.

Passo	I_{MVD} (%)	I_{AFD} (crad)	Custo Inv. (R\$)	FOB (u.c.)
(a)	9,251888	1,252242	0,00	10,504130
(b)	0,351468	0,007907	2.383.875,00	2.383.875,359375

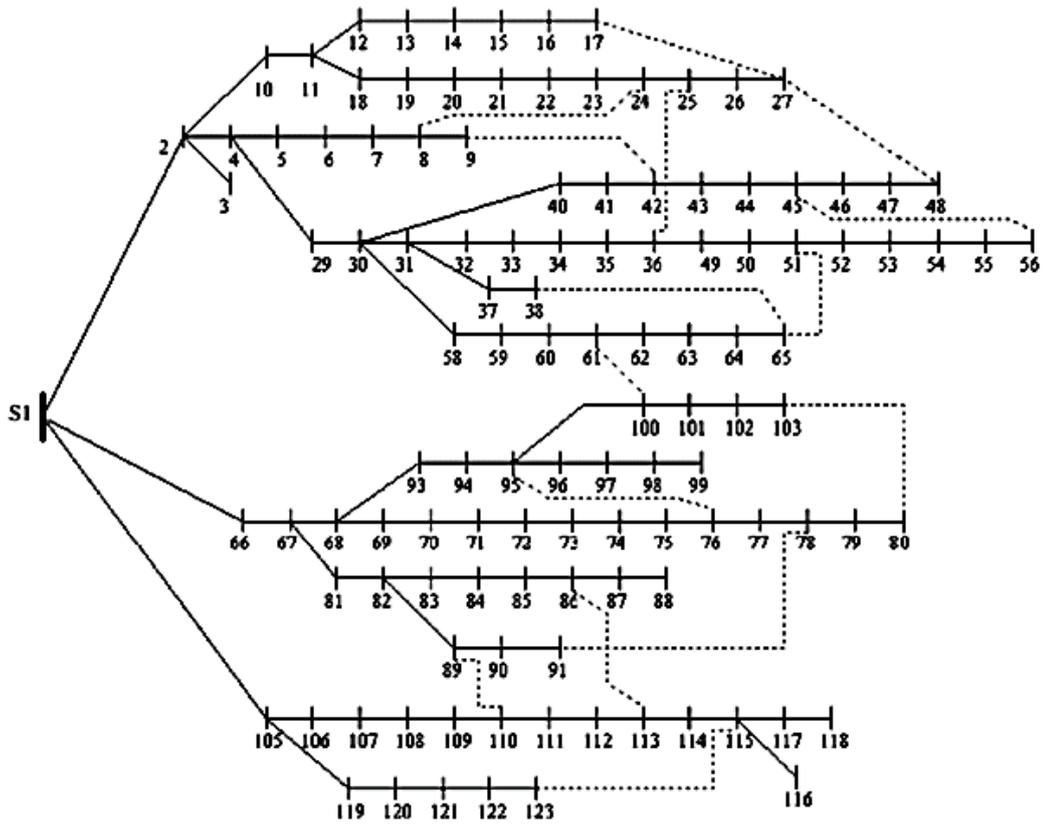


Figura 6.6. Sistema 119 barras.

Substituindo os valores da Tabela 6.8 no sistema de equações (6.1), obtém-se $\alpha = \beta = 235$ e $\gamma = 10^{-3}$. Daí, refazendo os passos (a) e (b), porém com estes valores atualizados dos parâmetros, obtém-se os resultados da Tabela 6.9, onde se pode observar uma maior aproximação entre os valores obtidos para ambas as simulações. Ou seja, os valores obtidos pelo sistema de equações (6.1) aproximam os resultados para uma situação extrema, sem investimento algum em medição ou passo (a), daqueles para outra situação extrema, com investimento mais elevado possível em medição ou passo (b). Portanto, os parâmetros obtidos da resolução deste sistema de equações minimizam a distância entre as duas situações extremas definidas ou, em outras palavras, estabelecem um compromisso adequado entre menor custo, passo (a), e melhor desempenho do estimador, passo (b).

Tabela 6.9 – Resultados dos passos com parâmetros ótimos, sistema 119 barras.

Passo	I_{MVD} (%)	I_{AFD} (crad)	Custo Inv. (R\$)	FOB (u.c.)
(a)	2174,193652	294,276859	0,000000	2468,470511
(b)	82,595070	1,858031	2.383,875000	2468,328101

A Tabela 6.10 apresenta os resultados obtidos pelo algoritmo *MMS* proposto e pelas outras metaheurísticas desenvolvidas para fins de comparação, envolvendo parâmetros da *FOB* e tempo computacional. Destaca-se que as barras dos equipamentos têm suas tensões monitoradas pelos mesmos. Além disto, os equipamentos medem as correntes dos trechos de distribuição também informados na tabela. A Figura 6.7 apresenta a configuração de equipamentos na rede elétrica deste sistema para a solução do *MMS*.

Tabela 6.10 – Resultados, sistema 119 barras, equipamentos comerciais.

Método	<i>MMS</i>	AG	RS
I_{MVD} (%)	0,504549	0,575520	0,573170
I_{AFD} (crad)	0,115993	0,079100	0,289434
Custo Inv.(R\$)	69.6950,00	94.0000,00	64.7300,00
$\alpha^*(I_{MVD})$	118,568914	135,247240	134,694920
$\beta^*(I_{AFD})$	27,258403	18,588605	68,016896
$\gamma^*(\text{Custo Inv.})$	69,695000	94,000000	64,730000
FOB (u.c.)	215,522317	247,835846	267,441816
P300 (Barras)	37, 102, 114	13, 83, 103, 114, 116	33, 74, 86, 103, 113
P600 (Barras)	13, 41, 66, 74	30, 46, 50, 102	4, 50, 66
PQ600 (Barras)	-	74	13
PQ700 (Barras)	51	77	-
Correntes P600 (Trechos)	12-13, 40-41, 66-67, 74-75	46-47, 49-50, 30-58, 101-102	40-41, 50-51, 66-67
Correntes PQ600 (Trechos)	-	73-74, 74-75	12-13, 13-14
Correntes PQ700 (Trechos)	50-51, 51-52	76-77, 77-78	-
Tempo (minutos)	19,16	31,67	46,71

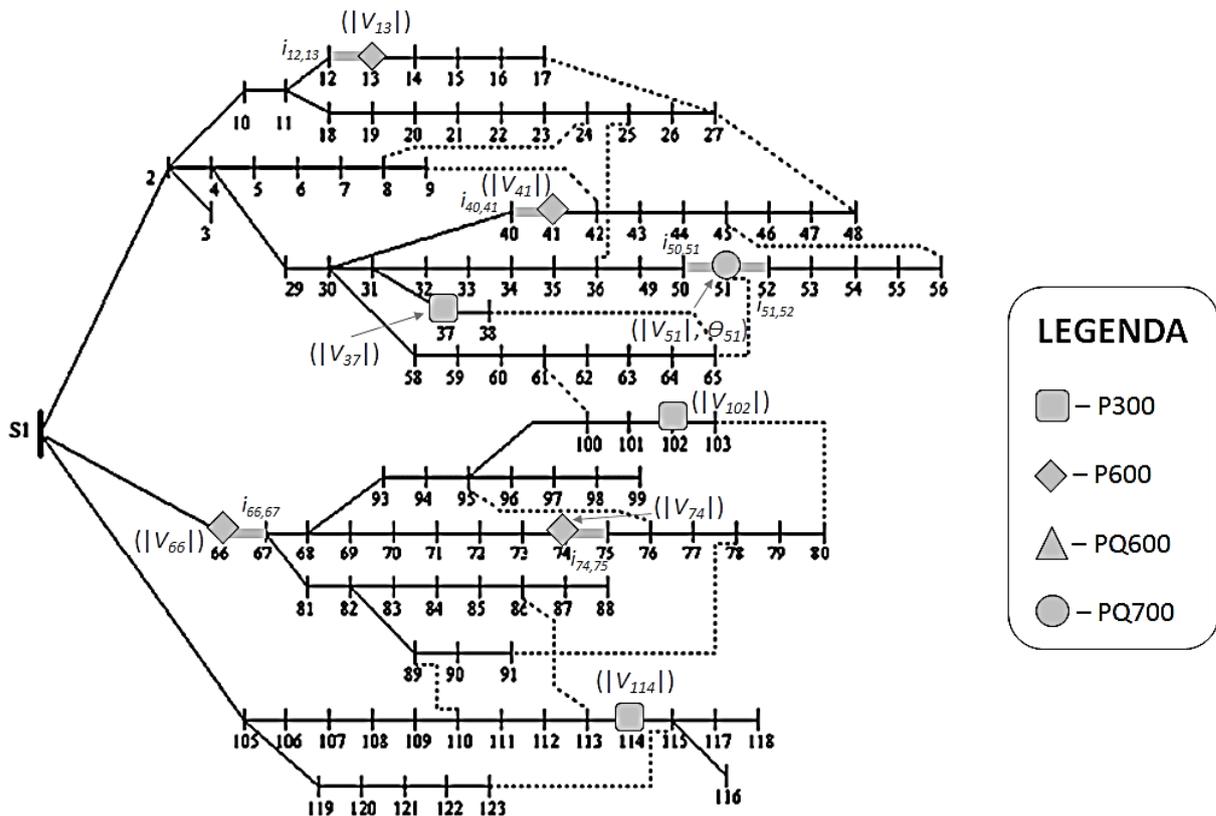


Figura 6.7 – Configuração da medição, sistema 119, equipamentos comerciais.

Observa-se nos resultados da Tabela 6.10, que a alocação estabelecida pelas ferramentas de busca *MMS*, *AG* e *RS* possuem uma maior quantidade de MIs alocados do que UMFs, ou seja, um número maior de MIs é alocado, pois uma decisão por UMF implicaria em canais ociosos, considerando a condição monofásica do sistema de distribuição. A melhor solução obtida via *MMS* determina o investimento em sete medidores inteligentes, P300 ou P600, e uma unidade de medição fasorial PQ700. Esta configuração de medidores permite medir correntes de seis trechos, sendo quatro monitorados pelo P600 e dois pelo PQ700, de acordo com a Tabela 6.10.

6.2.2 Sistema de 476 barras

O sistema de 476 barras [118] consiste em uma rede elétrica real de distribuição primária de médio porte de concessionária brasileira, parcialmente ilustrado na Figura 6.8. Esta rede é composta por dois alimentadores aéreos urbanos com tensão de 13,8 kV e 475 trechos. A SE é localizada na barra de código ‘1000’. Assim como no sistema anterior de 119 barras, é utilizado

apenas uma configuração topológica, ou seja, da Figura 6.8 e assim, o sobrescrito “*c*” da equação (4.8) é dado por $c = 1$.

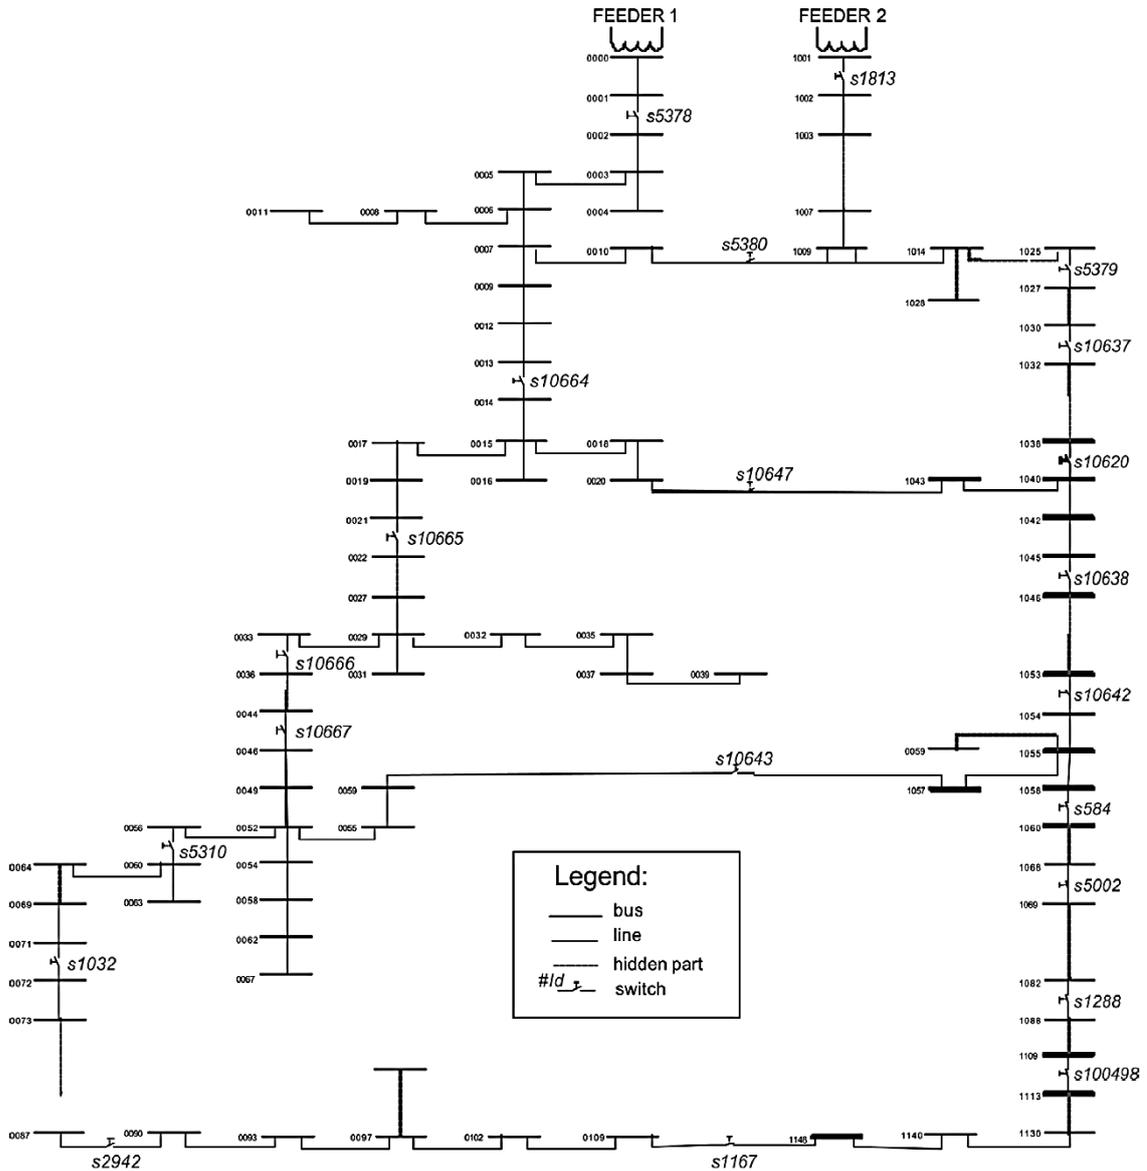


Figura 6.8. Sistema 476 barras.

Os valores dos parâmetros da função objetivo obtidos com a mesma estratégia descrita para o sistema anterior de 119 barras, ou seja, utilizando o modelo de equação (6.1), são dados por $\alpha = \beta = 1.653$ e $\gamma = 10^{-3}$. A Tabela 6.11 apresenta os resultados obtidos para as três ferramentas de busca analisadas.

Tabela 6.11 – Resultados, sistema 476 barras, equipamentos comerciais.

Método	MMS	AG	RS
I_{MVD} (%)	0,335769	0,361749	0,367938
I_{AFD} (crad)	0,110595	0,097216	0,084793
Custo Inv. (R\$)	137.2250,00	174.7500,00	245.0350,00
$\alpha^*(I_{MVD})$	555,025604	597,971548	608,201834
$\beta^*(I_{AFD})$	182,813197	160,698587	140,163397
$\gamma^*(\text{Custo Inv.})$	137,225000	174,750000	245,035000
FOB (u.c.)	870,063801	933,420135	993,400231
P300 (Barras)	59,157, 400, 442, 450	349, 374, 407	46, 93, 157, 242, 319
P600 (Barras)	46, 148, 158, 216, 225, 242, 269, 270, 340, 407	59, 158, 216, 269, 400, 429, 442, 460, 466	2, 32, 59, 230, 268, 281, 340, 450, 466
PQ600 (Barras)	-	28, 203, 230, 319	48, 270, 429, 442
PQ700 (Barras)	32	450	97, 203, 400, 460
Correntes P600 (Trechos)	46-44, 148-142, 158-152, 220-216, 225-221, 242-239, 269-266, 275-270, 340-335, 407-398	59-55, 158-152, 216-207, 269-266, 400-390, 429-426, 447-442, 460-455, 472-466	3-2, 32-30, 59-55, 234-230, 268-265, 281-277, 340-335, 450-443, 472-466
Correntes PQ600 (Trechos)	-	28-25, 30-28, 203-196, 230-224, 234-230, 235-230, 319-318, 320-319	48-46, 51-48, 270-266, 274-270, 275-270, 429-426, 433-429, 442-437, 447-442
Correntes PQ700 (Trechos)	32-30	450-443	97-94, 100-97, 203-196, 400-390, 408-400, 460-455, 466-460
Tempo (minutos)	35,84	49,28	65,78

Comportamento análogo ao descrito para o sistema de 119 barras também se verifica para a rede real de 476 barras, ou seja, as soluções obtidas pelas ferramentas de busca descritas acima, tendem a alocar uma maior quantidade de MIs devido a configuração monofásica do

sistema em questão. Também para o sistema de 476 barras, o algoritmo *MMS* proposto conduz ao melhor resultado, sob o ponto de vista da função objetivo da metodologia de alocação ótima, se comparado com as técnicas AG e RS desenvolvidas.

6.3 RESULTADOS PARA O MODELO DE PLANEJAMENTO MULTIOBJETIVO

Esta seção tem como objetivo apresentar os resultados e a potencialidade da metodologia proposta para gerar múltiplos planos de monitoramento de SDE através de uma abordagem multiobjetivo via conceitos de dominância de Pareto. Esta abordagem é mais adequada para tratar objetivos de diferentes naturezas e, inclusive, conflitantes entre si, como a minimização do custo de investimento em equipamentos de medição comerciais, considerados nos estudos da seção anterior, e a maximização de qualidade do processo de estimação de estados a partir das medidas provenientes destes equipamentos. Destaca-se que esta maximização de qualidade está associada à minimização de índices de estimação previamente definidos.

Destaca-se ainda que o modelo de planejamento multiobjetivo dispensa a necessidade de determinação dos parâmetros da função objetivo, conforme descrito para o modelo mono-objetivo. Os sistemas de 119 e 476 barras descritos anteriormente são novamente utilizados nestes estudos.

6.3.1 Planejamento Multiobjetivo - sistema de 119 barras

Neste caso, a população inicial é constituída por 16 soluções candidatas, divididas pela metade entre as matrizes *A*, não-dominadas, e *P*, dominadas, do método de Pareto, conforme descrito no tutorial apresentado no Capítulo 4. A Figura 6.9 e a Tabela 6.12 apresentam, respectivamente, as fronteiras de Pareto para a população inicial e os dados das soluções candidatas das matrizes *A* e *P* para esta população.

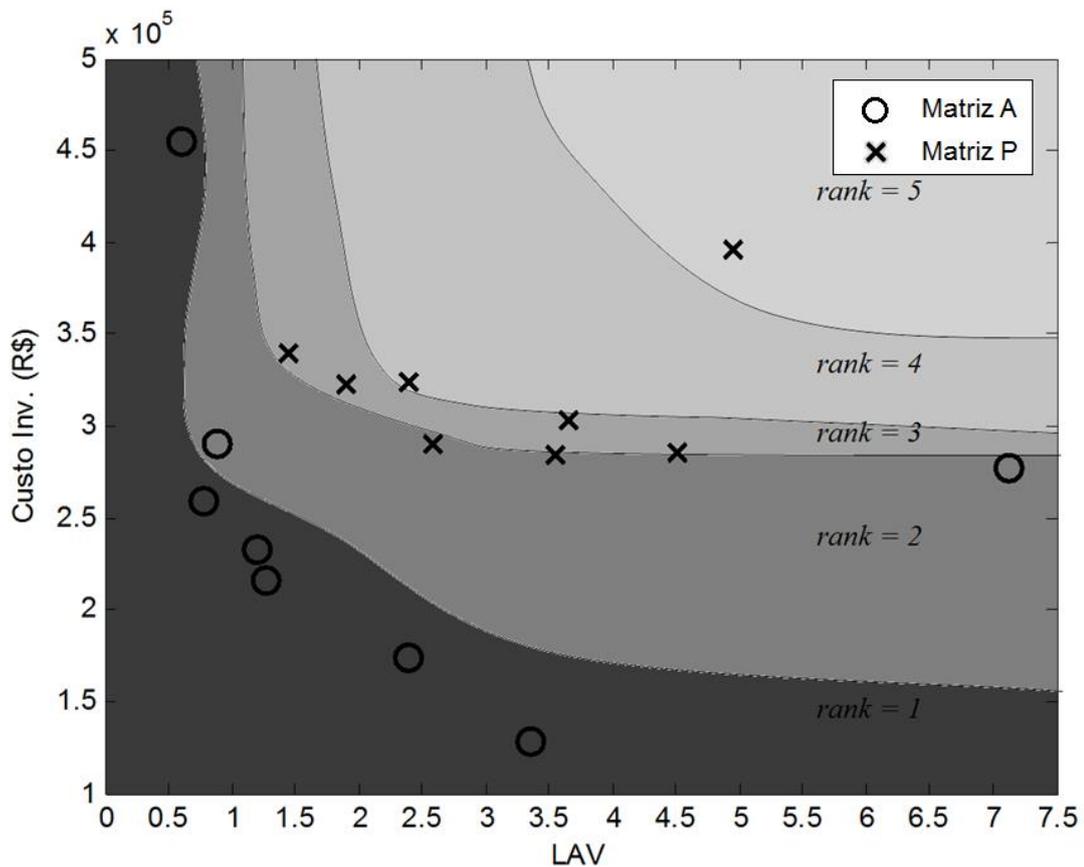


Figura 6.9 – Fronteiras de Pareto para a população inicial, sistema 119 barras.

Observa-se na Tabela 6.12 que a matriz *A* recebe, neste caso, 6 soluções da primeira fronteira, *rank* = 1, e, para completar as oito soluções que devem compor *A*, duas soluções candidatas da segunda fronteira, *rank* = 2, são selecionadas pelo critério de maior distância do respectivo aglomerado descrito no Capítulo 4. A melhor solução candidata é destacada da Tabela 6.12 segundo o critério da aptidão. Vale ressaltar que a avaliação de aptidão é calculada apenas para a matriz *A*, que é a parte que evolui no *MMS*.

Após a convergência do algoritmo *MMS* proposto, as soluções obtidas na primeira fronteira de Pareto são apresentadas na Figura 6.10, cujos dados são detalhados nas Tabela 6.13, Tabela 6.14 e Tabela 6.15.

Tabela 6.12 – Dados da população inicial, sistema 119 barras.

Matriz	LAV	Custo Inv. (R\$)	Rank	Distância	Aptidão
A	0,6095	454.430,00	1	$1,20 \cdot 10^{11}$	$2,38 \cdot 10^5$
	3,3641	127.910,00	1	$1,20 \cdot 10^{11}$	$1,49 \cdot 10^5$
	2,3838	173.300,00	1	$6,17 \cdot 10^{00}$	$1,03 \cdot 10^5$
	0,7780	259.470,00	1	$5,36 \cdot 10^{00}$	$8,62 \cdot 10^4$
	1,2752	216.045,00	1	$3,67 \cdot 10^{00}$	$7,48 \cdot 10^4$
	1,1964	232.135,00	1	$1,88 \cdot 10^{00}$	$5,88 \cdot 10^4$
	0,8834	290.795,00	2	$8,00 \cdot 10^{10}$	$1,67 \cdot 10^{-1}$
	7,1187	276.670,00	2	$8,00 \cdot 10^{10}$	$1,67 \cdot 10^{-1}$
P	3,5405	283.805,00	2	$6,74 \cdot 10^{01}$	-
	2,5904	290.205,00	2	$3,68 \cdot 10^{01}$	-
	1,4524	339.420,00	3	$8,00 \cdot 10^{11}$	-
	4,5131	285.605,00	3	$8,00 \cdot 10^{11}$	-
	1,8984	322.710,00	3	$4,16 \cdot 10^{01}$	-
	3,6537	309.705,00	3	$6,18 \cdot 10^{01}$	-
	2,3891	324.425,00	4	$2,00 \cdot 10^{11}$	-
	4,9427	395.520,00	5	$2,00 \cdot 10^{11}$	-

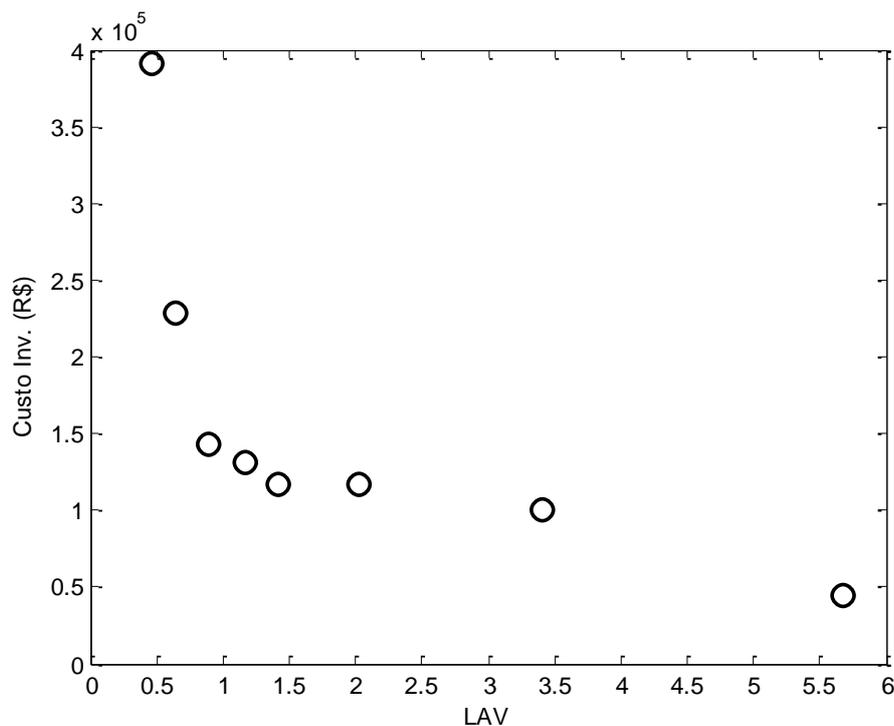


Figura 6.10 – Primeira fronteira obtida pelo *MMS-Pareto*, sistema 119 barras.

Tabela 6.13 – Opções de planejamento, sistema 119 barras - barras monitoradas.

Equipamento/ Solução	P300	P600	PQ600	PQ700
1	6, 31, 43, 58	3, 60, 69, 82, 88, 111	9, 11, 14, 23, 36, 51, 80, 101, 112	5, 12, 17, 25, 32, 45, 46, 71, 122
2	6, 20, 31, 43, 55, 58, 61, 107	3, 21, 60, 69, 70, 82, 87, 88, 111	9, 11, 14, 51	45
3	6, 13, 20, 31, 43, 55, 58, 61, 72, 107	3, 60, 70, 111	-	5, 17, 46
4	13, 31	-	23, 36, 61, 80	32, 71, 113
5	72	69, 82, 111	51, 101, 112	25, 54
6	6, 20 31, 58, 72, 107	3, 21, 47, 60, 69, 70, 82, 87, 88, 111	-	-
7	6, 31, 55	-	14, 23, 51	5, 71
8	13, 20, 43	-	51, 69	-

Tabela 6.14 – Opções de planejamento, sistema 119 barras - trechos monitorados.

Equipamento/ Solução	P300	P600	PQ600	PQ700
1	-	2-3, 59-60, 69-70, 87-88, 82-89, 111-112	8-9, 10-11, 13-14, 14-15, 11- 18, 22-23, 23-24, 35-36, 36-49, 50-51, 51-52, 79-80, 100-101, 101-102, 112-113	4-5, 5-6, 11-12, 12-13, 16-17, 24-25, 25-26, 31-32, 32-33, 44-45, 45-46, 46-47, 70-71, 71-72, 121-122, 122-123
2	-	2-3, 21-22, 59-60, 68-69, 70- 71, 81-82, 86-87, 87-88, 82-89, 110-111	8-9, 10-11, 11-12, 13-14, 14-15, 11-18, 50-51, 51-52, 100-101, 101-102, 111-112, 112-113	44-45, 45-46
3	-	2-3, 60-61, 69-70, 111-112	-	4-5, 5-6, 16-17, 45-46, 46-47
4	-	-	22-23, 23-24, 35-36, 36-49, 60-61, 61-62, 79-80	31-32, 32-33, 70-71, 71-72, 112-113, 113-114
5	-	69-70, 82-89, 110-111	50-51, 51-52, 100-101, 101-102, 111-112, 112-113	24-25, 25-26, 53-54, 54-55
6	-	2-3, 20-21, 47-48, 59-60, 69-70, 70-71, 81-82, 87-88, 111-112	-	-
7	-	-	13-14, 14-15, 22-23, 23-24, 50- 51, 51-52	4-5, 5-6, 70-71, 71-72
8	-	-	50-51, 51-52, 68-69, 69-70	-

Tabela 6.15 – Opções de planejamento, sistema 119 barras - objetivos e parâmetros.

Solução	LAV	Custo Inv. (R\$)	Rank	Distância
1	0,4638 (96%)	391.370,00	1	$1,80 \cdot 10^{11}$
2	0,6383 (94%)	227.940,00	1	$7,19 \cdot 10^{00}$
3	0,8936 (91%)	142.505,00	1	$3,04 \cdot 10^{00}$
4	1,1708 (89%)	130.865,00	1	$1,16 \cdot 10^{00}$
5	1,4145 (87%)	117.450,00	1	$1,84 \cdot 10^{00}$
6	2,0200 (81%)	116.430,00	1	$3,90 \cdot 10^{00}$
7	3,4119 (68%)	99.925,00	1	$8,19 \cdot 10^{00}$
8	5,6750 (46%)	44.030,00	1	$1,80 \cdot 10^{11}$

Os valores de “%” referentes a segunda coluna da Tabela 6.15 representam o impacto em termos de desempenho do estimador em comparação com o Caso Base do sistema, ou seja, $LAV = 10,504130$, conforme dados da Tabela 6.8. A escolha da solução da Tabela 6.15 está ligada diretamente ao orçamento disponível da concessionária e ao desempenho do estimador.

6.3.2 Planejamento Multiobjetivo - sistema de 476 barras

Assim como no estudo anterior, uma população inicial constituída por 16 soluções candidatas, divididas igualmente entre as matrizes P (dominadas) e A (não-dominadas), é definida para o sistema de 476 barras. A Figura 6.11 apresenta as fronteiras de Pareto para as oito soluções candidatas da matriz A , submetida ao processo evolutivo do MMS . Vale ressaltar que a solução candidata de A com melhor aptidão encontra-se na primeira fronteira e é utilizada na evolução da população pelo MMS .

Após a convergência do MMS , as soluções obtidas são ilustradas pelos pontos da Figura 6.12, cujos dados são detalhados nas Tabela 6.16, Tabela 6.17 e Tabela 6.18. Observa-se que, diferentemente dos sistemas anteriores, cujas soluções finais encontram-se todas na primeira fronteira, o sistema de 476 barras apresenta cinco de suas oito soluções obtidas na primeira fronteira, destacadas nas tabelas citadas. O comportamento observado pode ocorrer para o problema em questão e, neste caso, as soluções da primeira fronteira são de interesse para o planejador, pois aliam um compromisso adequado entre os dois objetivos considerados, uma vez que não são piores, sob o ponto de vista dos dois objetivos simultaneamente, em relação a qualquer outra solução.

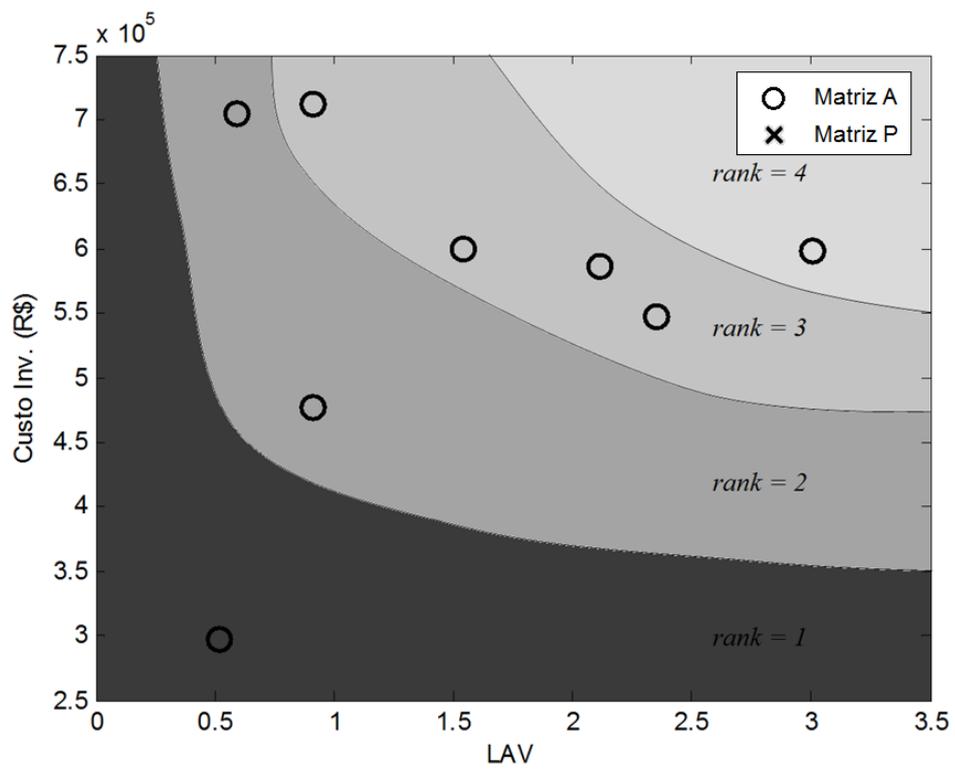


Figura 6.11 – Fronteiras de Pareto para a população inicial, sistema 476 barras.

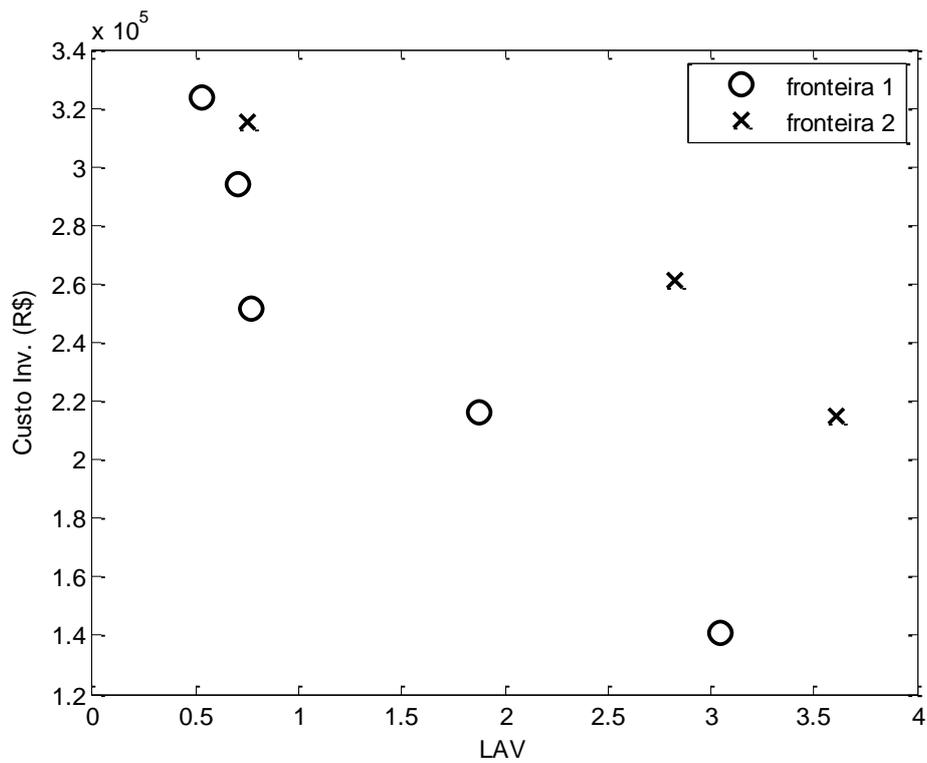


Figura 6.12 – Fronteiras de Pareto para a população final, sistema 476 barras.

Tabela 6.16 – Opções de planejamento, sistema 476 barras - barras monitoradas.

Equipamento/ Solução	P300	P600	PQ600	PQ700
1	134, 145, 214, 347, 371, 372,392, 430, 433, 462	19, 93, 167, 294, 344, 399, 407, 428, 437	95, 186, 276, 423, 426	102, 160, 199, 253, 272, 444
2	371	16, 19, 57, 82, 86, 93, 111, 119,136,167, 248, 273, 294, 334, 344, 352, 378, 381, 399, 401, 407, 428, 437, 458	97, 98, 130, 184, 426	-
3	25, 116, 371, 392, 462	19, 57, 82, 86, 93, 111, 119, 136, 167, 183, 273, 294, 334, 352, 378, 381, 399, 401, 407, 437	33, 426	169
4	127, 138,144, 160, 201, 383,392	19, 82, 119, 167, 248, 294, 344, 378, 399, 407, 428	22, 426, 448	230, 359
5	197, 205,315, 316, 453	248, 352, 401	27, 277	131, 318, 390
6	288, 364, 371, 383, 392, 462	19, 57, 93, 111, 119, 136, 167, 183, 248, 294, 344, 352, 378, 401, 407, 428, 437	6, 28, 140, 213, 338	9, 26, 423
7	63, 238, 265, 358, 472	19, 86, 381, 407	22, 119, 242, 250, 257, 289, 308, 426	120, 228, 443, 454
8	240, 392, 462	93, 111, 136, 248, 334	85, 130, 133, 180, 289, 314, 340, 423, 426	291

Tabela 6.17 – Opções de planejamento, sistema 476 barras - trechos monitorados.

Equipamento/ Solução	P300	P600	PQ600	PQ700
1	-	19-16, 95-93, 169-167, 295-294, 344-338, 399-389, 407-398, 428-422, 442-437	99-95, 186-181, 191-186, 192-186, 280-276, 423-417, 426-419, 429-426, 430-426	102-98, 108-102, 109-102, 160-152, 165-160, 199-191, 207-199, 253-251, 272-267, 276-272, 277-272, 444-440, 451-444
2	-	19-16, 21-19, 57-53, 82-80, 86-81, 93-90, 111-105, 125-119, 141-136, 169-167, 248-244, 279-273, 294-292, 338-334, 349-344, 357-352, 378-374, 381-375, 399-389, 401-392, 407-398, 428-422, 437-432, 463-458	97-94, 100-97, 101-98, 102-98, 103-98, 130-126, 136-130, 137-130, 184-179, 190-184, 426-419, 429-426, 430-426	-
3	-	21-19, 57-53, 82-80, 86-81, 95-93, 111-105, 125-119, 141-136, 167-165, 183-179, 273-270, 294-292, 334-331, 352-347, 378-374, 390-381, 399-389, 401-392, 407-398, 441-437	33-30, 36-33, 426-419, 429-426, 430-426	169-167, 172-169
4	-	19-16, 88-82, 119-113, 170-167, 250-248, 295-294, 348-344, 378-374, 399-389, 407-398, 432-428	22-20, 23-22, 426-419, 429-426, 430-426, 448-443, 452-448	230-224, 234-230, 235-230, 359-354, 364-359
5	-	248-244, 357-352, 401-392	27-24, 277-272, 281-277	131-127, 138-131, 318-316, 319-318, 390-381, 400-390
6	-	21-19, 61-57, 93-90, 111-105, 125-119, 136-130, 167-165, 183-179, 250-248, 294-292, 348-344, 352-347, 378-374, 401-392, 407-398, 428-422, 437-432	6-4, 7-6, 28-25, 30-28, 140-135, 145-140, 213-202, 338-334, 344-338	9-7, 12-9, 26-24, 29-26, 423-417
7	-	19-16, 86-81, 390-381, 407-398	22-20, 23-22, 119-113, 125-119, 242-239, 250-248, 252-250, 257-255, 289-287, 291-289, 308-307, 309-308, 426-419, 429-426, 430-426	120-113, 126-120, 228-222, 232-228, 443-440, 448-443, 449-443, 454-451, 457-454
8	-	93-90, 111-105, 136-130, 248-244, 334-331	85-81, 130-126, 133-128, 137- 130, 139-133, 180-176, 185- 180, 298-287, 314-313, 317- 314, 340-335, 346-340, 423- 417, 426-419, 429-426, 430- 426	291-289, 293-291

Tabela 6.18 – Opções de planejamento, sistema 476 barras - Objetivos e parâmetros.

Solução	LAV	Custo Inv. (R\$)	Rank	Distância
1	0,5274 (92%)	323.830,00	1	$1,00 \cdot 10^{11}$
2	0,7013 (89%)	293.785,00	1	$2,46 \cdot 10^{00}$
3	0,7685 (88%)	251.465,00	1	$4,45 \cdot 10^{00}$
4	1,8730 (70%)	216.090,00	1	$7,54 \cdot 10^{00}$
5	3,0437 (52%)	141.000,00	1	$1,00 \cdot 10^{11}$
6	0,7549	315.545,00	2	$6,00 \cdot 10^{10}$
7	2,8244	261.140,00	2	$6,00 \cdot 10^{00}$
8	3,6060	214.895,00	2	$6,00 \cdot 10^{10}$

Assim como na análise do sistema de 119 barras do caso anterior, os valores de “%” referentes a segunda coluna da Tabela 6.18 representam o impacto em termos de desempenho do estimador em comparação com o Caso Base do sistema, ou seja, $LAV = 6,297399$. A escolha da solução da Tabela 6.18 está ligada diretamente ao orçamento disponível da concessionária e ao desempenho do estimador. Vale ressaltar que as soluções ‘6’, ‘7’ e ‘8’ da Tabela 6.18 são descartados como opções de investimento por não terem relação de compromisso e pertencerem a fronteira 2 de Pareto.

6.4 CONSIDERAÇÕES FINAIS

Este capítulo apresentou os resultados obtidos pela aplicação da metaheurística *MMS* ao problema de planejamento de medição em sistemas de distribuição. Estes resultados demonstram que a localização de sistemas de medição não é predeterminada na topologia de uma rede de distribuição, o que reforça a importância da metodologia de alocação ótima proposta. Adicionalmente, os estudos demonstram a aplicabilidade da metodologia proposta por envolver dados imprecisos de demanda e variações topológicas que normalmente ocorrem na operação, estendendo, portanto, sua potencialidade para redes dinâmicas e inteligentes. A abordagem mono-objetivo envolve um procedimento de determinação de coeficientes da função objetivo, a partir de dados do sistema e dos equipamentos candidatos, abrangendo medidores comerciais. No entanto, esta necessidade não se verifica na abordagem multiobjetivo, o que consiste em uma vantagem desta. Outra vantagem da abordagem

multiobjetivo é a possibilidade de geração de planos que aliam bom compromisso entre os objetivos conflitantes do problema, alternativos para uma decisão assistida pelo planejador com base em prioridades da distribuidora.

7 CONCLUSÕES

7.1 CONSIDERAÇÕES FINAIS

A presente tese de doutorado propôs uma metodologia de planejamento de sistemas de monitoramento em redes de distribuição de energia elétrica, tipos de medidores, entre medidores inteligentes e unidades de medição fasorial, incluindo equipamentos comerciais, além dos trechos para monitoramento de corrente. Os objetivos são maximizar a qualidade do processo de estimação de estados, associada à minimização de índices de estimação previamente definidos, a partir das medidas provenientes dos equipamentos alocados e minimizar o custo total de investimento nos sistemas de medição para prover tais medidas. Para solucionar este problema, com objetivos conflitantes foi proposto o modelo multiobjetivo via Pareto, associado a técnica de otimização metaheurística *Modified Monkey Search*, para lidar com as variáveis inteiras referentes às decisões sobre os locais (barras e trechos monitorados) e os tipos de equipamentos a serem alocados (UMF e MI).

A abordagem multiobjetivo é adequada para tratar o problema em questão por dispensar a determinação de coeficientes de uma única função de mérito, necessária em modelo mono-objetivo. A tese também apresenta um modelo mono-objetivo com determinação destes coeficientes a partir de dados da rede de distribuição sob análise e de equipamentos de medição candidatos. No entanto, a abordagem multiobjetivo tem a vantagem de possibilitar a geração de planos alternativos de boa qualidade em termos de compromisso entre os objetivos citados, para um processo decisório posterior assistido pelo planejador em função de prioridades e necessidades da distribuidora de energia.

A metodologia utiliza um novo método, também proposto nesta tese, para executar o processo de estimação de estados para cada solução candidata a alocação ótima de medidores. Este método é baseado em um modelo de fluxo de potência ótimo modificado, cuja resolução é dada pela técnica matemática de pontos interiores. As modificações propostas no FPO, que resultaram no novo modelo *E-OPF* proposto, mostraram-se adequadas para aplicação em sistemas de distribuição, por permitir uma boa estimação de estados a partir de dados imprecisos de demanda para redes com variações topológicas durante sua operação. Destaca-se que a falta de observabilidade para o processo de estimação de estados é verificada em SDE.

A técnica *MMS-Pareto* proposta mostrou-se eficiente em termos de qualidade das soluções obtidas e tempos de processamento para o problema de planejamento objeto desta tese, mesmo diante da complexidade advinda das condições reais de operação consideradas, sistemas reais e equipamentos comerciais. Uma importante conclusão é que a alocação ótima de equipamentos de medição em SDE é tema relevante, pois os melhores pontos ou barras para monitoramento não seguem, necessariamente, a estrutura topológica, ou seja, para o efeito de qualidade como considerado.

O processo de estimação de estados combina medidas fornecidas por equipamentos alocados, pseudo-medidas e medições provenientes das subestações, a fim de analisar condições reais de monitoramento. Outro destaque é que por ser capaz de levar em conta mudanças topológicas, que inevitavelmente ocorrem na operação de redes ativas e inteligentes, a metodologia proposta é particularmente adequada neste cenário mediante as condições de chaveamento onde os trechos normalmente aberto (NA) devem ser restritos à alocação de medidores.

Estudos de casos envolvendo sistema real de médio porte comprovam a aplicabilidade da metodologia proposta e sua potencialidade para a geração de planos alternativos para o problema de planejamento da medição. As análises consideram equipamentos comerciais diversos e de diferentes características de monitoramento, a fim de avaliar a robustez da metodologia. Os tempos viáveis ao problema de planejamento e a qualidade das soluções obtidas em termos de otimização do processo de estimação, com minimização de custos envolvidos, comprovam esta metodologia como potencial para o problema de planejamento da medição.

Por fim, destaca-se que uma decisão assertiva sobre o problema deve balizar-se, além de resultados alternativos de ferramentas computacionais, como a proposta nesta tese, em outros fatores, como a realidade financeira da distribuidora e os requisitos operacionais do sistema em questão. A presente proposta visou, portanto, contribuir para este processo oferecendo as opções alternativas e de boa qualidade em termos dos compromissos visados, para acelerar e dar suporte ao processo decisório em pauta.

7.2 PROPOSTA DE CONTINUIDADE

- Desenvolvimento de outros métodos de otimização para resolução mais eficiente do *E-OPF* proposto, como o método de pontos interiores com função barreira de segurança.
- Desenvolvimento de um estimador dinâmico para a aplicação na operação considerando medições em tempo real.
- Aplicação de técnicas de avaliação de erros grosseiros ao processo de estimação de estados para eliminar possíveis falhas nas medições dos equipamentos.
- Aplicação da metodologia proposta em sistemas de distribuição trifásicos com características de carga desequilibrada, bem como sob cenários distintos de carga tais como cargas leve, média e pesada e mudanças de carga ao longo do dia.
- Validação do método para cenários atuais, envolvendo o uso de fontes renováveis de energia, redes ativas devido à inserção de geração distribuída, análise de contingências e cenários de restabelecimento.

APÊNDICE A

A.1 CONSIDERAÇÕES INICIAIS

A técnica de otimização de bio-inspirada conhecida como *Monkey Search (MS)* foi desenvolvida em [119] e [120]. Esta técnica é inspirada no comportamento de um macaco à procura de alimentos numa selva. Essa pesquisa é realizada através da subida e descida nas árvores que contêm fontes de alimento. À medida que a busca continua, o macaco armazena e atualiza em sua memória a melhor rota encontrada. Esta memória adaptativa é então usada para alcançar rotas mais promissoras entre várias alternativas possíveis.

Semelhante a outras técnicas baseadas em heurísticas e comportamentos bio-inspirados, o método *MS* busca determinar soluções com alta qualidade de forma eficiente computacionalmente. O algoritmo *Modified Monkey Search (MMS)* apresentado neste Apêndice é baseado no algoritmo *MS* de [119] e [120]. Ambos os algoritmos associam os mecanismos da memória adaptativa e a evolução das rotas, conforme mencionado acima, para aplicação dos processos de busca de problemas de otimização combinatória. Esta associação é resumida abaixo:

- (i). Uma árvore consiste em um conjunto de nós que estão ligados por caminhos, conforme ilustrado na Figura A.1 onde o primeiro nó "A" é a raiz.
- (ii). A raiz e os nós de uma árvore contêm fontes de alimentos relacionadas às possíveis soluções para um problema de otimização.
- (iii). Um ramo de uma árvore está associado a uma perturbação na solução atual do processo de busca que permite a transição para outra solução, em analogia com a escalada da árvore de um nó para outro.
- (iv). A memória adaptativa está associada ao armazenamento das informações adquiridas durante a exploração do espaço da solução e é usada para realizar o processo de busca.

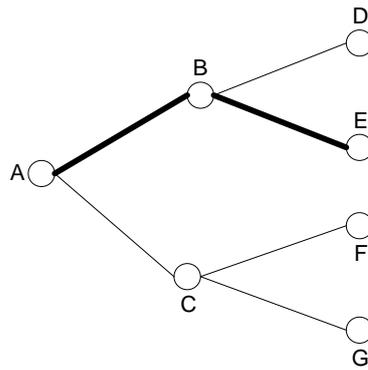


Figura A.1. A estrutura da árvore do algoritmo *MMS*.

A partir das definições anteriores, os caminhos da árvore na Figura A.1 são (i) "A-B-D", (ii) "A-B-E", (iii) "A-C-F" e (iv) "A-C-G". O nó "A" é a solução inicial e os nós restantes correspondem às soluções derivadas. Esta árvore possui três níveis, onde o primeiro nível consiste no nó "A", o segundo nível compreende os nós "B" e "C" e os nós de terceiro nível "D", "E", "F" e "G". Os nós do terceiro nível formam o topo desta árvore. O caminho destacado "A-B-E" compreende os ramos "A-B" e "B-E" e os nós "A", "B" e "E".

O processo de busca do algoritmo *MMS* pode ser dividido em duas etapas:

- (a) Pesquisa na árvore inicial: quando o método *MMS* inicia o processo de busca, não há informações sobre os caminhos a serem investigados, ou seja, não há soluções armazenadas na memória. Assim, a busca na árvore inicial envolve todos os caminhos possíveis. A partir dos resultados desta pesquisa completa, o mecanismo de memória adaptativa começa a armazenar um conjunto de soluções que servirão como referências para árvores futuras, que são referidas como árvores subsequentes.
- (b) Pesquisa em árvores subsequentes: as árvores subsequentes no método *MMS* são obtidas a partir de perturbações da melhor solução encontrada na árvore inicial. A partir da memória de referência formada na árvore inicial, o algoritmo de otimização executa uma varredura direcionada nas árvores subsequentes, evitando assim, o processo de busca em todos os caminhos e acelerando a investigação dessas árvores até um critério de convergência ser encontrado, o que será explicado posteriormente.

Os principais aspectos do algoritmo *MMS*, incluindo a definição de parâmetros, critérios de convergência e mecanismos de perturbação das soluções, são abordados a seguir.

A.2 PARÂMETROS DA ÁRVORE INICIAL

A árvore inicial envolve um conjunto de soluções obtidas a partir de um processo de busca que começa a partir de uma única solução, nó "A" na Figura A.1. Para o problema de alocação de equipamentos de medição, a solução inicial, ou seja, a raiz da árvore inicial, não é aleatória e corresponde ao Caso Base, isto é, à condição sem qualquer equipamento de medição.

O procedimento de busca na árvore inicial é completo devido à falta de informações prévias sobre o espaço da solução. No entanto, no algoritmo *MMS*, a convergência da árvore inicial é obtida quando todos os caminhos são percorridos.

Cada árvore possui um sistema estruturado binário, onde em cada nó pode ser selecionada uma das duas opções de perturbação e cada escolha leva a um novo nó. Do nó "A" da Figura A.1, o nó "B" pode ser selecionado através do ramo superior ou nó "C" através do ramo inferior. A codificação para as decisões tomadas nesta estrutura pode ser "0" para o ramo inferior e "1" para o ramo superior. Assim, o caminho coberto "ABE" é representado pelo código binário como 1-0, o que significa que este caminho consiste no ramo superior de "A" ("AB") seguido pelo ramo inferior de "B" ("BE").

A profundidade (h) de uma árvore é definida pelo número de níveis menos 1. Portanto, a profundidade da árvore na Figura A.1 é dada por $h = 3 - 1 = 2$. O número de caminhos (c) de uma árvore é limitado pelo parâmetro h de acordo com a equação (A.1).

$$c = 2^h \tag{A.1}$$

Em que:

c Número de caminhos possíveis na árvore.

h Altura da árvore

Assim, o número de caminhos na árvore da Figura A.1 é igual a $c = 2^h = 2^2 = 4$.

As rotas abordadas no algoritmo *MMS* incluem processos de subida e descida de uma árvore. Cada processo ocorre na direção oposta da fase anterior, isto é, cobrindo os mesmos nós, no entanto, na direção oposta.

O parâmetro "profundidade" da árvore (h) tem grande importância porque determina o número de caminhos a serem investigados e, conseqüentemente, o número de soluções a serem avaliadas. A escolha deste parâmetro deve considerar os seguintes aspectos:

- (a) Valor elevado de h : maior a profundidade da árvore, maior é o número de caminhos e soluções candidatas. À medida que o parâmetro h aumenta, a chance de obter uma solução de alta qualidade aumenta, mas o tempo de processamento também aumenta.
- (b) Valor baixo h : um baixo valor de h implica em tempos computacionais mais baixos para convergência do *MMS* no entanto, ele limita o espaço de busca e portanto, afeta a qualidade da solução.

Com base nesses aspectos, para escolher um valor para h que seja adequado para cada problema específico, existe um compromisso entre a qualidade da solução e os requisitos computacionais.

Uma vantagem do *MMS* é o número reduzido de parâmetros a serem ajustados. Por exemplo, uma vez que o parâmetro h é escolhido, o parâmetro c é uma função de h como mostrado na equação (A.1).

A.3 MEMÓRIA ADAPTATIVA

A memória adaptativa do algoritmo *MMS* consiste em uma lista das dez melhores soluções encontradas. Essa memória é formada durante a busca na árvore inicial e é atualizada durante as pesquisas nas árvores subsequentes.

Para explicar a formação e atualização da memória adaptativa, considere que após a busca na árvore inicial, a memória é dada por $memo_{m1}$ da equação (A.2), que é formada por soluções $m_{1,m1}$ a $m_{10,m1}$ dispostas em ordem decrescente de qualidade.

$$memo_{m1} = [m_{1,m1}, m_{2,m1}, m_{3,m1}, m_{4,m1}, m_{5,m1}, m_{6,m1}, m_{7,m1}, m_{8,m1}, m_{9,m1}, m_{10,m1}] \quad (A.2)$$

Em que:

- $memo_{m1}$ Memória adaptativa inicial.
- $m_{n,mi}$ Solução armazenada na posição n durante a exploração da árvore mi ;
 $mi = m1$ para a árvore inicial.

O vetor da equação (A.2) é obtido por uma busca exaustiva na árvore inicial ($m1$). A melhor solução deste vetor é $m_{1,m1}$ e é definida como a raiz da primeira árvore subsequente ($m2$). Esta solução é perturbada até que o critério de convergência da árvore subsequente seja atingido, o que será explicado posteriormente. O processo de atualização da memória é

executado sempre que uma solução melhor do que a pertencente ao conjunto $[m_{1,m1}: m_{10,m1}]$ é encontrada. Assim, a nova solução é inserida neste conjunto em uma posição definida de acordo com sua qualidade e os valores subsequentes são deslocados para a direita. O valor na última posição, $m_{10,m1}$, é descartado e substituído pelo valor armazenado em $m_{9,m1}$. O valor $m_{9,m1}$ recebe o valor de $m_{8,m1}$, e assim por diante, até a posição desta nova solução. Neste mecanismo de atualização, o tamanho do vetor permanece o mesmo, com dez posições.

Por exemplo, durante o processo de busca na árvore $m2$, as soluções $m_{1,m2}$ e $m_{2,m2}$ encontradas em $m2$ são melhores que as soluções $m_{3,m1}$ e $m_{6,m1}$ encontradas na árvore $m1$ e incluídas na memória inicial da equação (A.2), respectivamente. Neste caso, a nova configuração da memória adaptativa, atualizada após a busca na árvore $m2$, é mostrada na equação (A.3).

$$memo_{m2} = [m_{1,m1}, m_{2,m1}, \boxed{m_{1,m2}}, m_{3,m1}, m_{4,m1}, m_{5,m1}, \boxed{m_{2,m2}}, m_{6,m1}, m_{7,m1}, m_{8,m1}] \quad (A.3)$$

Em que:

$memo_{mi}$ $memo_{mi}$ é a memória adaptativa obtida após a convergência da árvore mi .

Observa-se que o procedimento de atualização da memória não é restrito apenas a soluções melhores do que $m_{1,m1}$. No exemplo acima, $m_{1,m2}$ e $m_{2,m2}$ não são melhores do que $m_{1,m1}$, mas são melhores do que $m_{3,m1}$ e $m_{6,m1}$, respectivamente. Esta estratégia de atualização permite uma convergência mais rápida do algoritmo e conseqüentemente aumenta sua eficiência computacional em relação ao *MS* proposto em [119] e [120], que limitam o procedimento de atualização a soluções melhores do que $m_{1,m1}$. Assim, a estratégia de atualização proposta é uma melhoria do algoritmo *MMS*.

A.4 MECANISMO DE PERTURBAÇÃO DA SOLUÇÃO

O procedimento realizado para modificar a solução ideal contida na raiz da árvore é definido como uma perturbação. No problema da alocação de equipamentos de medição, esta perturbação compreende na alteração (incrementos ou decrementos) de um ou mais posições na barra selecionada de forma aleatória. O número de incrementos e/ou decrementos da unidade também é aleatório. Para exemplificar este mecanismo de perturbação, considere um sistema com 10 barras, e após pesquisar a árvore $m1$, a melhor solução encontrada, $m_{1,m1}$, é dada

conforme Tabela A.1 em que “0” representa que não há equipamento e “1” que há equipamento de medição alocado.

Tabela A.1. Alocação de medidores definido por m_{l,m_l} após pesquisar a árvore m_l .

Barra	1	2	3	4	5	6	7	8	9	10
Condição	1	1	0	0	0	1	0	1	0	0

De acordo com a Tabela A.1, a solução dada por m_{l,m_l} após pesquisar a árvore m_l estabelece barras 1, 2, 6 e 8 possuem equipamentos de medição. Supondo que os valores aleatórios dos números de incrementos e decrementos seja 1 e 2, respectivamente, e que os barras selecionados aleatoriamente sejam: (i) incremento: barra 3 e (ii) decrementos: barras 6 e 8. A Tabela A.2 traz a atualização da solução proposta.

Tabela A.2. Alocação ótima dos de medidores após a perturbação.

Barra	1	2	3	4	5	6	7	8	9	10
Condição	1	1	1	0	0	0	0	0	0	0

O mecanismo de perturbação deve atender a restrição do número máximo de barras a receber e retirar os equipamentos de medição, ou seja, para o caso do exemplo anterior em que o sistema possui 10 barras e cuja a solução inicial possui 5 barras já alocadas, o número máximo para incrementos (n_{inc}) seria dado pela equação (A.4.a) e o número máximo de decrementos (n_{dec}) pela equação (A.4.b).

$$n_{inc} = Nb - n_{eq} \quad (A.4.a)$$

$$n_{dec} = n_{eq} \quad (A.4.b)$$

Em que:

Nb Número de barras do sistema.

n_{eq} Número de equipamentos de medição já alocados.

Assim, para o exemplo em questão, tem-se que o máximo de incrementos possíveis para o resultado da solução inicial da Tabela A.1 é $n_{inc} = 10 - 4 = 6$ e $n_{dec} = 4$.

A.5 CONVERGÊNCIA

No *MMS*, o critério de convergência para a árvore inicial difere dos critérios para as árvores subsequentes, sendo:

- (i) Critério para a árvore inicial: a convergência da árvore inicial é obtida quando todos os caminhos desta árvore estão cobertos (busca completa de caminhos).
- (ii) Critério para árvores subsequentes: a convergência de uma árvore subsequente é obtida quando se cumpre pelo menos uma das seguintes condições:
 - A solução obtida por uma perturbação é melhor do que a solução raiz da árvore, ou seja, a qualidade de uma solução perturbada ($m_{n,mi}$) é maior que a qualidade da melhor solução ($m_{l,mi}$). No problema da alocação de equipamentos de medição, esta condição é atendida quando a $FOB(m_{n,mi}) < FOB(m_{l,mi})$.
 - Todos os caminhos da árvore subsequente são investigados.

Além do critério de convergência para uma árvore que permite a transição para outra árvore, existe um critério de convergência global para o algoritmo *MMS*, ou seja, a convergência global é alcançada quando pelo menos uma das seguintes condições for atendida:

- (i) A diferença entre as funções objetivo das soluções da última e da primeira posição da memória adaptativa é menor ou igual a uma tolerância ϵ . Assim, esta condição é alcançada quando $FOB(m_{10,mi}) - FOB(m_{1,mi}) \leq \epsilon$ para uma árvore dada mi .
- (ii) Um número máximo de árvores (nt_{max}) são investigadas.

A.6 PROCESSO DE INTENSIFICAÇÃO

O algoritmo *MMS* armazena os caminhos que conduzem as melhores soluções da memória adaptativa mostrada na equação (A.3) durante o processo de otimização. Então, o processo de intensificação intensifica o processo de busca nesses caminhos após um número predefinido de perturbações (n_{peri}). Nesse sentido, o *MMS* pode avaliar quais as barras se destacam mais no processo de busca e assim otimizar a busca em locais onde as soluções melhoram a qualidade durante a alocação de um medidor por exemplo. Por exemplo, se durante

o processo de busca a barra 1 estiver presente nas melhores soluções da memória adaptativa, ou seja, n_{peri} vezes está barra passa a ser um local de destaque e assim, será sempre fixada com o equipamento de medição.

A.7 FLUXOGRAMA DO ALGORITMO PROPOSTO DO *MMS*

A Figura A.2 apresenta o fluxograma do algoritmo *MMS*. Os passos deste algoritmo são descritos a seguir.

Passo 1:

Dados de entrada. Nesta etapa, os dados do SDE são obtidos e os parâmetros do *MMS* são definidos.

Passo 2:

Escalando a árvore inicial. Este passo consiste em explorar a árvore inicial a partir da sua raiz, que correspondente ao Caso Base, sem equipamentos de medição. A raiz é sucessivamente perturbada até atingir o topo. A raiz e cada nó alcançado na árvore são soluções para a alocação de equipamentos de medição, avaliada cada uma através do problema de otimização formulado em (4.8). A qualidade de cada solução é inversamente proporcional a sua FOB.

Passo 3:

Inicialização da memória adaptativa (*memo*). As melhores soluções n encontradas na árvore inicial são armazenadas em $memo_{ml}$ em ordem decrescente de qualidade. O primeiro elemento da *memo* é chamado de “*ibest*”. No algoritmo *MMS*, n está definido em 10.

Passo 4:

Início da pesquisa na árvore subsequente. Perturbação do “*ibest*” para gerar dois novos nós ou soluções através do mecanismo de perturbação descrito anteriormente.

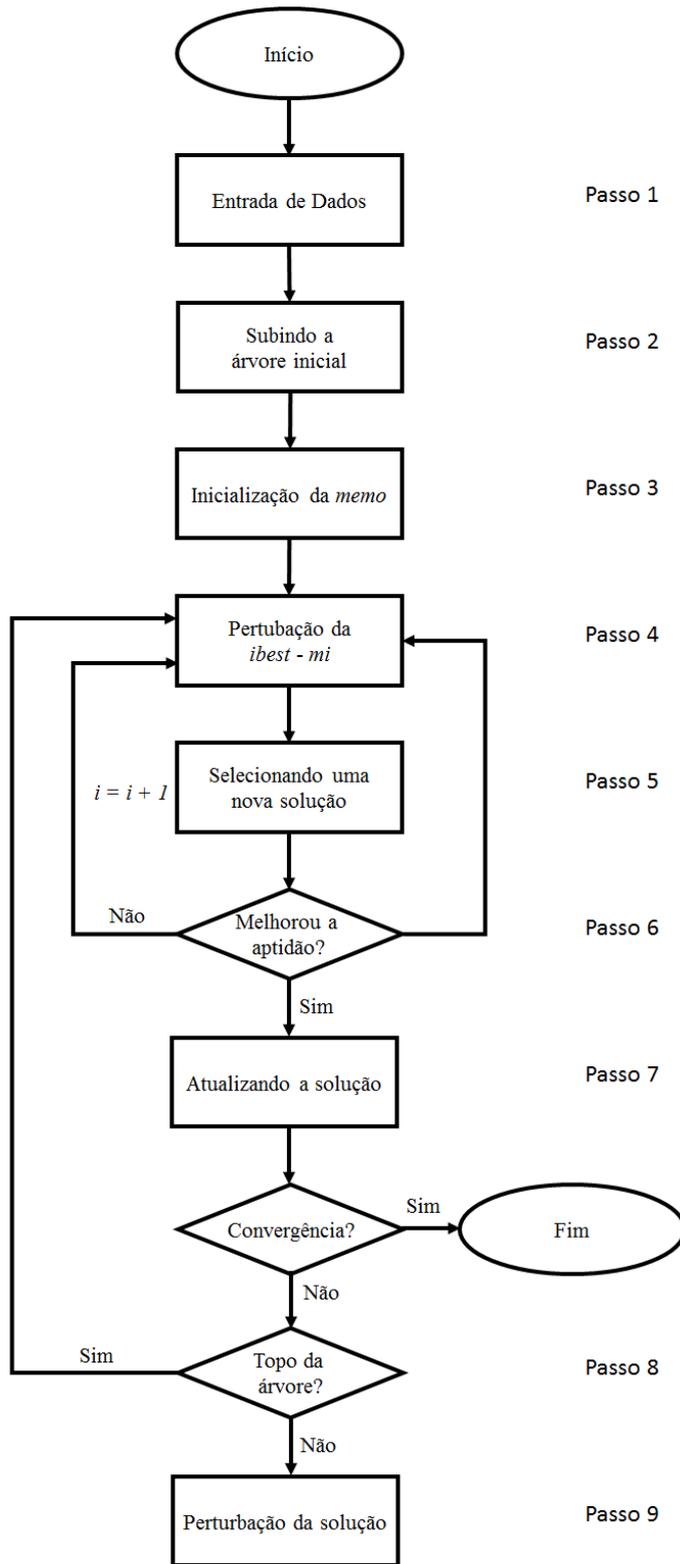


Figura A.2. Fluxograma do algoritmo *MMS*.

Passo 5:

Escolhendo a nova solução atual. O nó gerado no Passo 4 que apresenta melhor solução é escolhido.

Passo 6:

Avaliação da nova solução atual escolhida no Passo 5. Podem ocorrer duas situações: (i) se a solução escolhida apresentar qualidade melhor do que o “*ibest*”, esta solução substitui o “*ibest*” e a convergência da árvore *mi* é alcançada, neste caso, o contador *i* é incrementado e uma nova árvore, *mi* começa a ser explorada a partir do Passo 4; (ii) caso contrário, a memória adaptativa é atualizada se a nova solução atual for melhor que pelo menos uma solução da *memo*, neste caso o algoritmo vai para o Passo 7.

Passo 7:

Avaliação dos critérios de convergência global. Nesta etapa, os critérios de convergência global previamente descritos são avaliados. Se pelo menos uma das condições apresentadas for alcançada, o algoritmo é finalizado. Caso contrário, segue para o Passo 8.

Passo 8:

O algoritmo verifica se o topo da árvore foi alcançado. Se a resposta for "sim", significa que nenhuma solução melhor do que o “*ibest*” foi encontrada da raiz ao topo da *mi*. Nesse caso, o algoritmo retorna ao Passo 4 para executar um novo processo de perturbação no “*ibest*”. Este procedimento é o processo de descida. Caso contrário, se o topo não for alcançado, o algoritmo permanece no processo de subida no Passo 9.

Passo 9:

Perturbação da solução atual. Conforme descrito anteriormente, o mecanismo de perturbação gera duas novas soluções candidatas a nova solução atual. A partir desta geração, o algoritmo vai para o Passo 5.

APÊNDICE B

B.1 MÉTODO DE RESOLUÇÃO DO PROBLEMA DE OTIMIZAÇÃO *E-OPF*

O método de resolução do problema de FPO proposto nesta tese para a execução do processo de estimação de estados, formulado nas Equações (4.4), baseia-se no MPI primal-dual [121] descrito a seguir.

B.2 MÉTODO PRIMAL-DUAL DOS PONTOS INTERIORES

Um problema de otimização não linear pode ser genericamente formulado como:

$$\text{Min } f(x) \tag{B.1.a}$$

sujeito a

$$g(x) = 0 \tag{B.1.b}$$

$$l \leq x \leq u \tag{B.1.c}$$

Em que:

f função objetivo;

x variáveis de otimização;

g conjunto de restrições; e

l, u limites inferior e superior das variáveis de otimização, respectivamente.

Na formulação anterior, as restrições funcionais de desigualdade são transformadas em restrições de igualdade, através da inclusão de variáveis de folga (s), e incluídas no conjunto ‘ g ’ [122]. Daí, o vetor ‘ x ’ compreende as variáveis originais e as de folga incluídas. Procedimento análogo é realizado a seguir para as restrições de canalização (B.1.c) através da introdução dos conjuntos de variáveis de folga s_l e s_u .

$$\text{Min } f(x) \quad (\text{B.2.a})$$

sujeito a

$$g(x) = 0 \quad (\text{B.2.b})$$

$$x - s_l = l \quad (\text{B.2.c})$$

$$x + s_u = u \quad (\text{B.2.d})$$

$$s_l \geq 0, s_u \geq 0 \quad (\text{B.2.e})$$

Para tratamento das restrições de desigualdade (B.2.e), uma função de penalidade barreira logarítmica é incluída na função objetivo como:

$$\text{Min } f(x) - \mu \sum_{j=1}^n \ln(s_{l_j}) - \mu \sum_{j=1}^n \ln(s_{u_j}) \quad (\text{B.3})$$

Em que:

n número de variáveis de otimização que participam em (B.2.e); e

μ parâmetro barreira logarítmica.

O processo inicia-se utilizando um valor aleatório maior que zero para o parâmetro barreira ($\mu^0 > 0$), que tende a zero no final do processo iterativo. As equações (B.4) apresentam a função lagrangeana e as condições de otimização de primeira ordem.

$$L = f(x) - \sum_{i=1}^m \lambda_i \cdot g_i(x) - \mu \cdot \sum_{j=1}^n \ln(s_{l_j}) - \sum_{j=1}^n \pi_{l_j} \cdot (x_j - s_{l_j} - l_j) - \sum_{j=1}^n \pi_{u_j} \cdot (x_j - s_{u_j} - u_j) \quad (\text{B.4.a})$$

$$\begin{bmatrix} H_x & -J^t \\ -J & 0 \end{bmatrix} \cdot \begin{bmatrix} \Delta x \\ \Delta \lambda \end{bmatrix} = - \begin{bmatrix} G_x \\ g(x) \end{bmatrix} \quad (\text{B.4.b})$$

$$H_x = w_x + \sum_j \left(\frac{\pi_{l_j}}{s_{l_j}} - \frac{\pi_{u_j}}{s_{u_j}} \right) \quad (\text{B.4.c})$$

$$G_x = r_x + \sum_j \left(\frac{\mu}{s_{l_j}} - \frac{\mu}{s_{u_j}} \right) \quad (\text{B.4.d})$$

$$r_x = -\nabla_x f(x) + \nabla_x g(x)^t \cdot \lambda \quad (\text{B.4.e})$$

Em que:

- m número de restrições do vetor ‘ g ’;
- λ multiplicadores de Lagrange associados ao conjunto de restrições (B.2.b);
- π_l, π_u multiplicadores de Lagrange associados aos conjuntos de restrições (B.2.c) e (B.2.d), respectivamente;
- w_x, H_x submatrizes hessiana relativas às variáveis x sem e com as contribuições do método de pontos interiores, respectivamente; e
- G_x vetor gradiente relativo às variáveis x incluindo as contribuições do método de pontos interiores.

Observa-se que o parâmetro barreira e as variáveis de folga contribuem na matriz H_x e no vetor G_x , equações (B.4.c) e (B.4.d), respectivamente. Resolvendo o sistema de equações (B.4.b), são obtidos os valores de Δx e $\Delta \lambda$. Os valores das direções de busca $\Delta s_l, \Delta s_u, \Delta \pi_l$ e $\Delta \pi_u$ são calculados conforme equações (B.5).

$$\Delta x - \Delta s_l = 0 \quad (\text{B.5.a})$$

$$\Delta x + \Delta s_u = 0 \quad (\text{B.5.b})$$

$$\Delta \pi_{l_j} = -\frac{\mu}{s_{l_j}^2} \Delta x_j + \frac{\mu}{s_{l_j}} - \pi_{l_j} \quad (\text{B.5.c})$$

$$\Delta \pi_{u_j} = -\frac{\mu}{s_{u_j}^2} \Delta x_j - \frac{\mu}{s_{u_j}} - \pi_{u_j} \quad (\text{B.5.d})$$

Para manter a positividade de s_l e s_u , e também um sinal adequado de π_l e π_u , os passos α_p e α_d , $0 < \alpha_p, \alpha_d \leq 1$, são determinados como:

$$\alpha_p = \min \left\{ \min_{\Delta s_{l_j} < 0} \frac{s_{l_j}}{|\Delta s_{l_j}|}; \min_{\Delta s_{u_j} < 0} \frac{s_{u_j}}{|\Delta s_{u_j}|}; 1, 0 \right\} \quad (\text{B.6.a})$$

$$\alpha_d = \min \left\{ \min_{\Delta \pi_{l_j} < 0} \frac{\pi_{l_j}}{|\Delta \pi_{l_j}|}; \min_{\Delta \pi_{u_j} < 0} \frac{-\pi_{u_j}}{|\Delta \pi_{u_j}|}; 1, 0 \right\} \quad (\text{B.6.b})$$

Para manter os valores de s e π fora da região de fronteira e assim, evitar eventuais problemas numéricos nas equações referentes aos termos H_x e G_x , (B.4.c) e (B.4.d),

respectivamente, o parâmetro $\sigma = 0,9995$ é ainda utilizado para a atualização das variáveis como [109]:

$$x = x + \sigma \cdot \alpha_p \cdot \Delta z \quad (\text{B.7.a})$$

$$s_l = s_l + \sigma \cdot \alpha_p \cdot \Delta s_l \quad (\text{B.7.b})$$

$$s_u = s_u + \sigma \cdot \alpha_p \cdot \Delta s_u \quad (\text{B.7.c})$$

$$\lambda = \lambda + \sigma \cdot \alpha_d \cdot \Delta \lambda \quad (\text{B.7.d})$$

$$\pi_l = \pi_l + \sigma \cdot \alpha_d \cdot \Delta \pi_l \quad (\text{B.7.e})$$

$$\pi_u = \pi_u + \sigma \cdot \alpha_d \cdot \Delta \pi_u \quad (\text{B.7.f})$$

Por fim, lembrando que o processo se inicia com um valor para o parâmetro barreira sendo $\mu^0 > 0$, este é atualizado a cada iteração utilizando-se outro parâmetro, denominado “*gap*” de dualidade, conforme equação (B.8) [123]. Nesta equação, β tem como objetivo controlar o decaimento de μ e auxiliar o processo de convergência [124] e [125].

$$\mu = \beta \cdot \frac{\text{gap}}{2.n} = \beta \cdot \frac{\sum_{j=1}^n (s_{l_j} \cdot \pi_{l_j} - s_{u_j} \cdot \pi_{u_j})}{2.n} \quad (\text{B.8})$$

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Stevenson Jr., W. D.(1986). *Elementos de Análise de Sistema de Potência*. 2 ed., McGraw-Hill.
- [2] Monticelli, A., Garcia, A., (2004). *Introdução a Sistemas de Energia Elétrica*. Unicamp.
- [3] Freitas, M. V., Freitas, J. S., Haffner, S., Lemos, F. A. B.(2004). Alocação de Bancos de Capacitores Fixos e Chaveados em Redes de Distribuição Considerando Diversos Níveis de Carga. *XV Congresso Brasileiro de Automação (CBA)*, Gramado, RS-Brasil.
- [4] Gönen, T.(1986). *Electric Power Distribution System Engineering*, 1 ed., McGraw-Hill.
- [5] Silva, E. L., (2001). *Formação de Preços em Mercados de Energia Elétrica*. 1 ed., Sagra Luzzatto
- [6] Oliveira, L. W., Oliveira, E. J., Carneiro Junior, S., Pereira, J. L. R., Costa, J. S. Silva Junior, I. C.(2010). Optimal reconfiguration and capacitor allocation in radial distribution systems for energy losses minimization. *Int. J. Electr. Power Energy Syst.*, 32(8), 840–848.
- [7] [Online]. Disponível em: <http://www.aneel.gov.br>. Agência Nacional De Energia Elétrica (Brasil). Resolução nº 505, de 26 de novembro de 2001.
- [8] Borges, G. P. (2011). Medição fasorial sincronizada em estimação de estado. *Tese de MSc.*, EESC(São Carlos), SP-Brasil.
- [9] Freitas, I. M. M. A. F. (1995). A Estimacao de Estado de Sistemas Electricos de Energia. Tese de PhD., Departamento de Engenharia Electrotecnica e de Computadores, *Tese de PhD.*, FEUP, Porto-Portugal.
- [10] Vide, P. S. P. S. C. (2013). Estimação de estado de um sistema elétrico de energia, usando medidas fasoriais sincronizadas. *Tese de PhD.*, FEUP, Porto-Portugal.
- [11] Raghuraman, S., Jegatheesan, R. (2011). A survey on state estimation techniques in electrical power system. *Recent Advancements in Electrical, Electronics and Control Engineering (ICONRAEeCE)*,199-205.

- [12] Riviera, R., Sposito, A.S., Teixeira, I. (2013). Redes elétricas inteligentes (smart grid): oportunidade para adensamento produtivo e tecnológico local. *Revista do BNDES*, 40, 43-84.
- [13] Junior, R. T., Araujo, A. L., Eduardo, M., Alcântara, R., Felix, F., Oliveira, A. M. B. (2013). Diga-Energia, Uma Plataforma De Serviços Ao Usuário Utilizando Smart Grid E O Middleware Ginga. *XXXI Simpósio Brasileiro de Telecomunicações*.
- [14] Falcão, D. M. (2010). Integração de tecnologias para viabilização da Smart Grid. *III Simpósio Brasileiro de Sistemas Elétricos (Sbse)*, 1-5.
- [15] Amin, S. M., Wollenberg, B. F. (2005). Toward a *smart grid*: power delivery for the 21st century. *IEEE Power and Energy Magazine*, 3(5), 34-41.
- [16] Exposito, A. G., Abur, A., Jaen, A. V., & Quiles, C. G. (2011). A multilevel state estimation paradigm for smart grids. *Proceedings of the IEEE*, 99(6), 952-976.
- [17] [Online] Disponível em: <http://www.aneel.gov.br/>. (2011). *Agência Nacional de Energia Elétrica*.
- [18] [Online] Disponível em: <http://www.aneel.gov.br/arquivos/PDF/manualdetransmissao.pdf>. *Agência Nacional de Energia Elétrica*.
- [19] [Online]. Disponível em: <http://www.ons.org.br>. (2011). *Operador Nacional do Sistema*.
- [20] [Online]. Disponível em: <http://www.aneel.gov.br/area.cfm?idArea=82&idPerfil=2,2011>. (2011). Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Módulo 8 - Qualidade da Energia Elétrica.
- [21] [Online] Disponível em: <http://www.powerstandards.com/IEEE.htm>. (2011). *IEEE 1159 Monitoring Electric Power Quality*.
- [22] Won, D. J., Moon, S. I. (2008). Optimal number and locations of power quality monitors considering system topology. *Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, 1 –1.

- [23] Klaric, I., Sagovac, G.(2007). Building permanent PQ monitoring system on MV network in Elektra Zagreb, Croatia. *9th International Conference on Electrical Power Quality and Utilisation*, 1–4.
- [24] Singh, R., Pal, B. C., Vinter, R. B. (2009). Measurement placement in distribution system state estimation. *IEEE Trans. Power Syst.*, 24(2), 668–675.
- [25] Chilard, O., Grenard, S. B., Devaux, O.,Garcia, L. A. (2009). Distribution state estimation based on voltage state variables: Assessment of results and limitations. *20th International Conference and Exhibition on Electricity Distribution - Part 1*, 1–4.
- [26] Singh, R.,Pal, B. C.,Jabr, R. A.,Vinter, R. B. (2011). Meter placement for distribution system state estimation: An ordinal optimization approach. *IEEE Trans. Power Syst.*, 26(4), 2328-2335.
- [27] Wang, H. Schulz, N. N. (2004). A revised branch current-based distribution system state estimation algorithm and meter placement impact. *IEEE Trans. Power Syst.*, 19(1), 207–213.
- [28] Baran, M. E. Kelley, A. W. (1995). A branch-current-based state estimation method for distribution systems. *IEEE Trans. Power Syst.*, 10(1), 483–491.
- [29] De, J. Ree, L. Centeno, V., Thorp, J. S., Phadke, A. G. (2010). Synchronized phasor measurement applications in power systems. *IEEE Trans. on Smart Grid*, 1(1), 20–27.
- [30] Thorp, J., Abur,A.,Begovic, M.,Giri, J.,Avila-Rosales, R. (2008). Gaining a wider perspective. *IEEE Power and Energy Magazine*, 6(5), 43–51.
- [31] Phadke, A.G. Thorp,J. S. (2008). *Synchronized Phasor Measurements and Their Applications*. Springer Science.
- [32] Muscas, C., Pilo, F. Pisano, G. Sulis, S. (2009). Optimal allocation of multichannel measurement devices for distribution state estimation. *IEEE Trans. on Instr. and Meas.*, 58(6), 1929–1937.

- [33] Heydt, G. T. (2010). The next generation of power distribution systems. *IEEE Trans. on Smart Grid*, 1(3), 225-235.
- [34] Albu, M., Heydt, G. T. Cosmescu, S. C. (2010). Versatile platforms for wide area synchronous measurements in power distribution systems. *North American Power Symposium*, 1-7.
- [35] Paolone, M., Borghetti, A., Nucci, C. A. (2009). Development of an RTU for synchrophasors estimation in active distribution networks. *IEEE Bucharest PowerTech*, 1-6.
- [36] Singh, R., Pal, B. C., Jabr, R. A. (2009). Choice of estimator for distribution system state estimation. *IET Generation, Transmission & Distribution*, 3(7), 666-678.
- [37] Shafiu, A., Jenkins, N. Strbac, G. (2005). Measurement location for state estimation of distribution networks with generation. *IEE Proceedings Generation, Transmission and Distribution*, 152(2), 240-246.
- [38] Fang, X., Misra, S., Xue, G., Yang, D. (2012). Smart Grid - The New and Improved Power Grid: A Survey. *IEEE Communications Surveys & Tutorials*, 14(4), 944-980.
- [39] IEEE Standard C37.118.1-2011. (2011). *IEEE Standard for Synchrophasor Measurements for Power Systems*, 1-61.
- [40] De Souza, J. C. S. (2009). Forecasting-aided state estimation - Part I: Panorama. *IEEE Trans. Power Syst.*, 24(4), 1667-1677.
- [41] Phadke, A. G., Pickett, B., Adamiak, et al. (1994). Synchronized sampling and phasor measurements for relaying and control. *IEEE Trans. Power Syst.*, 9(1), 442-452.
- [42] Emami, R, Abur, A, Galvan, F. (2008). Optimal placement of phasor measurements for enhanced state estimation: a case study. *Proc. 16th Power Systems Computation Conf. (PSCC)*, 1-6.

- [43] Castello, P., Ferrari, P., Flammini, A., Muscas, C., Pegoraro, P. A., & Rinaldi, S. (2015). A distributed PMU for electrical substations with wireless redundant process bus. *IEEE Transactions on Instrumentation and Measurement*, 64(5), 1149-1157.
- [44] IEEE Standard for a Precision Clock Synchronization Protocol for Networked Measurement and Control Systems (2008), *IEEE Standard 1588*, 1–269.
- [45] Castello, P., Ferrari, P., Flammini, A., Muscas, C., & Rinaldi, S. (2013). A new IED with PMU functionalities for electrical substations. *IEEE Transactions on Instrumentation and Measurement*, 62(12), 3209-3217.
- [46] Castello, P., Ferrari, P., Flammini, A., Muscas, C., Pegoraro, P. A., & Rinaldi, S. (2014, May). Improving availability of distributed PMU in electrical substations using wireless redundant process bus. *In Instrumentation and Measurement Technology Conference (I2MTC) Proceedings*, 239-244.
- [47] Rodriguez, A. C. F. (2014). Compressão de Dados de Demanda Elétrica em Smart Metering. *Tese de MSc.*, UNICAMP(Campinas), SP-Brasil.
- [48] Falcão, D. M. (2009). Smart grids e microrredes: o futuro já é presente. *Simpósio de Automação de Sistemas Elétricos*, 8, 1-11.
- [49] Almada, L. C. F., Paes Jr., M. R. C., Loureiro, C. A. G., et al. (2014). Metodologia para Roadmap Tecnológico de Redes Inteligentes (Smart Grid) com foco em Medição Inteligente e Automação da Distribuição. *XXI Seminário Nacional de Distribuição de Energia Elétrica (SENDI)*, 1-12.
- [50] Abood, H. G., Sreeram, V. (2014). A Review on Phasor Measurement Units Placement for State Estimation Studies. *Australasian Universities Power Engineering Conference*, 1-6.
- [51] Baldwin, T. L., Mili, L., Boisen, M. B. J., Adapa, R. (1993). Power system observability with minimal phasor measurement placement. *IEEE Trans. Power Syst.*, 8, 707-715.

- [52] Gyllstrom, D., Rosensweig, E., Kurose, J. (2012). On the impact of PMU placement on observability and cross-validation. *The 3rd International Conference on Future Energy Systems: Where Energy, Computing and Communication Meet*, 1-10.
- [53] Xu, B. Abur, A. (2004). Observability analysis and measurement placement for systems with PMUs. *Power Systems Conference and Exposition*, 2, 943-946.
- [54] Dongjie, X., Renmu, H., Peng, W., Tao, X. (2004). Comparison of several PMU placement algorithms for state estimation. *Eighth IEE International Conference on Developments in Power System Protection*, 1, 32-35.
- [55] Baran, M. E., Zhu, J., Zhu, H., Garren, K. E. (1995). A meter placement method for state estimation. *IEEE Trans. Power Syst.*, 10(3), 1704-1710.
- [56] Miljanic, Z., Djurovic, I., Vujosevic, I. (2012). Optimal placement of PMUs with limited number of channels. *Electric Power Systems Research*, 90, 93-98.
- [57] Mazhari, S. M., Monsef, H., Fereidunian, A. (2013). A Multi-Objective PMU Placement Method Considering Measurement Redundancy and Observability Value Under Contingencies. *IEEE Trans. Power Syst.*, 28(3), 2136-2146.
- [58] Anderson, J. E., Chakraborty, A. (2014). PMU placement for dynamic equivalencing of power systems under flow observability constraints. *Electric Power Systems Research*, 106, 51-61.
- [59] Mahaei, S. M., Hagh, M. T. (2012). Minimizing the number of PMUs and their optimal placement in power systems. *Electric Power Systems Research*, 83, 66-72.
- [60] Enshae, A., Hashmood, R. A., Fesharaki, F. H. (2012). A new method for optimal placement of phasor measurement units to maintain full network observability under various contingencies. *Electric Power Systems Research*, 89, 1-10.
- [61] Jiang, W., Vittal, V. (2006). Optimal Placement of Phasor Measurements for the Enhancement of State Estimation. *Power Systems Conference and Exposition*, 1550-1555.

- [62] Rosli, H. M., Mokhlis, H., Bakar, A. H. A. (2012). Optimal measurement placement using PSO for state estimation. *IEEE International Conference on Power and Energy*, 834-839.
- [63] Li, X., Scaglione, A., Chang, T. H. (2013). Optimal sensor placement for hybrid state estimation in *smart grid*. *IEEE International Conference on Acoustics, Speech and Signal Processing*, 5253-5257.
- [64] Li, X., Scaglione, A., Chang, T. H. (2014). A Framework for Phasor Measurement Placement in Hybrid State Estimation Via Gauss–Newton. *IEEE Trans. Power Syst.*, 29(2), 824- 832.
- [65] Fan J., Borlase, S. The evolution of distribution. (2009). *IEEE Power and Energy Magazine*, 7(2), 63–68.
- [66] Repo, S., Maki, K., Jarventausta, P. Samuelsson, O. (2008). ADINE-EU demonstration project of active distribution network. *IETCIRED Seminar SmartGrids for Distribution*, 1–5.
- [67] Meliopoulos, A. P., Zhang, F. Multiphase power flow and state estimation for power distribution systems. *IEEE Trans. Power Syst.*, 11(2), 939-946.
- [68] Madlener, R., Liu, J., Monti, A., Muscas, C., Rosen, C. (2009). Measurement and Metering Facilities as Enabling Technologies for Smart Electricity Grids in Europe. *A Sectoral e-Business Watch*.
- [69] [Online]. Disponível em: <http://www.alstom.com/grid/products-and-services/substation-automation-solutions/substation-measurement/iSTAT-M2x3-High-Performance-Measurement-Centre/AlSTOM>. *iSTAT M2x3 High Performance Measurement Centre*.
- [70] [Online]. Disponível em: <http://www.landisgyr.com/ap/en/pub/products.cfm?eventProducts=products.Productetail&ID=143&catID=63Landis&GyrZxQ>. *Qualigrd*.

- [71] [Online]. Disponivel em: <http://www.energy.siemens.com/hq/en/automation/power-transmission-distribution/power-quality/sicam-t.htm>. *Siemens SICAM T Electrical Measurement Transducer*.
- [72] Baran, M. E., McDermott, T. E. (2009). Distribution system state estimation using AMI data. *Power Systems Conference and Exposition*, 1–3.
- [73] Baran, M. E., Jung, J., McDermott, T. E. (2009). Including voltage measurements in branch current state estimation for distribution systems. *Power & Energy Society General Meeting*, 1–5.
- [74] Abur, A., Exposito, A. G. (2004). *Power System State Estimation: Theory and Implementation*. New York: Marcel Dekker.
- [75] Monticelli, A., Wu, F. F. (1985). Network observability: Identification of observable islands and measurement placement. *IEEE Trans. Power App. Syst.*, 104(5), 1035–1041.
- [76] Gou, B., Abur, A. (2001). An improved measurement placement algorithm for network observability. *IEEE Trans. on Power Syst.*, 16(4), 819–824.
- [77] Liu, J., Tang, J., Ponci, F., Monti, A., Muscas, C., Pegoraro, P. A. (2012). Trade-Offs in PMU Deployment for State Estimation in Active Distribution Grids. *IEEE Transactions on Smart Grid*, 3(2), 915-924.
- [78] Pegoraro, P. A., Tang, J., Liu, J., Ponci, F., Monti, A., Muscas, C. (2012). PMU and Smart Metering Deployment for State Estimation in Active Distribution Grids. *IEEE Inter.Energy Conf. and Exhib.*, 873-878.
- [79] Liu, J., Ponci, F., Monti, A., Muscas, C., Pegoraro, P. A., Sulis, S. (2014). Optimal Meter Placement for Robust Measurement Systems in Active Distribution Grids. *IEEE Trans. on Inst. and Meas.*, 63(5), 1096-1105.
- [80] Yang, Y., Roy, S. (2013). PMU Placement for Optimal Three-Phase State Estimation Performance. *IEEE International Conference on Smart Grid Communications*, 342-347.

- [81] Schweppe, F. C. Wildes, J. (1970). Power system static state estimation, part I: exact model. *IEEE Trans. on Power App. and Syst.*, 89, 120-125.
- [82] Irving, M. R., Owen, R. C., Sterling, M. J. H. (1978). Power-system state estimation using linear programming. *Proceedings of the Inst. of Elect. Engineers*, 125, 879-885.
- [83] Handschin, E., Schweppe, F. C., Kohlas, J., Fiechter, A. (1975). Bad data analysis for power system state estimation. *IEEE Trans. on Power App. and Syst.*, 94(2), 329-337.
- [84] Lopes, T. T. (2008). Estimadores de Estado em Sistemas de Energia Elétrica Incluindo Restrições Fuzzy. *Tese de PhD.*, UFRJ (Rio de Janeiro), RJ-Brasil.
- [85] Santos Filho, C. A. N. (2006). Estimação de Estado via Método de Pontos Interiores com Ajuste das Restrições de Desigualdade. *Dissertação de MSc.*, COPPE(Rio de Janeiro), RJ-Brasil.
- [86] Monticelli, A. (1999). *State estimation in electric power systems: a generalized approach*. Springer Science & Business Media, 507, 1-394.
- [87] Abur, A., & Celik, M. K. (1993). Least absolute value state estimation with equality and inequality constraints. *IEEE Transactions on Power Systems*, 8(2), 680-686.
- [88] Singh, H., & Alvarado, F. L. (1994). Weighted least absolute value state estimation using interior point methods. *IEEE Transactions on Power Systems*, 9(3), 1478-1484.
- [89] Van Cutsem, T., Ribbens-Pavella, M., & Mili, L. (1984). Hypothesis testing identification: A new method for bad data analysis in power system state estimation. *IEEE Transactions on Power Apparatus and Systems*, (11), 3239-3252.
- [90] Shivakumar, N. R., & Jain, A. (2008). A review of power system dynamic state estimation techniques. *In Power System Technology and IEEE Power India Conference, POWERCON 2008. Joint International Conference on* 1-6.
- [91] Mandal, J. K., Sinha, A. K., & Roy, L. (1995). Incorporating nonlinearities of measurement function in power system dynamic state estimation. *IEE Proceedings-Generation, Transmission and Distribution*, 142(3), 289-296.

- [92] Sakr, M. M., Bahgat, A., & El-Shafei, A. R. (1985). Dynamic state estimation in power systems with abnormalities detection, identification and correction. *In IEE'Control*, 85, 245-251.
- [93] Sakr, M. M. F., Bahgat, A., & El-Shafei, A. R. (1985, November). Modified estimator applied to electric power systems. *In Proc. of Int. AMSE Conf. Modeling and Simulation*, 131-146.
- [94] Shih, K. R., & Huang, S. J. (2002). Application of a robust algorithm for dynamic state estimation of a power system. *IEEE Transactions on Power Systems*, 17(1), 141-147.
- [95] Huang, S. J., & Shih, K. R. (2002). Dynamic-state-estimation scheme including nonlinear measurement function considerations. *IEE Proceedings-Generation, Transmission and Distribution*, 149(6), 673-678.
- [96] Durgaprasad, G., & Thakur, S. S. (1998). Robust dynamic state estimation of power systems based on M-estimation and realistic modeling of system dynamics. *IEEE Transactions on Power Systems*, 13(4), 1331-1336.
- [97] Thakur, S. S., & Sinha, A. K. (2003). A robust dynamic state estimator for electric power systems. *Journal-Institution of Engineers India Part El Electrical Engineering Division*, 42-46.
- [98] Ferreira, I. M., & Barbosa, F. M. (1994). A square root filter algorithm for dynamic state estimation of electric power systems. *In Electrotechnical Conference. Proceedings, 7th Mediterranean*, 877-880.
- [99] Sinha, A. K., & Mondal, J. K. (1999). Dynamic state estimator using ANN based bus load prediction. *IEEE Transactions on Power Systems*, 14(4), 1219-1225.
- [100] Zhou, M., Centeno, V. A., Thorp, J. S., Phadke, A. G. (2006). An alternative for including phasor measurements in state estimators. *IEEE Trans. on Power Syst.*, 21(4), 1930-1937.
- [101] Therefore, S. T. C., As, M., & Approved, A. S. S. U. (1995). Guide to the Expression of Uncertainty in Measurement.

- [102] Duque, F. G., de Oliveira, L. W., de Oliveira, E. J., & Augusto, A. A. (2017). State estimator for electrical distribution systems based on an optimization model. *Electric Power Systems Research*, 152, 122-129.
- [103] Tecchio, P.P. Benedito, R.A. Alberto, L.F.C (2010). The behavior of *WLS* state estimator near the maximum loadability point of power systems. *Power and Energy Society General MeetingIEEE*, 1–6.
- [104] Momoh, J. A., Adapa, R., & El-Hawary, M. E. (1999). A review of selected optimal power flow literature to 1993. I. Nonlinear and quadratic programming approaches. *IEEE transactions on power systems*, 14(1), 96-104.
- [105] Duque, F. G., de Oliveira, L. W., de Oliveira, E. J., Marcato, A. L., & Silva, I. C. (2015). Allocation of capacitor banks in distribution systems through a modified monkey search optimization technique. *International Journal of Electrical Power & Energy Systems*, 73, 420-432.
- [106] Duque, F. G., Oliveira, L. W., and Oliveira, E. J. (2016). An approach for optimal allocation of fixed and switched capacitor banks in distribution systems based on the monkey search optimization method. *Journal of Control Automation and Electrical Systems*, 27(2), 212-227.
- [107] Silva, I. C., Carneiro, S., de Oliveira, E. J., de Souza Costa, J., Pereira, J. L. R., & Garcia, P. A. N. (2008). A heuristic constructive algorithm for capacitor placement on distribution systems. *IEEE Transactions on Power Systems*, 23(4), 1619-1626.
- [108] Su, C. T., & Lee, C. S. (2001). Feeder reconfiguration and capacitor setting for loss reduction of distribution systems. *Electric Power Systems Research*, 58(2), 97-102.
- [109] Oliveira, E. J., Oliveira, L. W., Pereira, J. L. R., Honório, L. M., Silva, I. C., Marcato, A. L. M. (2015). An optimal power flow based on safety barrier interior point method. *Int. J. Electr. Power Energy Syst.*, 64, 977-985.

- [110] Baykasoglu, A., Owen, S., Gindy, N. (1999). A Tabu Search Based Approach to Find the Pareto Optimal Set in Multiple Objective Optimization. *Engineering Optimization*, 31(6), 731-748
- [111] Konaka, A., Coitb, D. Smith, A. (2006). Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering and System Safety*, 91, 992–1007.
- [112] Carvalho, P. (2004). *Lecture Notes in Evolutionary Computation*, Instituto Superior Técnico, Lisbon, November 2004.
- [113] Zitzler, E., Laumanns, M., & Thiele, L. (2001). SPEA2: Improving the strength Pareto evolutionary algorithm. *TIK-report*, 103.
- [114] [Online]. Disponível em: <http://www.mathworks.com/help/optim/ug/fmincon.html>.
- [115] Civanlar, S., Grainger, J. J., Yin, H., Lee, S. S. H.(1988). Distribution Feeder Reconfiguration for Loss Reduction. *IEEE Trans. on Power Deliv.*, 3(3), 1217–1223.
- [116] Baran, M. E., Wu, F. F. (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Trans. on Power Deliv.*, 4(2), 1401-1407.
- [117] Zhang, D., Fu, Z., & Zhang, L. (2008). Joint optimization for power loss reduction in distribution systems. *IEEE Transactions on Power Systems*, 23(1), 161-169.
- [118] Gomes, F. V., Carneiro, S., Pereira, J. L. R., Vinagre, M. P., Garcia, P. A. N., & De Araujo, L. R. (2006). A new distribution system reconfiguration approach using optimum power flow and sensitivity analysis for loss reduction. *IEEE Transactions on Power Systems*, 21(4), 1616-1623.
- [119] Mucherino, A., Liberti, L., Lavor, C., & Maculan, N. (2009, July). Comparisons between an exact and a metaheuristic algorithm for the molecular distance geometry problem. In *Proceedings of the 11th Annual conference on Genetic and evolutionary computation*, 333-340. ACM.

- [120] Kammerdiner, A. R., Mucherino, A., & Pardalos, P. M. (2009). Application of monkey search meta-heuristic to solving instances of the multidimensional assignment problem. In *Optimization and Cooperative Control Strategies*, 385-397. Springer Berlin Heidelberg.
- [121] Granville, S. (1994). Optimal reactive dispatch through interior point methods. *IEEE Trans. on Power Syst.*, 9(1), 136-146.
- [122] Clements, K., Davis, P. W., & Frey, K. D. (1995). Treatment of inequality constraints in power system state estimation. *IEEE Trans. on Power Syst.*, 10(2), 567-574.
- [123] Wu, Y. C., Debs, A. S., Marsten, R. E. (1994). A direct nonlinear predictor-corrector primal-dual interior point algorithm for optimal power flows. *IEEE Trans. on Power Syst.*, 9(2), 876-883.
- [124] Torres, G. L., Quintana, V. H. (2001). On a nonlinear multiple-centrality-corrections interior-point method for optimal power flow. *IEEE Trans. on Power Syst.*, 16(2), 222-228.
- [125] Irisarri, G. D., Wang, X., Tong, J., Mokhtari, S. (1997). Maximum loadability of power systems using interior point nonlinear optimization method. *IEEE Trans. on Power Syst.*, 12(1), 162-172.