

UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
MESTRADO EM ENGENHARIA ELÉTRICA E DE TELECOMUNICAÇÕES

RENE CRUZ FREIRE

OTIMIZAÇÃO NATURAL MULTI OBJETIVO COMO FERRAMENTA PARA DESVIO
MÍNIMO DE PONTOS DE OPERAÇÃO CONSIDERANDO RESTRIÇÕES DE
SEGURANÇA

NITERÓI
2016

RENE CRUZ FREIRE
MATRÍCULA: M054.214.009

OTIMIZAÇÃO NATURAL MULTI OBJETIVO COMO FERRAMENTA PARA DESVIO
MÍNIMO DE PONTOS DE OPERAÇÃO CONSIDERANDO RESTRIÇÕES DE
SEGURANÇA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

Orientador: Prof. Vitor Hugo Ferreira, D. Sc.

NITERÓI
2016

Ficha Catalográfica elaborada pela Biblioteca da Escola de Engenharia e Instituto de Computação da UFF

F866 Freire, Rene Cruz

Otimização natural multiobjetivo como ferramenta para desvio mínimo de pontos de operação considerando restrições de segurança / Rene Cruz Freire. – Niterói, RJ : [s.n.], 2016.
145 f.

Orientador: Vitor Hugo Ferreira.
Dissertação (Mestrado em Engenharia Elétrica e de Telecomunicações) - Universidade Federal Fluminense, 2016.

1. Sistema elétrico de potência. 2. Otimização natural multiobjetivo. 3. Algoritmo. I. Título.

CDD 621.3191

RENE CRUZ FREIRE

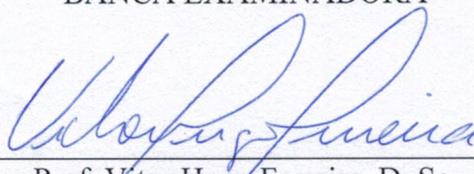
OTIMIZAÇÃO NATURAL MULTI OBJETIVO COMO FERRAMENTA PARA DESVIO
MÍNIMO DE PONTOS DE OPERAÇÃO CONSIDERANDO RESTRIÇÕES DE
SEGURANÇA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

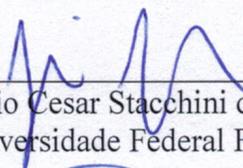
Área de concentração: Sistemas de Energia Elétrica.

Aprovado em 25 de julho de 2016.

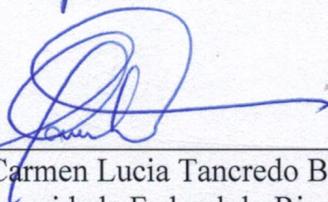
BANCA EXAMINADORA



Prof. Vitor Hugo Ferreira, D. Sc.
Universidade Federal Fluminense



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



Prof. Carmen Lucia Tancredo Borges, D. Sc.
Universidade Federal do Rio de Janeiro

NITERÓI
2016

*Dedico este trabalho aos meus pais,
Conceição e Valdemir, por todos os
sacrifícios que me permitiram estar aqui
hoje.*

AGRADECIMENTOS

Primeiramente a Deus, por tudo.

Aos meus pais, Conceição e Valdemir, e às minhas irmãs, Eliza e Rafaela, pelo apoio, incentivo e compreensão durante todo o meu curso, fundamentais na minha vida e para a realização desse trabalho.

Ao meu orientador, professor Vitor Hugo Ferreira, pela dedicação, paciência e conhecimentos transmitidos ao longo de todos esses anos na UFF, e sobretudo pela competência durante a orientação deste trabalho.

Aos professores Júlio César Stacchini de Souza e Carmen Lúcia Tancredo Borges, pela honra ao aceitarem o convite para fazer parte da banca de avaliação do meu trabalho.

A todos os professores do Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações (PPGEET) presentes em minha trajetória, pelo ensino de excelente qualidade e pelos conhecimentos transmitidos.

A toda a equipe do PPGEET, em especial ao secretário Maurício Shvartz e à coordenadora, professora Leni Joaquim de Matos, por serem sempre solícitos e pacientes no atendimento.

A todos os colegas do LISPOT, em especial aos professores Márcio Ribeiro Guimaraens e André Abel Augusto, pela excelente convivência e por todos os ensinamentos transferidos.

Ao apoio financeiro recebido da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) através da bolsa do Programa de Demanda Social, por permitir minha dedicação a este trabalho.

*“Comece fazendo o que é necessário,
depois o que é possível e, de repente, você
estará fazendo o que é impossível”*

São Francisco de Assis

RESUMO

Um dos temas de alta relevância para a sociedade atual é a qualidade do suprimento de energia elétrica, que deve ser ininterrupto, seguro e econômico. Para tal, é primordial que o sistema de potência esteja preparado para um possível defeito de algum equipamento da rede, mantendo a operação dentro dos patamares seguros, evitando os blecautes e todas as suas consequências para a sociedade. Isso pode ser feito através do redespacho das unidades geradoras, de modo a encontrar um ponto de operação que concilie segurança e economicidade, dois objetivos conflitantes, enquanto busca se afastar o mínimo possível do ponto de operação previamente estabelecido, via planejamento eletroenergético, para o sistema de potência em questão. Trata-se de uma abordagem multiobjetiva do Fluxo de Potência Ótimo com Restrições de Segurança (FPORS) que pode ser solucionada com uma abordagem de Computação Evolucionária (CE) com viés multiobjetivo. Neste trabalho, foram implementadas e comparadas duas meta-heurísticas evolutivas multiobjetivo: *Nondominated Sorting Genetic Algorithm II* (NSGA-II) e o *Multi-objective Evolutionary Particle Swarm Optimization* (MOEPSO). Os resultados dessas heurísticas também foram comparados com a abordagem mono-objetivo do mesmo problema. Os algoritmos foram implementados no MATLAB® e testados em um sistema-teste que simula as condições do Sistema Interligado Nacional (SIN). As heurísticas multiobjetivo foram comparadas através da metodologia de análise da Fronteira de Pareto (FP), onde é analisado qual método concilia melhor os objetivos de economia e segurança. Na primeira análise o NSGA-II saiu-se melhor, entretanto após a implementação de melhorias no algoritmo, o MOEPSO mostrou desempenho superior na segunda análise. Nas duas análises, o viés multiobjetivo mostrou-se superior ao mono-objetivo, na comparação através do critério de agregação de objetivos. Em relação ao tempo de simulação de cada método, o MOEPSO foi superior na primeira análise, já na segunda análise foi implementado um refinamento baseado no Fluxo de Potência Linearizado no FPORS, que baixou o tempo de simulação das duas heurísticas multiobjetivas em comparação com a primeira análise, e o MOEPSO teve o menor tempo de simulação. Na comparação com o viés mono-objetivo, apenas o NSGA-II teve tempo médio de simulação maior que o método mono-objetivo na primeira análise. Na segunda análise, todas as heurísticas multiobjetivo possuíam tempo de simulação menores que o método mono-objetivo.

Palavras-chave: Fluxo de potência ótimo com restrições de segurança, Despacho seguro e econômico, Otimização natural multiobjetivo, Meta-heurísticas evolutivas.

ABSTRACT

One of the topics of high relevance to the today's society is the quality of electric power supply, which must be uninterrupted, safe and economical. To this end, it is essential that the power system be prepared for a possible defect of some equipment from the network while maintaining operation within safe levels, avoiding blackouts and all its consequences for society. This can be done by redispatch of generating units, in order to find an operation point which conciliate security and economy, two conflicting objectives, while seeking to depart as little as possible of the operation point previously established in the energy planning for the power system in question. This is a multi-objective approach to Security Constrained Optimal Power Flow (SCOPF) that can be solved with an approach of Evolutionary Computation with multi-objective bias. In this work we were implemented and compared two multi-objective evolutionary meta-heuristics: Nondominated Sorting Genetic Algorithm II (NSGA-II) and Multi-objective Evolutionary Particle Swarm Optimization (MOEPSO). The results of these heuristics were also compared with mono-objective approach to the same problem. The algorithms were implemented in MATLAB[®] and tested in a test-case that simulates the conditions of the Brazilian *Sistema Interligado Nacional* (National Interconnected System). The multi-objective heuristics were compared using the analysis methodology of the Pareto Frontier, where is analyzed which method is better to conciliate the economy and security objectives. In the first analysis the NSGA-II fared better, but after the implementation of improvements in the algorithm, the MOEPSO showed superior performance in the second analysis. In both analyzes, the multi-objective bias was superior to the mono-objective bias, in the comparison through objectives aggregation criteria. Concerning the simulation time of each method, the MOEPSO was superior in the first analysis, but in the second analysis was implemented a refinement based on DC Load Flow, which lowered the simulation time of the two multi-objective heuristics compared with the first analysis, and the MOEPSO had the shortest time simulation. Compared to the mono-objective bias, only the NSGA-II had an average time simulation greater than the mono-objective method in the first analysis. In the second analysis, all multi-objectives heuristics had simulation time smaller than the mono-objective method.

Keywords: Security constrained optimal power flow, Safe and economic dispatch, Multi-objective natural optimization, Evolutionary metaheuristics.

SUMÁRIO

1. INTRODUÇÃO	13
1.1. MOTIVAÇÃO	13
1.2. OBJETIVOS	16
1.3. ESTRUTURA DA DISSERTAÇÃO	17
2. OTIMIZAÇÃO SEGURA DE SISTEMAS DE POTÊNCIA	19
2.1. EVOLUÇÃO HISTÓRICA	19
2.2. RESUMO DO ESTADO DA ARTE SOBRE TÉCNICAS DE OTIMIZAÇÃO	21
2.2.1. <i>TÉCNICAS TRADICIONAIS</i>	21
2.2.2. <i>ALGORITMOS EVOLUTIVOS</i>	23
2.2.3. <i>CONTRIBUIÇÃO PARA O ESTADO DA ARTE</i>	28
3. ANÁLISE DE SEGURANÇA ESTÁTICA	30
3.1. INTRODUÇÃO	30
3.2. ESTADOS DE OPERAÇÃO DO SISTEMA	31
3.3. ANÁLISE DE CONTINGÊNCIAS	34
3.3.1. <i>INTRODUÇÃO</i>	34
3.3.2. <i>ANÁLISE DE CONTINGÊNCIAS SIMPLES UTILIZANDO Z_{BARRA}</i>	35
4. FLUXO DE POTÊNCIA ÓTIMO	40
4.1. INTRODUÇÃO	40
4.2. FORMULAÇÃO DO PROBLEMA	41
4.3. MÉTODOS TRADICIONAIS DE SOLUÇÃO DO FPO	43
4.3.1. <i>MÉTODOS BASEADOS EM PROGRAMAÇÃO LINEAR</i>	43
4.3.2. <i>MÉTODOS BASEADOS EM PROGRAMAÇÃO NÃO-LINEAR</i>	44
4.4. FLUXO DE POTÊNCIA ÓTIMO COM RESTRIÇÕES DE SEGURANÇA (FPORS)	45
4.4.1. <i>INTRODUÇÃO</i>	45
4.4.2. <i>FORMULAÇÃO DO PROBLEMA DO FPORS</i>	47
5. OTIMIZAÇÃO MULTIOBJETIVO	49
5.1. INTRODUÇÃO	49
5.2. SOLUÇÕES PARETO-ÓTIMAS	50
5.2.1. <i>INTRODUÇÃO</i>	50
5.2.2. <i>DOMINÂNCIA DE PARETO</i>	51
5.3. METAS EM OTIMIZAÇÃO MULTIOBJETIVO	52
5.4. DIFERENÇAS PARA A OTIMIZAÇÃO MONO-OBJETIVO	53
5.5. TÉCNICAS TRADICIONAIS DE OTIMIZAÇÃO MONO-OBJETIVO	53
5.5.1. <i>SOMATÓRIO DE PESOS</i>	53
5.5.2. <i>MÉTODO DE RESTRIÇÕES ϵ</i>	54
5.5.3. <i>PROGRAMAÇÃO POR METAS</i>	55
5.5.4. <i>VANTAGENS E DESVANTAGENS DAS TÉCNICAS TRADICIONAIS</i>	57

6.	ALGORITMOS EVOLUTIVOS	58
6.1.	INTRODUÇÃO.....	58
6.2.	OPERADORES GENÉTICOS	59
6.2.1.	<i>INTRODUÇÃO</i>	59
6.2.2.	<i>SELEÇÃO</i>	60
6.2.3.	<i>CRUZAMENTO</i>	60
6.2.4.	<i>MUTAÇÃO</i>	61
6.3.	ALGORITMOS EVOLUTIVOS PARA OTIMIZAÇÃO MULTIOBJETIVO.....	61
6.4.	TÉCNICAS DE OTIMIZAÇÃO MULTIOBJETIVO.....	63
6.4.1.	<i>NSGA-II</i>	63
6.4.2.	<i>MOEPSO</i>	66
7.	FORMULAÇÃO DO PROBLEMA	69
7.1.	INTRODUÇÃO.....	69
7.2.	MODELAGEM MATEMÁTICA	69
7.3.	ESTRUTURA DO VETOR-SOLUÇÃO.....	72
7.4.	ALGORITMOS IMPLEMENTADOS PARA A RESOLUÇÃO DO FPORS	73
7.4.1.	<i>INTRODUÇÃO</i>	73
7.4.2.	<i>OTIMIZAÇÃO BASEADA APENAS EM FLUXO DE POTÊNCIA CA</i>	74
7.4.3.	<i>OTIMIZAÇÃO EM FLUXO DE POTÊNCIA CA COM REFINAMENTO CC</i>	75
7.5.	SISTEMA-TESTE E PARÂMETROS DAS META-HEURÍSTICAS	77
8.	RESULTADOS	80
8.1.	METODOLOGIA DE ANÁLISE DOS RESULTADOS.....	80
8.2.	AVALIAÇÃO DO CASO BASE.....	81
8.3.	PRIMEIRA IMPLEMENTAÇÃO (I1).....	83
8.4.	SEGUNDA IMPLEMENTAÇÃO (I2).....	93
9.	CONCLUSÕES.....	103
9.1.	CONSIDERAÇÕES SOBRE OS OBJETIVOS	103
9.2.	PROPOSTAS PARA TRABALHOS FUTUROS	105
	REFERÊNCIAS BIBLIOGRÁFICAS	107
	APÊNDICE A: DESVIOS DOS DESPACHOS OBTIDOS.....	117
	APÊNDICE B: VIOLAÇÕES EM CADA EQUIPAMENTO.....	125
	ANEXO I: ABORDAGEM MONO-OBJETIVA DO PROBLEMA	129

ÍNDICE DE FIGURAS

Figura 1 – Etapas resumidas da análise de segurança	15
Figura 2 – Estados do sistema e as transições entre os mesmos [98]	32
Figura 3 – Equivalente Thévenin para simulação da saída da linha $m-n$	37
Figura 4 – Camadas ilustrando as fronteiras.....	63
Figura 5 – Fluxograma do NSGA-II.....	65
Figura 6 – Fluxograma do MOEPSO	68
Figura 7 – Vetor-solução.....	72
Figura 8 – Refinamento da solução inicial pelo FPORS CC	73
Figura 9 – Otimização baseada apenas em fluxo de potência CA	74
Figura 10 – Refinamento via FPORS CC.....	75
Figura 11 – Otimização em fluxo de potência CA com refinamento CC	76
Figura 12 – Sistema-teste brasileiro de 107 barras CA [124]	77
Figura 13 – Fronteiras de Pareto retornadas pela execução do NSGA-II (I1)	83
Figura 14 – Fronteiras de Pareto retornadas pela execução do MOEPSO (I1)	83
Figura 15 – Comparação entre as frentes de Pareto de cada método (I1)	84
Figura 16 – Fronteiras de Pareto retornadas pela execução do NSGA-II (I2)	93
Figura 17 – Fronteiras de Pareto retornadas pela execução do MOEPSO (I2)	93
Figura 18 – Comparação entre as frentes de Pareto de cada método (I2)	94

ÍNDICE DE TABELAS

Tabela 1 – Estados de operação do sistema de potência	32
Tabela 2 – Transição entre os estados de operação	33
Tabela 3 – Limites operativos avaliados pela heurística	71
Tabela 4 – Penalizações correspondentes a cada restrição violada	71
Tabela 5 – Lista de contingências	78
Tabela 6 – Parâmetros do NSGA-II	79
Tabela 7 – Parâmetros do MOEPSO	79
Tabela 8 – Avaliação do despacho ativo original do caso base	82
Tabela 9 – Valores de função objetivo e tempo de simulação para o NSGA-II (I1)	85
Tabela 10 – Valores de função objetivo e tempo de simulação para o MOEPSO (I1)	86
Tabela 11 – Despachos do caso base e obtidos pelos métodos de otimização (I1)	87
Tabela 12 – Comparação de objetivos entre os vieses multi e mono-objetivo (I1)	88
Tabela 13 – Comparação de tempo entre os vieses multi e mono-objetivo (I1)	88
Tabela 14 – Contabilização do número de violações para cada meta-heurística (I1)	89
Tabela 15 – Número de violações por meta-heurística separados por contingência (I1)	90
Tabela 16 – Violação percentual por meta-heurística separados por contingência (I1)	91
Tabela 17 – Valores de função objetivo e tempo de simulação para o NSGA-II (I2)	95
Tabela 18 – Valores de função objetivo e tempo de simulação para o MOEPSO (I2)	96
Tabela 19 – Despachos do caso base e obtidos pelos métodos de otimização (I2)	97
Tabela 20 – Comparação de objetivos entre os vieses multi e mono-objetivo (I2)	98
Tabela 21 – Comparação de tempo entre os vieses multi e mono-objetivo (I2)	98
Tabela 22 – Contabilização do número de violações para cada meta-heurística (I2)	99
Tabela 23 – Número de violações por meta-heurística separados por contingência (I2)	100
Tabela 24 – Violação percentual por meta-heurística separados por contingência (I2)	101

1. INTRODUÇÃO

1.1. MOTIVAÇÃO

Uma das principais metas dos responsáveis pelo planejamento dos sistemas elétricos de potência é a operação econômica e segura desses sistemas. No que se refere ao Brasil, o órgão responsável pela operação do Sistema Interligado Nacional (SIN), o Operador Nacional do Sistema Elétrico (ONS), descreve como sua missão institucional “operar o Sistema Interligado Nacional de forma integrada, com transparência, equidade e neutralidade, de modo a garantir a segurança, continuidade e economicidade do suprimento de energia elétrica no país” [1]. Para cumprir essa missão, são necessárias ferramentas computacionais de análise, controle e otimização de sistemas de potência, com o objetivo de definir estratégias de operação que visam realizar um fornecimento de energia seguro, contínuo e confiável que ao mesmo tempo minimize os custos operativos do sistema.

Entende-se como segurança de um sistema de potência a sua capacidade de manter a estabilidade quando sujeito à ocorrência de algumas perturbações previamente estabelecidas, ou seja, uma lista de contingências pré-selecionadas geralmente de acordo com algum critério: impacto no sistema, confiabilidade do equipamento, etc., de modo que o sistema opere prevenido para as faltas mais importantes e/ou prováveis. Mais especificamente, um ponto de operação é considerado seguro para um sistema de potência, dada determinada uma lista de contingências, se na ocorrência de cada possível contingência o sistema conseguir manter os fluxos de potência nas linhas de transmissão, a magnitude da tensão nos barramentos e a geração de potência ativa e reativa dentro de patamares seguros definidos pelos operadores, os limites operativos [2]. No Brasil, as diretrizes para a definição desses patamares estão relacionadas nos procedimentos de rede, conjunto de documentos elaborados pelo ONS, mais precisamente no submódulo 23.3, “Diretrizes e Critérios para Estudos Elétricos” [3].

A continuidade é a capacidade do sistema de potência de manter um fornecimento ininterrupto de energia elétrica para os consumidores, sendo a característica da rede elétrica que mais afeta e gera repercussão na sociedade em geral. Está diretamente ligada à segurança do sistema de potência, uma vez que a violação de um único limite operativo pode levar à atuação da proteção individual de algum equipamento do sistema, desconectando-o da rede. A ausência desse equipamento, por sua vez, pode ocasionar mais uma violação de limite operativo, e assim sucessivamente, dando sequência a um processo conhecido como

“desligamentos em cascata” [4], responsável pelos grandes blecautes e também por enormes prejuízos financeiros.

Por fim, a economicidade diz respeito à minimização dos custos de operação do sistema de potência, o que é feito através do escalonamento das saídas das unidades de geração para encontrar a demanda de carga consumidora ao menor custo operativo possível, medida conhecida como despacho econômico [5]. Entretanto, a obtenção do despacho econômico deve estar sujeita a restrições, como por exemplo, segurança e continuidade, uma vez que as perdas econômicas ocasionadas pelos blecautes costumam ser muito maiores do que o investimento necessário para evitar os “apagões”, o que justifica o aporte financeiro exigido para tornar o sistema seguro. Portanto, é necessário no planejamento energético um estudo que encontre um ponto de operação ótimo tanto do ponto de vista da segurança quanto do ponto de vista econômico. Observando que a geração de cada unidade geradora dos sistemas de potência é definida através do despacho econômico, uma operação econômica e segura da rede deve procurar se afastar o mínimo possível desse despacho previamente estabelecido.

O estudo indicado para encontrar o ponto de operação seguro e econômico de um sistema de potência é a análise de segurança, onde é verificado se a rede elétrica em questão atende às restrições de carga, de operação e de segurança, no caso de ocorrer alguma contingência na rede, ou seja, se houver falha de algum equipamento, tal como linhas de transmissão, transformadores, geradores, etc. Isso significa que o sistema sempre manterá reservas energéticas para compensar uma possível saída de algum componente da rede, de modo a evitar a violação de limites operativos em qualquer trecho do sistema e assim não comprometer o suprimento de energia elétrica para os consumidores. Esse estudo pode ser dividido em três etapas básicas: monitoração, análise de contingências e fluxo de potência ótimo considerando contingências.

A primeira etapa é a monitoração, na qual o operador pode verificar em tempo real, através do sistema SCADA (*Supervisory Control and Data Acquisition* – Sistema de Supervisão e Aquisição de Dados), dados de grandezas elétricas, como fluxo de potência ativa nas linhas de transmissão e magnitude de tensão nos barramentos, e dados lógicos, como estados de chaves e disjuntores, permitindo ao centro de controle elaborar uma estratégia para contornar possíveis violações de limites operativos. A etapa seguinte é a análise de contingências, onde é estudado o comportamento da rede na ausência de alguns dos seus equipamentos. Para esse estudo, é elaborada uma lista de contingências selecionadas de

acordo com o critério mais conveniente ao operador, e o sistema será preparado para estar prevenido para a ocorrência de qualquer contingência da lista. A terceira e última etapa, o fluxo de potência ótimo considerando contingências, é subsidiada pelos dados das etapas anteriores, ou seja, utiliza as medições retornadas pelo SCADA e o comportamento da rede diante de alguma das contingências da lista pré-estabelecida para encontrar o ponto de operação ótimo para os critérios analisados: segurança, custos, flexibilidade, etc. Nesta etapa se encontra o desafio de prover um ponto de operação seguro e econômico para o sistema, sendo, portanto, o foco deste trabalho.

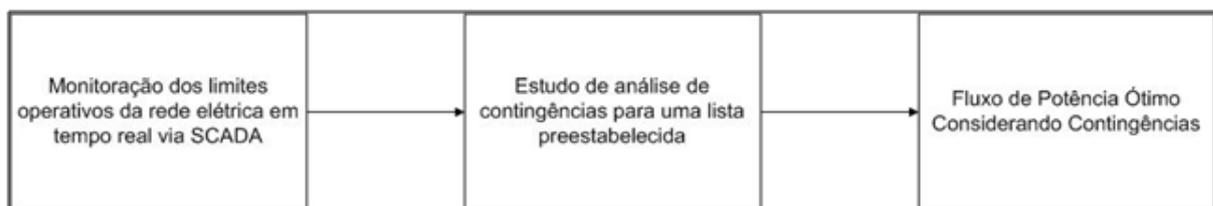


Figura 1 – Etapas resumidas da análise de segurança

Na operação de sistemas de potência, segurança e economicidade são objetivos conflitantes, uma vez que prover uma rede elétrica segura exige um grande investimento financeiro, e uma minimização dos custos de operação sem observar restrições de segurança dá origem a uma rede despreparada para eventuais contingências, comprometendo o suprimento de energia elétrica. Ou seja, são objetivos que não podem ser melhorados simultaneamente, cabendo ao operador escolher, dentre um conjunto de possíveis pontos de operação, aquele que melhor atende aos seus critérios de tomada de decisões, levando em conta que há soluções que possuem vantagens em segurança, mas que não são melhores em custo e vice-versa. Esse problema compõe um cenário típico de otimização multiobjetivo [6], no qual é necessário conciliar objetivos que, até que haja um parecer do operador, possuem a mesma importância, não sendo possível afirmar que uma melhora na economicidade compense uma piora na segurança.

Trata-se de um cenário perfeito para a aplicação de técnicas de Inteligência Computacional (IC) com viés multiobjetivo inspiradas na natureza, que são conhecidas como Algoritmos Evolutivos Multiobjetivo (AEMO). As heurísticas evolutivas multiobjetivo vêm ganhando espaço na resolução de problemas de FPORS, uma vez que são capazes de contornar limitações inerentes aos métodos clássicos de otimização baseados em programação não-linear, como por exemplo a estagnação em mínimos locais em casos de otimização não-convexos [7], realizando uma busca estocástica pelo espaço de soluções com a meta de

encontrar regiões com soluções promissoras, de modo a evitar a convergência prematura em mínimos locais. Apesar de lidar com desvantagens como o elevado esforço computacional e a ausência de garantias quanto à otimalidade das soluções, os AEMO são uma abordagem promissora para a resolução do problema do ajuste mínimo (econômico) de pontos de operação considerando restrições de segurança.

1.2. OBJETIVOS

O presente trabalho procura demonstrar a eficácia da abordagem via AEMO para a resolução do problema do desvio mínimo de pontos de operação considerando restrições de segurança, através do cumprimento de três objetivos principais:

- 1) Implementar duas meta-heurísticas evolutivas multiobjetivo, o NSGA-II (*Nondominated Sorting Genetic Algorithm II* – Algoritmo Genético de Ordenação por Não-dominância II) e o MOEPSO (*Multi-objective Evolutionary Particle Swarm Optimization* – Otimização por Enxame de Partículas Evolucionário Multiobjetivo), como técnicas alternativas para a solução do problema em questão através da resolução do FPORS;
- 2) Comparar o desempenho das duas meta-heurísticas evolutivas multiobjetivo implementadas entre si, analisando o conjunto de soluções retornado e o tempo de simulação de cada técnica;
- 3) Comparar o desempenho das duas meta-heurísticas evolutivas multiobjetivo implementadas com o desempenho da implementação de viés mono-objetivo para a resolução do mesmo problema, relatada em [8], analisando as soluções retornadas e o tempo de simulação de cada viés.

Dessa forma, espera-se obter uma ferramenta computacional de análise de sistemas de potência em regime permanente capaz de definir um conjunto de ações de controle que eliminem as violações operativas de uma rede elétrica, frente a uma lista de contingências pré-estabelecida, ao mesmo tempo em que busca não se afastar demais do despacho base previamente estabelecido para o referido sistema de potência. Ainda em relação às violações de limites operativos, deve-se observar também a sua severidade, ou seja, o quanto a grandeza medida ultrapassou o patamar seguro definido para si pelo operador. Isso porque uma violação operativa de baixa magnitude pode ser suportada pela rede elétrica sem prejudicar o suprimento de energia para o consumidor, sendo até mesmo preferível ter várias pequenas violações operativas a ter uma única violação operativa que seja muito severa. Todos esses

aspectos são observados na função objetivo que avalia a qualidade das soluções geradas pelas duas meta-heurísticas evolutivas multiobjetivo implementadas para a resolução do fluxo de potência ótimo.

1.3. ESTRUTURA DA DISSERTAÇÃO

Segue abaixo um breve resumo estrutural deste documento:

O Capítulo 1, “Introdução”, descreve a motivação e os objetivos dos estudos apresentados nesse documento, bem como a sua estrutura.

O Capítulo 2, “Otimização com Restrições de Segurança de Sistemas de Potência”, faz um breve levantamento histórico sobre os registros literários acerca da análise de segurança de sistemas de potência e fluxo de potência ótimo, e faz o resumo do estado da arte sobre as técnicas de otimização utilizadas para o problema em questão.

O Capítulo 3, “Análise de Segurança Estática” fala sobre a análise estática de segurança de sistemas de potência, abordando a questão do monitoramento do sistema, incluindo as restrições de fluxo de potências e os estados possíveis de operação do sistema, as modalidades preventiva e corretiva de despacho econômico seguro e as definições de análise de contingências e fluxo de potência ótimo.

O Capítulo 4, “Fluxo de Potência Ótimo”, refere-se ao Fluxo de Potência Ótimo e sua formulação, abordando a vertente com Restrições de Segurança (FPORS) e realizando uma revisão sobre os métodos tradicionais de resolução.

O Capítulo 5, “Otimização Multiobjetivo”, disserta sobre a otimização multiobjetivo, no qual são abordadas as soluções Pareto-ótimas, as metas da otimização multiobjetivo, as diferenças em relação às técnicas mono-objetivo e por fim uma revisão das técnicas tradicionais de otimização multiobjetivo, com suas vantagens e desvantagens.

O Capítulo 6, “Algoritmos Evolutivos”, aborda a técnica de algoritmos evolutivos, dissertando sobre a sua aplicação para a resolução de problemas de otimização multiobjetivo e apresentando as duas técnicas que serão comparadas neste trabalho.

O Capítulo 7, “Formulação do Problema”, diz respeito à metodologia utilizada para desenvolver o estudo, compreendendo formulação matemática, descrição do problema e os dados utilizados e o modelo estrutural da solução a ser retornada pelo algoritmo de otimização.

O Capítulo 8, “Resultados”, apresenta a coleta e avaliação dos resultados obtidos por cada técnica de otimização, bem como a melhor solução obtida em cada técnica e a evolução da aptidão para cada uma dessas soluções.

O Capítulo 9, “Conclusões”, traz as conclusões do trabalho e propostas para trabalhos futuros, compreendendo recapitulação do estudo, balanço dos resultados e propostas para trabalhos futuros.

2. OTIMIZAÇÃO SEGURA DE SISTEMAS DE POTÊNCIA

2.1. EVOLUÇÃO HISTÓRICA

O blecaute na cidade de Nova York em 1965 [2] foi o ponto de partida para o estabelecimento do conceito de segurança dos sistemas de potência como a habilidade de manter a continuidade no suprimento de energia elétrica enquanto respeita os seus limites operativos, mesmo após a falha de algum equipamento componente da rede. Um ano após o evento, em 1966, o termo “segurança” foi mencionado pela primeira vez na literatura [9] e a estrutura básica de classificação dos estados de operação dos sistemas elétricos foi proposta por Dy Liacco em [10], onde eram previstas três condições de operação para o sistema: Normal, Emergência e Restaurativo. Mais tarde, em 1969, foi incluída mais uma condição, chamada de Alerta [11], que é definida quando o sistema opera dentro dos seus limites operativos, mas uma contingência pode ocasionar uma violação de limite operativo em algum trecho. O conceito de segurança é complementado em 1987 com as definições dos modos de segurança preventivo e corretivo [12], que leva em consideração a capacidade do sistema de potência de operar com violações de limites operativos durante algum tempo, antes da atuação da proteção individual do equipamento.

Desde então, o conhecimento sobre a análise de segurança estática se expandiu cada vez mais, abarcando também a monitoração, seleção de contingências e o FPORS. Em 1997, por exemplo, Harsan et. al. propõe um novo método para a resolução do problema do FPORS, através da seleção de contingências com abordagem cíclica, que otimiza as iterações do algoritmo do FPORS [13]. Já em 1998, Alves e Monticelli abordam a decomposição do tipo pipeline, em que o sistema é decomposto em módulos funcionais que transformam as entradas em saídas, ou seja, essa análise retorna uma seleção de contingências [14]. Em 1999, Fu e Bose abordam mais uma vez a problemática da seleção de contingências, dessa vez baseado no índice de severidade das violações obtidas na análise de segurança dinâmica de um dado sistema de potência [15]. Também em 1999, Yurievich e Wong finalmente realizam a primeira abordagem sobre computação evolucionária aplicada a sistemas de potência: no caso, foi utilizado um protótipo de algoritmo genético para a obtenção da solução do fluxo de potência ótimo [16].

Conforme observado, uma das ferramentas essenciais na análise de segurança é o fluxo de potência ótimo. O problema de fluxo de potência ótimo constitui uma ativa linha de pesquisa na área de sistemas de potência desde o seu surgimento na década de 1960 com o

trabalho pioneiro de Carpentier apresentando uma formulação do problema de despacho econômico considerando restrições da rede elétrica em 1962 [17], juntamente com a definição do FPO por Dommel e Tinney em 1968 [18]. Os estudos de FPO têm por objetivo a determinação de um conjunto de controles de um dado sistema elétrico de potência visando otimizar um dado critério e simultaneamente satisfazer um conjunto de restrições operativas, tais como limites de geração de unidades geradoras, limites de tensão e limites de fluxo em linhas de transmissão. Esta ferramenta vem sendo utilizada extensivamente em estudos de planejamento da operação e da expansão de redes elétricas, podendo ser citados: despacho econômico, coordenação hidrotérmica, alocação ótima de bancos de capacitores, alocação ótima de unidades de medição fasorial (*Phasor Measurement Units* – PMUs), dentre outras aplicações.

A inclusão de restrições de segurança ao problema de fluxo de potência ótimo dá origem ao chamado Fluxo de Potência Ótimo com Restrições de Segurança (FPORS) [4]. Tendo como objetivo, por exemplo, a minimização do custo de operação e utilizando como variáveis de controle somente os despachos de potência ativa das unidades geradoras, o FPORS passa a ser visto como uma formulação mais geral do tradicional problema de despacho econômico, passando neste caso a considerar restrições tanto da rede elétrica e quanto de segurança. Estas questões evidenciam a importância do FPORS como ferramenta para a operação econômica e segura de sistemas de potência.

Os registros de pesquisa sobre o FPO na literatura técnica são vastos. Em 1981, Happ e Wirgau fizeram em [19] uma revisão sobre as aplicações do Fluxo de Potência Ótimo existentes até então. Muitas aplicações mantêm-se nos dias atuais: despacho econômico, controle de reativos, alocação de corte de carga e redespacho de potência ativa, tema desse projeto. Os autores mostraram grande visão de futuro ao mencionarem o despacho “ambiental”, no qual a geração de reativos é alocada de tal forma a minimizar os impactos ao meio ambiente através da redução da emissão de gases poluentes por parte das unidades térmicas, um estudo muito importante em tempos atuais, nos quais a fiscalização ambiental fica mais rigorosa a cada dia que passa.

Alguns anos depois, em 1987, Stott et. al. uma das primeiras abordagens de técnicas de otimização computacional aplicadas à sistemas de potência, neste estudo sobre a problemática do Fluxo de Potência Ótimo com Restrições de Segurança (FPORS) [20]. Aqui já é possível notar a sugestão de algoritmos para seleção das contingências a serem analisadas (baseados em critérios como maior sobrecarga do elemento que sofreu a queda do sistema de

energia ou a probabilidade daquela contingência realmente ocorrer) e para a detecção de violação dos limites operativos da rede elétrica, tal como sobrecarga nas linhas de transmissão, sobretensão nos barramentos, controle de reativo nas barras e também restrições econômicas. A intenção é atingir uma configuração de despacho ótima para uma dada rede elétrica, com prevenção para as contingências selecionadas, atendimento às restrições econômicas e de segurança da rede e sem violar seus limites operativos.

2.2. RESUMO DO ESTADO DA ARTE SOBRE TÉCNICAS DE OTIMIZAÇÃO

2.2.1. TÉCNICAS TRADICIONAIS

Diante da importância do fluxo de potência ótimo, abundam na literatura propostas para solução deste problema. Formulado em linhas gerais como um problema de otimização (programação) não-linear com restrições, a literatura apresenta diversos métodos clássicos de solução de problemas desta natureza, tais como métodos de programação não-linear e programação quadrática. Existem propostas que tem por objetivo identificar os pontos que atendem as condições de otimalidade de Karush-Kuhn-Tucker (KKT), utilizando, por exemplo, método de Newton para solução do sistema não-linear de equações que define tais condições de otimalidade de problemas de otimização não-linear com restrições. O Método dos Pontos Interiores (MPI), que converte as restrições de desigualdade em restrições de igualdade por meio da inserção de variáveis de folga, também vem sendo utilizado para solução do FPO, assim como a Programação Quadrática Sequencial (PQS) e o Método de Newton, que são utilizados na resolução dos problemas tanto isoladamente quanto em hibridizações com técnicas de diversas naturezas.

Os métodos não-lineares são historicamente mais aplicados para a resolução do FPO. Em [21], Jiang et. al. implementam o método de Diferenciação Automática (DA) para melhorar o Método dos Pontos Interiores utilizado para resolver um problema de FPO. Em [22], Yan et al. desenvolveram um método híbrido combinando Algoritmos Genéticos (AG) com o Método dos Pontos Interiores (MPI) não-linear para resolver o problema do Fluxo de Potência Reativo Ótimo (FPRO). Em [23], Duan et. al. desenvolve uma versão melhorada do MPI para a resolução do Fluxo de Potência Ótimo envolvendo equipamentos FACTS (do inglês *Flexible AC Transmission System* – Sistemas Flexíveis de Transmissão CA). Já em [24], Nie et. al. propôs uma variação do MPI primal-dual para a resolução do FPRO para um sistema híbrido CA-CC e por fim em [25] Chung et. al. propõem um MPI preditor-corretor para a solução do FPO dinâmico.

Em [26] Sivasubramani et. al. propõe uma combinação de Programação Quadrática Sequencial (PQS) com Algoritmos de Evolução Diferencial (AED) para a resolução do FPO, no qual o PQS fica responsável por gerar a população inicial a ser otimizada pelo AED, em busca da melhor solução. Em [27] Basu implementa uma combinação entre o PQS e o Algoritmo de Colônia de Abelhas (ACA), para a resolução do problema do Despacho Econômico Dinâmico (DED), no qual a potência ativa gerada pela unidade é decidida em tempo real de modo a operar o sistema da maneira mais econômica possível. A tarefa do ACA é indicar a direção de uma região ótima, enquanto o PQS faz uma busca local na região indicada pelo ACA. Em [28], Nejdavi et. al. propõe um algoritmo PQS combinado com o Método dos Pontos Interiores para uma resolução mais eficiente do FPO enquanto em [29] Morshed et. al. implementam um PQS híbrido para a obtenção do despacho econômico incluindo geração eólica, de natureza estocástica. Por fim em [30] Subathra et. al. utilizam um PSQ combinado com o Método de Entropia Cruzada para solucionar o problema do despacho econômico.

O Método de Newton é aplicado em [31] por Nguyen et. al. para resolver o problema do FPO com restrições de estabilidade transitória e avaliação do preço nodal de energia em sistemas munidos com equipamentos FACTS. Em [32], Nguyen et. al. desenvolvem uma ferramenta de otimização baseada no Método de Newton para determinar a melhor saída fornecida por um UPFC (do inglês *Unified Power Flow Controller* – Controlador de Fluxo de Potência Unificado) na operação no regime estacionário. Por fim, em [33], Lima et. al. realiza experimentos numéricos com um algoritmo de resolução do FPO baseado em técnicas paramétricas, o cujas condições necessárias são resolvidas pelo Método de Newton.

Na literatura técnica há ainda registros da utilização de técnicas de Programação Linear para solucionar o FPO. Em [34], Ferreira et al. utilizam Programação Linear Inteira Mista (PLIM) para resolver o problema do Fluxo de Potência Ótimo CA para sistemas de distribuição. Em [35] Lesieutre et. al. identifica os geradores que têm potencial para o mercado energético por meio de informações de sensibilidade fornecidas por um FPO baseado em Programação Linear. Já em [36], Miguelez et. al. descreve a implementação do serviço ancilar de controle de tensão espanhol, para o qual foi utilizado uma ferramenta de FPO baseada em PLIM. Por fim, em [37] Shao et. al. implementa um FPO baseado em Programação Linear que permite a equipamentos FACTS realizarem o controle corretivo, contornando de maneira eficiente possíveis sobrecargas e violações de tensão no sistema de potência estudado e permitindo assim uma operação segura da rede elétrica mesmo

considerando a ocorrência de violações que comprometam o estado seguro do sistema, no caso de acontecer alguma contingência grave e não haver nenhum estudo preventivo que levasse esse defeito em conta, ou seja, faz-se necessário uma ação corretiva.

2.2.2. ALGORITMOS EVOLUTIVOS

Trata-se de um nicho de heurísticas de otimização inspiradas nos mecanismos evolutivos encontrados na natureza, como auto-organização e comportamento adaptativo, que Rosenberg chamou de Algoritmos Evolutivos na sua tese de doutorado em 1967 [38]. Existem técnicas de otimização baseadas em enxame de abelhas, colônia de formigas, evolução das espécies, dentre outros. Os AE usam modelos computacionais probabilísticos para copiar os processos utilizados por Darwin em suas pesquisas, para resolver problemas encontrando soluções ótimas e subótimas. Em todos os modelos computacionais desenvolvidos, os Algoritmos Evolucionários simulam a evolução das espécies através dos métodos de seleção, reprodução e mutação dos indivíduos, fazendo com que o desempenho médio das populações no problema proposto melhore com o passar das gerações (iterações). Inclui várias técnicas, como Algoritmos Genéticos (AG), Recozimento Simulado (RS), Algoritmo de Colônia de Abelhas (ACA), Enxame de Partículas (PSO – *Particle Swarm Optimization*), Algoritmo de Evolução Diferencial (AED), Algoritmo de Busca Gravitacional (ABG), dentre inúmeras outras heurísticas.

Em [39], Todorovski et. al. adaptam um AG para resolver o FPO em um sistema com uma nova abordagem: a magnitude e o ângulo da tensão são pré-programados em todas as barras de geração e não apenas na barra de referência, através da aplicação de uma ordenação das barras da matriz de admitância em camadas, como um bloco tridiagonal esparsa, e também através de uma nova técnica de eliminação gaussiana e retro-substituição desenvolvido para essas matrizes, enquanto em [40] Afzalan et. al. utiliza uma técnica conhecida como Algoritmos Genéticos ϵ -Multiobjetivo (AGMO), uma combinação entre o AG e uma técnica de elitização da população chamada de ϵ -dominância, para resolver o problema do despacho de carga com restrições econômicas e ambientais considerando funções de custo não-suaves e não-convexas. Por fim, em [41] Chen et. al. desenvolve um ACA para resolver o FPO considerando como funções objetivo a minimização das perdas energéticas, custos de geração e impactos das emissões de poluentes.

Em [42], Abido desenvolve um PSO para a resolução do FPO multiobjetivo no sistema IEEE 30 barras, visando otimizar o custo de combustível, perfil de tensão e

estabilidade de tensão. Já em [43] Abido propõe um PSO multiobjetivo com melhoria dos mecanismos de busca locais e globais para resolver o problema do despacho econômico e ambiental. Em [44] Niknam et. al. elabora um PSO aperfeiçoado com lógica Fuzzy para resolver o problema do FPO multiobjetivo considerando custos, perdas, estabilidade de tensão e impacto das emissões como funções objetivo. Em [45] Varadarajan et. al. desenvolve um AED para a resolução do FPO multiobjetivo, na qual o problema é dividido em dois: fluxo de potência ativo ótimo (FPAO) e fluxo de potência reativa ótimo (FPRO). Por fim, em [46] Roselyn et. al. desenvolve uma abordagem de AED multiobjetivo para a resolução do problema do planejamento de geração de potência reativa considerando restrições de estabilidade de tensão, com o objetivo de minimizar o custo total de perdas energéticas e de produção de reativo dos bancos de capacitores e a maximização da margem de estabilidade de tensão.

Em [47] Bhattacharya et. al. aplica a técnica para a resolução do FPO multiobjetivo, tendo como meta a minimização do custo de combustível, do desvio de tensão e das perdas de geração, considerando as restrições operativas de praxe. Já em [48] Bhowmik et. al. utiliza um ABG modificado para resolver o FPO visando a otimização de critérios operacionais e econômicos. Em [49], Amorim et. al. propõem um algoritmo evolucionário baseado na teoria de Pareto combinado com lógica Fuzzy para a resolução do problema do FPORS, tendo como meta a redução dos custos de operação. Em [50] Surender Reddy et. al. propõem um algoritmo evolucionário aperfeiçoado por variáveis incrementais para resolver o problema do FPO. Em [51] Abido desenvolve um AG combinado com nichos de Pareto para a resolução do despacho econômico-ambiental multiobjetivo. Em [52] Bhagwan Das et. al. elaboram um algoritmo evolucionário híbrido combinando AG e RS para a resolução do fluxo de potência ótimo visando minimizar os custos de geração, as emissões, perdas de transmissão e desvios de tensão e fluxo de potência.

Em [53] Nangia et. al. testa uma técnica alternativa para a realização do FPO multiobjetivo. Em [54] Srinivasan et. al. empregam heurísticas evolucionárias para a obtenção do despacho ótimo das unidades geradoras de um sistema de potência, considerando as suas restrições operativas. Em [55], Nangia et. al. apresentam uma técnica de otimização multiobjetivo baseada no método da minimização da distância ideal no espaço 3D. Este método utiliza o conceito de um “Ponto Ideal” (PI) para escalar os problemas com múltiplos objetivos e minimiza a distância euclidiana entre PI e o conjunto de soluções não-inferior. Em [56] Roman et. al. aplicam pontos de Pareto uniformemente distribuídos para a resolução do

FPO multiobjetivo. Em [57] Yalcinoz et. al. apresenta uma técnica de otimização baseada em articulação progressiva de informação preferencial para resolver o problema do despacho econômico-ambiental. Em [58] Tripathy et. al. implementam um algoritmo de forrageamento de bactérias para a otimizar a perda de potência ativa e o limite de estabilidade de tensão.

Em [59] Abido et. al. utiliza um algoritmo evolucionário baseado em ótimo de Pareto e conjuntos Fuzzy para resolver a questão do despacho ótimo de reativo. Em [60] Singh et. al. apresenta uma abordagem de Pareto ponderada para realizar a alocação ótima dos despachos de potência ativa e reativa das unidades térmicas. Em [61] Basu desenvolve um AED multiobjetivo para resolver o despacho econômico-ambiental. Em [62] Niknam et. al. aplicam uma técnica conhecida como algoritmo do salto aleatório do sapo modificado para resolver o problema do FPO multiobjetivo. Em [63] Sivasubramani et. al. aplica um algoritmo de busca harmônica multiobjetivo para solucionar o problema do FPO. Em [64] Al-Hajri et. al. desenvolvem um algoritmo evolucionário com Pareto reforçado para resolver o fluxo de potência ótimo multiobjetivo. Em [65] Jeyadevi et. al. utilizam um AG híbrido para resolver o problema do despacho ótimo de reativo. Em [66] Mohamed et. al. utiliza um Algoritmo Adaptativo de Busca Direta por Malha (AABDM) multiobjetivo para resolver o problema do despacho ótimo para uma *microgrid*. Por fim, em [67] Medina et. al. realiza um estudo comparativo entre modernos algoritmos meta-heurísticos baseados em decomposição para resolver o FPO multiobjetivo.

Já em [68], Kumari et. al. formula o FPO como um problema de otimização multiobjetivo, no qual os parâmetros a serem otimizados são o custo de combustível, índice de estabilidade de tensão e perdas de transmissão, primeiro combinando dois parâmetros de cada vez e por fim combinando os três simultaneamente. O algoritmo desenvolvido combina uma nova técnica de fluxo de potência (Desacoplado Quadrático) com um AG pré-refinado. Um Algoritmo Evolucionário de Força Pareto (AEFP) é utilizado para formar o conjunto ótimo de Pareto, com a técnica de agrupamento hierárquico sendo utilizada para limitar o conjunto de trade-off. Por fim, uma abordagem baseada em lógica Fuzzy é utilizada para obter a solução ótima da curva de compensação. Em [69], Devaraj et. al. propõe um AG melhorado para o aumento da estabilidade de tensão. Trata-se de uma otimização multiobjetivo, onde as tensões de geração, fontes comutáveis de reativos e os comutadores de tap dos transformadores são as variáveis de otimização. A abordagem proposta permite que as variáveis de otimização sejam representadas na forma natural na população do AG. Para o

processamento genético eficaz, os operadores de cruzamento e mutação, que podem lidar com números de ponto flutuante e inteiros, são utilizados.

Em [70], Malik et. al. é elaborado um AG para fornecer a solução do problema do FPO, no qual as variáveis de controle são a potência ativa gerada, o perfil de tensão nas barras de geração, a posição de tap dos transformadores e os dispositivos de shunt, com a função objetivo de minimizar o custo de combustível. O AG implementado é flexível para a implementação de qualquer sistema de potência, desde que fornecidos os dados de linha, de barra, os custos de combustível para geração e a demanda de carga prevista. Em [71], Kumar et. al. modela o FPO com restrições de carregamento de linha incorporados à solução do despacho de potência ativa utilizando AG. O problema proposto é dividido em duas fases: na primeira, o despacho de potência ativa é solucionado com todas as restrições, exceto as de carregamento de linha, pelo AG. Na segunda, as violações de linha são minimizadas pela função objetivo do FPO através do AG. A solução resultante minimiza as violações de carregamento de linhas ao mesmo tempo que obtém o despacho econômico.

Já em [72], Lee et. al. propõe um algoritmo de otimização para resolver o problema do despacho econômico incluindo geração de energia eólica utilizando os chamados Algoritmos Genéticos Quânticos (AGQ), uma combinação entre AG e computação quântica. Adicionalmente à introdução de detalhes para modelos de despacho econômico geral, bem como de restrições associadas, é incluído também o efeito da geração de energia eólica. Por outro lado, a utilização de AGQ para resolver o processo de despacho econômico é também discutida e cenários reais são usados para os testes de simulação. Depois de comparar o AGQ com vários outros algoritmos comumente usados para resolver problemas de otimização, os resultados mostram que o AGQ é capaz de encontrar a solução ideal mais rapidamente e com precisão (ou seja, para obter o custo mínimo para geração de energia no menor tempo). No final, o impacto para a economia de custo total para a geração de energia após a adição (ou não adição) de geração de energia eólica também é discutida.

Em [73], Abookazemi et. al. apresenta uma aplicação de AG otimizado para resolver o problema do despacho de unidades térmicas. Uma estrutura paralela foi inicialmente desenvolvida para lidar com o problema da inviabilidade através de um AG estruturado e aprimorado, o que fornece um processo de busca eficaz e, portanto, maior economia. A metodologia proposta resultou em um melhor desempenho com uma operação mais rápida, utilizando ambos os métodos computacionais e classificação das características das unidades geradoras. Restrições típicas, tais como balanço de potência do sistema, *start-up* e *shut-down*

também foram considerados. Um número importante de parâmetros (tanto os que são considerados como padrão quanto os novos) do problema do despacho ativo de unidades térmicas foi identificado.

Em [74], Acharjee elabora um AG com restrições de segurança para a identificação do limite máximo de capacidade das barras de carga, enquanto em [75] Szuvovski et. al. desenvolve um AG combinado com FPO para atribuição simultânea de capacitores e reguladores de tensão em redes de distribuição. Em [76] Yaşar et. al. desenvolve um GA para solucionar o problema do despacho econômico com restrições ambientais, e por fim em [77] Liao elabora uma nova técnica híbrida, o Algoritmo Genético Quântico Caótico (AGQC), que corresponde a uma combinação entre AG, computação quântica e Teoria do Caos, para a solução do problema do despacho ativo com restrições ambientais e de segurança aplicados para redes do tipo *Smart Grid* contendo geração distribuída.

Por outro lado, em [78] Kapse et. al. elaboram uma nova abordagem de AG, desta vez para obter uma solução do fluxo de potência em regime permanente, como uma alternativa aos métodos iterativos convencionais. Em comparação ao método de Gauss-Seidel, o AG levou vantagem tanto em velocidade de convergência quanto em número de iterações. Em [79] Hassan et. al. aplicou a técnica dos AG's para otimização dos parâmetros do controlador unificado de fluxo de potência (UPFC) e sua localização no sistema elétrico em questão, enquanto em [80] Afzalan et. al. utiliza uma técnica conhecida como Algoritmos Genéticos ϵ -Multi-Objetivo (AGMO), uma combinação entre o AG e uma técnica de elitização da população chamada de ϵ -dominância, para resolver o problema do despacho de carga com restrições econômicas e ambientais considerando funções de custo não-suaves e não-convexas. Já em [81], Mahdad et. al. utiliza o Algoritmo Genético Paralelo Eficiente (AGPE), uma combinação do AG com programação paralela, para realizar o estudo de FPO de sistemas de potência de grande escala que possuem elementos FACTS em derivação.

Em [82], Mo et. al. propõem um PSO para a resolução do fluxo de potência ótimo com restrições de estabilidade transitória (FPOET), no qual as inequações de ângulo do rotor são adicionadas como restrições de desigualdade ao FPO, de modo a minimizar o custo total de combustível do sistema de potência. Já em [83], Yumbla et. al. utiliza um PSO com operadores de reconstrução para a resolução do fluxo de potência ótimo com restrições de segurança (FPORS), com o objetivo de minimizar o custo operacional total. Por outro lado, em [84] Baskar et. al. aplica uma abordagem melhorada do PSO, com uma adaptação estratégica da equação de velocidade para sistemas de larga escala assim como um fator de

aproximação adaptado, para a obtenção do despacho econômico com restrições de segurança. Já em [85] Abido propõe um PSO multiobjetivo com melhoria dos mecanismos de busca locais e globais para resolver o problema do despacho econômico e ambiental. Em [86] Azadani et. al. desenvolve um PSO para lidar com o multi-produto (reserva energética e energia despachada) e com o problema do despacho ótimo do ponto de vista do mercado de eletricidade, sendo oferecida uma solução para otimizar o custo total de mercado considerando as restrições do sistema.

Em [87] Niknam et. al. elabora um PSO aperfeiçoado com lógica Fuzzy para resolver o problema do FPO multiobjetivo considerando custos, perdas, estabilidade de tensão e impacto das emissões como funções objetivo. Já em [88] Leung et. al. desenvolve um PSO para resolver o problema do FPO para um sistema de potência com elementos FACTS incorporados à rede, mais notadamente o UPFC (Unified Power Flow Controller), tomando como função objetivo a minimização do custo total de operação e a manutenção do fluxo de potência dentro dos limites de segurança. Em [89] Maciel et. al. utilizam uma abordagem do PSO multiobjetivo para avaliar o impacto da geração distribuída no processo de planejamento da rede de distribuição. Por outro lado em [90] Mohammadi-Ivatloo apresenta um PSO com coeficiente de variação temporal da velocidade para resolver o problema do despacho econômico considerando o efeito do ponto de válvula, zonas proibidas de operação, restrições de taxa de rampa e perdas de transmissão. Por fim, em [91] Gomez-Gonzalez et. al. apresenta uma combinação entre o PSO do tipo discreto e o próprio estudo do FPO para otimizar a geração distribuída, procurando os melhores locais na rede de distribuição para conectá-la, ao invés de escolher entre um infundável número de possíveis combinações.

2.2.3. CONTRIBUIÇÃO PARA O ESTADO DA ARTE

Do levantamento do estado da arte é possível observar que a utilização de Algoritmos Evolutivos Multiobjetivos (AEMO) para a solução de problemas relacionados à otimização de sistemas de potência está cada vez mais em voga desde a última década até os tempos atuais, tendo cada vez mais implementações e publicações a respeito e tomando a frente das técnicas tradicionais de otimização com melhores resultados em comparações diretas, tanto em relação ao tempo de simulação quanto à precisão das soluções encontradas. Tanto que algumas aplicações de técnicas tradicionais utilizam hibridizações com técnicas de AE para melhorar seu desempenho, como em [26] e [27]. Assim, justifica-se a escolha de técnicas dessa natureza para solucionar o problema proposto nesse trabalho.

A contribuição para o estado da arte vem da elaboração e implementação do MOEPSO (do inglês *Multi Objective Evolutionary Particle Swarm Optimization* – Otimização por Enxame de Partículas Evolutivo Multiobjetivo) para redespacho de unidades de geração e obtenção do mínimo desvio em relação a um ponto de operação prévio, para o qual não foram encontradas publicações de aplicações nos últimos anos, então o presente trabalho pretende ajudar a preencher essa lacuna na literatura. O MOEPSO implementado tem sua eficácia comparada com o NSGA-II (do inglês *Elitist Non-dominated Sorting Genetic Algorithm* – Algoritmo Genético de Classificação Elitista por Não-dominância), uma das técnicas da classe dos AEMO mais utilizadas na literatura, com ótimos resultados para todos os problemas em que foi utilizada, e, portanto, um bom parâmetro de comparação. Ambos os métodos foram usados para solucionar o mesmo problema e comparados em tempo de simulação e qualidade das soluções apresentadas.

3. ANÁLISE DE SEGURANÇA ESTÁTICA

3.1. INTRODUÇÃO

De acordo com Wood et. al., a análise de segurança para sistemas de potência significa resumidamente estudar a manutenção da continuidade do suprimento de energia elétrica para os consumidores, na ocorrência de uma falha qualquer em algum dos equipamentos componentes da rede [4]. Como a ocorrência de falhas no sistema elétrico é imprevisível, o sistema é programado para a ocorrência de um conjunto de faltas previamente estabelecido segundo algum critério, a lista de contingências. Conforme já anteriormente mencionado, um defeito em um equipamento de alta tensão do sistema de potência pode ocasionar um efeito dominó composto de sucessivas violações de limites operativos, causando falhas de outros equipamentos da rede e levando a um blecaute que pode atingir enormes proporções. Por exemplo, quando ocorre a queda de uma linha de transmissão (LT), seja por rompimento do isolamento, descarga atmosférica ou etc., a ausência dessa LT pode causar um aumento no carregamento das demais linhas, uma vez que o fluxo de potência que escoava pela mesma terá que se redistribuir para as outras LT do sistema elétrico, possivelmente sobrecarregando essas linhas e fazendo atuar sua proteção individual, e assim sucessivamente levando a um efeito cascata seguido de blecaute.

Os estudos para avaliação da segurança de sistemas de potência podem ser divididos em dois grandes grupos relacionados basicamente com a escala de tempo dos fenômenos: segurança estática e segurança dinâmica. A análise de segurança estática avalia o estado operativo do sistema desconsiderando os transitórios envolvidos na ocorrência de cada contingência. Estes estudos consideram o desempenho da rede em regime permanente após a perturbação em análise. Por outro lado, a análise de segurança dinâmica considera a evolução temporal do sistema a partir da contingência em questão, avaliando principalmente questões de estabilidade da rede. Abundam na literatura propostas para análise de segurança estática, como em [7], [25], [92] e [93], e dinâmica em [82] e [94]-[96]. Discussões sobre as principais questões e ferramentas envolvidas na análise de segurança de sistemas de potência podem ser encontradas em [2], [25], e [97].

Neste trabalho, a avaliação de segurança foi processada levando em conta que a transição entre os estados de operação do sistema alcança um equilíbrio estável, ou seja, que todos os transitórios se estabilizaram, caracterizando a análise de segurança estática ou de regime permanente. Obviamente entre a ocorrência da falta e a estabilização do sistema

podem ocorrer diversas perturbações, onde o sistema pode nem mesmo se estabilizar, de modo que se faz necessária a análise dinâmica da segurança do sistema de potência. Os limites operativos considerados aqui para determinar se um sistema de potência é ou não seguro são os seguintes: limite de fluxo de potência ativa nas linhas de transmissão e transformadores e limites mínimos e máximos de tensão e geração de reativos nas barras.

3.2. ESTADOS DE OPERAÇÃO DO SISTEMA

A operação em regime permanente de sistemas de potência compreende três tipos de restrições, que irão fundamentar a definição dos estados de operação do sistema, conforme relatado por Monticelli em [98]:

- 1) *Restrições de Carga*: compreendem as injeções de potência ativa e reativa nas barras de carga e injeções de potência ativa nas barras de geração;
- 2) *Restrições de Operação*: compreendem os limites das magnitudes das tensões nas barras, dos fluxos de potência aparente nas linhas de transmissão e transformadores e das injeções de potência reativa nas barras de geração;
- 3) *Restrições de Segurança*: estão associadas a um conjunto pré-definido de possíveis contingências no sistema (lista de contingências), como perda de linha, geradores, transformadores, reatores shunt, entre outros equipamentos.

Geralmente a lista de contingências vinculada às restrições de segurança inclui contingências simples, ou seja, a queda de um equipamento por vez, podendo mais raramente conter contingências múltiplas. Não existem critérios fixos para a elaboração dessa lista: é possível tanto utilizar uma ferramenta computacional para a seleção automática das contingências quanto considerar a experiência do operador e as probabilidades de ocorrência de cada falha, ou levar em conta aspectos como o impacto da queda do equipamento no sistema de potência.

A definição das restrições da operação em regime permanente de sistemas de potência subsidia a definição dos quatro estados de operação do sistema: seguro, alerta, emergência e restaurativo, conforme relatado por Monticelli em [98]. Cabe observar que a rede elétrica pode flutuar entre os estados, dependendo da reação da mesma à ocorrência de uma contingência. A intenção é sempre manter a rede no estado de operação seguro, para tal são utilizadas duas modalidades de despacho das unidades geradoras: preventiva, na qual se leva em conta previamente a ocorrência de uma contingência, e corretiva, que leva em conta a capacidade corretiva da rede e faz parte do escopo da operação em tempo real.

Tabela 1 – Estados de operação do sistema de potência

Estado de Operação	Descrição
Seguro	Neste estado são obedecidas todas as restrições, ou seja, o sistema opera normalmente, atendendo a demanda e respeitando os limites operativos. Caso ocorra uma das contingências para a qual o sistema de potência foi programado, o fornecimento de energia prossegue normalmente. Entretanto, se ocorrer uma contingência não prevista, o sistema pode entrar em estado de emergência.
Alerta	Neste estado o sistema continua a atender a demanda enquanto respeita os limites operativos, entretanto até mesmo a ocorrência de uma contingência da lista pode levar o sistema para o estado de emergência.
Emergência	Neste estado ocorre a violação de pelo menos um limite operativo, o que pode ser provocado por uma contingência e o consequente desligamento de um ou mais equipamentos do sistema, que se mantêm intacto, exceto os equipamentos que provocaram a emergência.
Restaurativo	Neste estado ocorre a eliminação da emergência através do desligamento manual ou automático de uma ou mais partes do sistema feito pelo centro de controle ou por dispositivos locais. Os limites operativos são atendidos, entretanto o sistema não está intacto, podendo haver cargas não atendidas, ilhamento, etc.

A transição entre os estados de operação do sistema de potência em regime permanente está ilustrada na Figura 2, e uma descrição detalhada do processo de transição entre os estados está contida na Tabela 2.

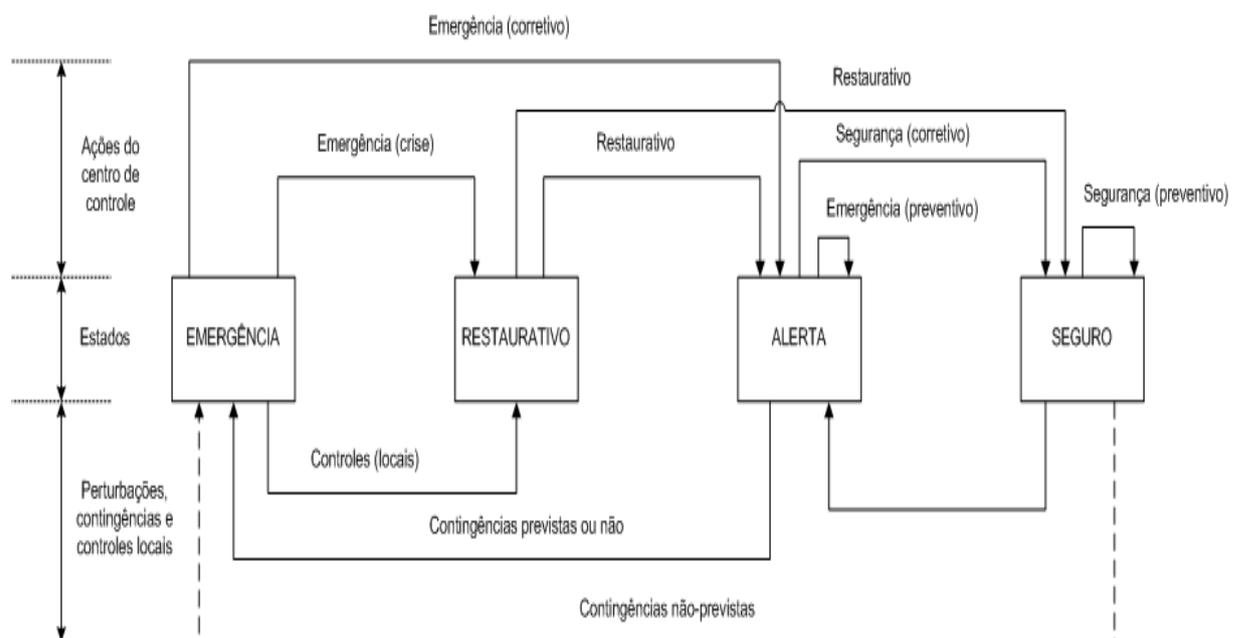
**Figura 2 – Estados do sistema e as transições entre os mesmos [98]**

Tabela 2 – Transição entre os estados de operação

Estado Inicial	Estado Final	Descrição
Seguro	Alerta	Ocorre como consequência de uma contingência, ou até mesmo devido a uma evolução natural da demanda.
Alerta	Seguro	Ocorre a partir da execução de um controle de segurança por parte dos operadores no centro de controle, no qual é realizado um redespacho da geração que leva o sistema a operar em outro ponto, seguro.
Seguro	Seguro	De posse das informações sobre a previsão de carga em curto prazo, é possível alterar o ponto de operação do sistema tendo em conta a futura demanda (da ordem de uma hora), evitando assim que o sistema tenha que passar por duas transições de estado (seguro para alerta e alerta para seguro).
Alerta	Emergência	Ocorre quando uma contingência que levaria o sistema para o estado de emergência acontece antes que o operador tenha tomado ações que levassem o sistema de volta para o estado seguro.
Emergência	Alerta	Ocorre a partir de ações corretivas visando eliminar violações de limites operativos, sem que haja corte de carga. Essas ações podem ser a redistribuição da geração, mudança de tap do transformador, e etc.
Emergência	Restaurativo	Ocorre quando é inevitável o corte de carga, o que acontece quando os dispositivos locais de controle e proteção atuam antes que qualquer providência seja tomada pelo centro de controle, desligando cargas e circuitos, ou então quando o próprio centro de controle opta por fazê-lo, seja por meio da função de controle de emergência ou por decisão do operador. Esta opção é escolhida quando não é possível restabelecer o sistema de modo mais brando, como no remanejamento de geração ou controle de tensão.
Alerta	Alerta	Estando o sistema em estado de alerta e sabendo que a previsão de carga futura leva a uma chance real de ocorrência de estado de emergência, o operador pode mudar o ponto de operação do sistema de maneira tal que para o estado previsto não seja mais verificada a emergência anteriormente detectada. O operador escolhe essa opção quando está impossibilitado de levar o sistema ao estado seguro por alguma razão, como no caso da manutenção de algum elemento do sistema.
Restaurativo	Alerta ou Seguro	O controle restaurativo tem como atribuição religar as cargas e os circuitos do sistema desligados durante uma emergência, levando o sistema ao estado seguro ou, na pior das hipóteses, ao estado de alerta.

3.3. ANÁLISE DE CONTINGÊNCIAS

3.3.1. INTRODUÇÃO

O evento chamado de contingência é definido como uma ocorrência em que um ou mais equipamentos componentes do sistema de potência saem de operação de maneira não esperada, podendo ocasionar uma mudança no estado de operação da rede elétrica [101]. A contingência pode ser tanto um evento previamente analisado, que compõe uma lista de contingências para as quais o sistema está preparado, quanto pode ser um evento não previsto, que pode ocasionar a saída do modo de operação seguro pelo fato do sistema não estar preparado para a sua ocorrência. Sendo assim, em uma definição comum, a contingência pode ser classificada em prevista ou imprevista. Outra classificação de contingências diz respeito ao número de equipamentos que saem de operação em um evento: quando apenas um equipamento sai de operação, a contingência é considerada simples; quando dois ou mais equipamentos saem de operação, a contingência é considerada múltipla. Normalmente o número de contingências simples é muito menor que a quantidade de possibilidades combinatoriais de contingências múltiplas, sendo que em sistemas de grande porte pode haver um grande número de contingências múltiplas [102].

Dessa forma, a prática recomendada é realizar a análise primeiramente de todas as contingências simples, e depois das contingências múltiplas de ocorrência mais provável de acordo com critérios estabelecidos pelo próprio operador. Esse problema é agravado no contexto da operação em tempo real, onde a restrição de tempo computacional para processamento das possibilidades de contingência é muito severa, principalmente para sistemas de grande porte. Conforme já relatado, é essencial manter o sistema operando de maneira segura, com as grandezas físicas dentro dos limites operativos definidos pelo operador, em caso de contingência, pois uma violação de limite operativo pode fazer atuar o dispositivo individual de proteção de algum equipamento, que causará uma violação de limite operativo em outro equipamento, e assim por diante, ocasionando um blecaute por contingências em cascata [103].

Sendo assim, é importante identificar as contingências que conduzem o sistema a condições de operação anormais ou próximas ao ponto crítico. Em outras palavras, caso a rede se encontre em um ponto de operação que corresponda aos estados operativos seguro e alerta, deve-se verificar qual será o efeito da ocorrência de contingências na rede, sob o ponto de vista da violação de limites operativos, avaliando seu impacto sobre a operação do sistema.

Os limites operacionais levados em conta na análise de contingências compreendem fluxo de potência nas linhas de transmissão, magnitude de tensão nos barramentos e geração de reativos pelas unidades geradoras.

Caso seja detectado o aparecimento de violações após a ocorrência de uma certa contingência, as seguintes atitudes podem ser tomadas pelo operador: desenvolver uma rotina corretiva, que será utilizada caso ocorra de fato a contingência; ou desenvolver uma estratégia preventiva antes da ocorrência da contingência, de modo que a mesma deixe de provocar violações. Conhecido o ponto de operação inicial da rede (comumente denominado como caso base), pode-se iniciar o processo de análise de contingências, que começa com a verificação de seus limites operativos. Caso haja violações, ações de controle devem ser realizadas de forma a eliminar as violações que forem detectadas, havendo situações em que a única ação para retornar a operação para o estado normal é o corte de carga [103].

3.3.2. ANÁLISE DE CONTINGÊNCIAS SIMPLES UTILIZANDO Z_{BARRA}

Sempre que uma linha de transmissão ou um transformador é retirado de serviço, é dito que uma contingência ocorreu. Esses desligamentos podem ser tanto planejados, como em uma manutenção programada, quanto forçados, como quando as condições meteorológicas provocam a falha do referido equipamento. Após a estabilização dos transitórios de tensão e corrente correspondentes à contingência ocorrida, um novo estado operativo de regime permanente do sistema de potência é obtido, no qual os fluxos de potência nas linhas de transmissão e as tensões nos barramentos foram alterados em relação ao estado operativo pré-contingência. Neste caso, a ordem é evitar sobrecarga nas linhas de transmissão devido a uma corrente excessiva, e também episódios de sobretensão e subtensão nos barramentos da rede elétrica, de modo a não tornar o sistema susceptível a interrupções do fornecimento de energia.

A enorme quantidade de possíveis contingências é analisada através de um programa de avaliação de contingências, chamado de análise de contingências, que consiste em verificar se há ou não alguma condição insegura na rede no estado estacionário após qualquer uma das falhas. Normalmente, é necessária uma nova simulação do fluxo de potência para cada nova topologia da rede gerada por cada contingência, o que deixaria a análise de contingências com um elevado custo computacional. No entanto, Grainger et. al. em [104] descreve uma nova metodologia de análise de contingências baseada na matriz de impedância nodal da rede, que

necessita apenas de uma simulação de fluxo de potência, para o caso base, e a partir dela aproxima os efeitos no sistema de potência causado pelas contingências.

Dado um ponto de operação (fluxo de potência ou estimador de estado), todas as cargas e gerações são convertidas para injeções de correntes consideradas constantes e proporcionais à tensão. A variação nas tensões devido à variação de corrente ΔI_m na barra m é dada por:

$$\begin{bmatrix} \Delta V_1 \\ \vdots \\ \Delta V_i \\ \Delta V_j \\ \vdots \\ \Delta V_N \end{bmatrix} = \begin{bmatrix} V_1 - V_1^0 \\ \vdots \\ V_i - V_i^0 \\ V_j - V_j^0 \\ \vdots \\ V_N - V_j^0 \end{bmatrix} = \begin{bmatrix} Z_{11} & \dots & Z_{1m} & Z_{1n} & \dots & Z_{1N} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Z_{m1} & \dots & Z_{mm} & Z_{mn} & \dots & Z_{mN} \\ Z_{n1} & \dots & Z_{nm} & Z_{nn} & \dots & Z_{nN} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Z_{N1} & \dots & Z_{Nm} & Z_{Nn} & \vdots & Z_{NN} \end{bmatrix} \begin{bmatrix} 0 \\ \vdots \\ \Delta I_m \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} Z_{1m} \\ \vdots \\ Z_{mm} \\ Z_{nm} \\ \vdots \\ Z_{Nm} \end{bmatrix} \Delta I_m \quad (3.1)$$

As variações da tensão nas barras i e j podem ser descritas como:

$$\Delta V_i = Z_{im} \Delta I_m \quad (3.2)$$

$$\Delta V_j = Z_{jm} \Delta I_m \quad (3.3)$$

Se o ramo conectando as barras i e j possui uma impedância z_{ij} , então a variação do fluxo de corrente no ramo conectando as barras i e j é:

$$\Delta I_{ij} = \frac{\Delta V_i - \Delta V_j}{z_{ij}} = \frac{Z_{im} - Z_{jm}}{z_{ij}} \Delta I_m \quad (3.4)$$

A partir da equação (3.4) é possível definir o fator de sensibilidade da variação de corrente no ramo conectando as barras i e j devido à variação de corrente injetada na barra m , $K_{ij,m}$:

$$K_{ij,m} \triangleq \frac{\Delta I_{ij}}{\Delta I_m} = \frac{Z_{im} - Z_{jm}}{z_{ij}} \quad (3.5)$$

Portanto, a variação de corrente no ramo conectando as barras i e j devido à variação de corrente injetada na barra m é definida como:

$$\Delta I_{ij} = K_{ij,m} \Delta I_m \quad (3.6)$$

Caso haja variação nas injeções de corrente em duas barras, p e q , o efeito no ramo conectando as barras i e j pode ser estimado pelo princípio da superposição:

$$\Delta I_{ij} = K_{ij,p} \Delta I_p + K_{ij,q} \Delta I_q \quad (3.7)$$

Para estudar a remoção de um ramo de impedância z_{mn} conectando as barras m e n , basta adicionar um ramo de impedância $-z_{mn}$ entre as barras m e n , tal como mostrado na Figura 3:

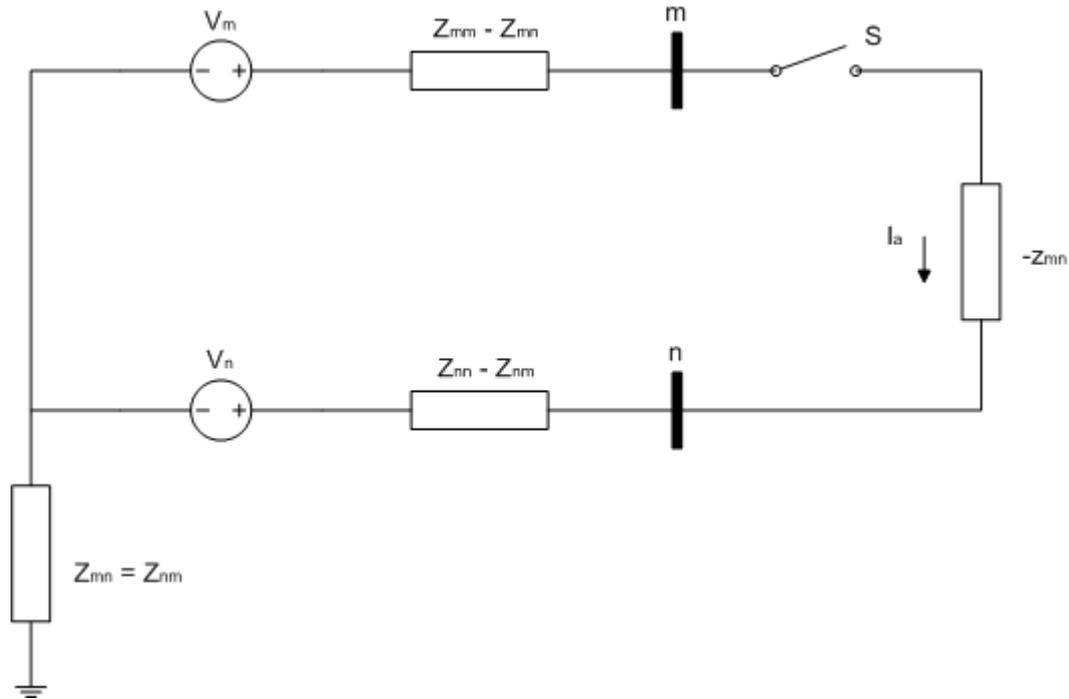


Figura 3 – Equivalente Thévenin para simulação da saída da linha m - n

Ao fechar a chave S , a impedância $-z_{mn}$ é conectada entre as barras m e n , permitindo a circulação da corrente I_a . Sabendo que $Z_{mn} = Z_{nm}$, têm-se que:

$$I_a = \frac{V_m^0 - V_n^0}{(Z_{mm} - Z_{nn} + 2Z_{mn}) - z_{mn}} = \frac{V_m^0 - V_n^0}{Z_{th,mn} - z_{mn}} \quad (3.8)$$

Neste caso, a corrente I_a atuará como corrente de compensação nas barras m e n , sendo $\Delta I_m = -I_a$ para a barra m , e $\Delta I_n = I_a$ para a barra n . Dessa forma, a variação de corrente no ramo conectando as barras i e j devido à variação nas injeções de corrente nas barras m e n é expressa como:

$$\Delta I_{ij} = K_{ij,m} \Delta I_m + K_{ij,n} \Delta I_n = \frac{[(Z_{in} - Z_{im}) - (Z_{jn} - Z_{jm})]}{z_{ij}} I_a \quad (3.9)$$

Substituindo I_a pela equação (3.8) obtêm-se:

$$\Delta I_{ij} = \frac{[(Z_{in} - Z_{im}) - (Z_{jn} - Z_{jm})]}{z_{ij}} \frac{V_m^0 - V_n^0}{Z_{th,mn} - z_{mn}} \quad (3.10)$$

É possível, portanto, considerar a queda do ramo conectando as barras m e n como variações de corrente nas respectivas barras. Substituindo as equações (3.2), (3.3) e (3.5) na equação (3.7), fazendo analogia para as barras consideradas:

$$\Delta I_{ij} = \frac{Z_{im} - Z_{jm}}{z_{ij}} \frac{\Delta V_i}{Z_{im}} + \frac{Z_{in} - Z_{jn}}{z_{ij}} \frac{\Delta V_i}{Z_{in}} = \frac{\Delta V_i}{z_{ij}} \left(\frac{Z_{im} - Z_{jm}}{Z_{im}} + \frac{Z_{in} - Z_{jn}}{Z_{in}} \right) \quad (3.11)$$

$$\Delta I_{ij} = \frac{Z_{im} - Z_{jm}}{z_{ij}} \frac{\Delta V_j}{Z_{jm}} + \frac{Z_{in} - Z_{jn}}{z_{ij}} \frac{\Delta V_j}{Z_{jn}} = \frac{\Delta V_j}{z_{ij}} \left(\frac{Z_{im} - Z_{jm}}{Z_{jm}} + \frac{Z_{in} - Z_{jn}}{Z_{jn}} \right) \quad (3.12)$$

Por fim, substituindo a equação (3.10) nas equações (3.11) e (3.12), é possível obter as novas tensões nas barras i e j devido ao desligamento do ramo conectando as barras m e n :

$$V_i = V_i^0 - Z_{im} Z_{in} \frac{(Z_{im} - Z_{in}) - (Z_{jm} - Z_{jn})}{Z_{in}(Z_{im} - Z_{jm}) + Z_{im}(Z_{in} - Z_{jn})} \frac{V_m^0 - V_n^0}{Z_{th,mn} - z_{mn}} \quad (3.13)$$

$$V_j = V_j^0 - Z_{jm} Z_{jn} \frac{(Z_{im} - Z_{in}) - (Z_{jm} - Z_{jn})}{Z_{jn}(Z_{im} - Z_{jm}) + Z_{jm}(Z_{in} - Z_{jn})} \frac{V_m^0 - V_n^0}{Z_{th,mn} - z_{mn}} \quad (3.14)$$

A corrente na linha conectando as barras m e n antes da ocorrência do defeito pode ser calculada em função das tensões pré-defeito e da impedância z_{mn} :

$$I_{mn}^0 = \frac{V_m^0 - V_n^0}{z_{mn}} \quad (3.15)$$

Utilizando a equação (3.15) na equação (3.10), obtêm-se:

$$\Delta I_{ij} = \frac{z_{mn}}{z_{ij}} \left[\frac{(Z_{in} - Z_{im}) - (Z_{jn} - Z_{jm})}{Z_{th,mn} - z_{mn}} \right] I_{mn}^0 \quad (3.16)$$

Dividindo a equação (3.16) pela equação (3.15), obtêm-se o fator de sensibilidade da variação de corrente no ramo conectando as barras i e j devido ao desligamento do ramo conectando as barras m e n .

$$\frac{\Delta I_{ij}}{I_{mn}^0} = - \frac{z_{mn}}{z_{ij}} \left[\frac{(Z_{im} - Z_{in}) - (Z_{jm} - Z_{jn})}{Z_{th,mn} - z_{mn}} \right] \triangleq L_{ij,mn} \quad (3.17)$$

Analogamente, o fator de sensibilidade da variação de corrente no ramo conectando as barras p e q , de impedância z_{pq} , devido ao desligamento do ramo conectando as barras m e n é expresso como:

$$L_{pq,mn} = \frac{\Delta I_{pq}}{I_{mn}^0} = -\frac{z_{mn}}{z_{pq}} \left[\frac{(Z_{pm} - Z_{pn}) - (Z_{qm} - Z_{qn})}{Z_{th,mn} - z_{mn}} \right] \quad (3.18)$$

Dessa forma, obtêm-se as novas correntes que percorrem os ramos conectando as barras i e j e também p e q quando ocorre a falta do ramo conectando as barras m e n :

$$I_{ij} = I_{ij}^0 + \Delta I_{ij} = I_{ij}^0 + L_{ij,mn} I_{mn}^0 \quad (3.19)$$

$$I_{pq} = I_{pq}^0 + \Delta I_{pq} = I_{pq}^0 + L_{pq,mn} I_{mn}^0 \quad (3.20)$$

Conhecendo a nova estimativa para as correntes nos ramos e para as tensões nos barramentos do sistema de potência, basta aplicar o resultado nas equações de fluxo de potência para obter o estado operativo da rede após a contingência, e assim verificar se a mesma mantém uma operação segura, respeitando os limites operativos, depois da ocorrência da contingência em questão.

4. FLUXO DE POTÊNCIA ÓTIMO

4.1. INTRODUÇÃO

O Fluxo de Potência Ótimo (FPO) é uma ferramenta computacional que visa obter os ajustes das variáveis de controle para condições otimizadas da operação do sistema de potência (despacho econômico, minimização de perdas da transmissão, dentre outros), não deixando de observar o atendimento de um conjunto de restrições físicas e operacionais dos equipamentos e da rede de transmissão. Em outras palavras, otimizar o ponto de operação de uma rede elétrica de acordo com um determinado critério (função objetivo) sujeito a algumas restrições (equações e inequações). A necessidade de conciliar a meta representada na função objetivo com as restrições operacionais da rede confere ao problema do FPO um elevado grau de complexidade, sendo exploradas diversas técnicas para abordá-lo.

Levando em conta as características da sua formulação, os problemas de FPO podem ser divididos em duas subclasses. Quando o problema apresenta tanto funções objetivo quanto restrições operacionais de natureza linear, a abordagem é realizada através de técnicas de programação linear, enquanto que os problemas que apresentam qualquer não-linearidade, seja nas funções objetivo ou nas restrições, são abordados através de técnicas de programação não-linear ou então são linearizados em torno de um ponto de operação, de modo a permitir a utilização de alguma técnica de programação linear para resolvê-lo. Existem ainda outras formas de classificação dos problemas de FPO: tipo de abordagem da função objetivo, que pode ser mono ou multiobjetivo; e método de resolução utilizado, que pode ser clássico ou metaheurístico.

Como é uma ferramenta que proporciona aos operadores e planejadores do sistema de potência a possibilidade de analisar problemas de múltiplas variáveis, o FPO possui várias aplicações na otimização de redes elétricas, tais como: despacho econômico e seguro (tanto para operação em tempo real, quanto para estudos de planejamento da operação e expansão); estudos de coordenação hidrotérmica; minimização de perdas elétricas em sistemas de potência; minimização de emissão de gases poluentes na operação de sistemas elétricos; planejamento de expansão da transmissão; dentre outras diversas aplicações.

Resumindo, com o Fluxo de Potência Ótimo escolhe-se, dentre os vários pontos de operação possíveis, aquele que otimize os critérios escolhido. A intenção é atingir uma configuração ótima para uma dada rede elétrica, de acordo com o ponto de vista da função objetivo trabalhada, atendendo as restrições operativas inerentes ao sistema de potência e

também outras restrições próprias do problema a ser resolvido. Trata-se de um tema sobre o qual os pesquisadores debruçam-se há mais de 50 anos, e ainda tem muito a oferecer em termos de pesquisa, com o surgimento de novas técnicas de otimização e computadores ainda mais potentes.

4.2. FORMULAÇÃO DO PROBLEMA

Normalmente, o FPO é um problema de otimização voltado para a minimização de alguma função objetivo, com raras exceções que envolvem maximização. Devido à natureza das funções objetivo e restrições envolvidas, é considerado um problema de otimização não-linear. É modelado como abaixo:

$$\underline{F} = \min_{\underline{x}} \underline{f}(\underline{x}, \underline{u}) \quad (4.1)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}, \underline{u}) = \underline{0} \\ \underline{h}(\underline{x}, \underline{u}) \geq \underline{0} \end{cases} \quad (4.2)$$

Onde:

$\underline{x} \in \mathbb{R}^{2n_{barras}}$ – vetor com as $2n_{barras}$ variáveis de estado;

$\underline{u} \in \mathbb{R}^n$ – vetor com as n variáveis de controle;

$\underline{F}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto dos n_{obj} critérios que se deseja otimizar;

$\underline{f}(\underline{x}, \underline{u}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto das n_{obj} funções objetivo;

$\underline{g}(\underline{x}, \underline{u}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$ - conjunto das n_{igual} restrições de igualdade;

$\underline{h}(\underline{x}, \underline{u}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{desig}}$ - conjunto das n_{desig} restrições de desigualdade.

O vetor \underline{u} é composto por variáveis do tipo independente (ou de controle), que são aquelas alteradas durante o processo de solução para obter o ponto de operação ótimo do sistema de potência, podendo ser representadas na rede pela potência ativa gerada pela máquina, módulo de tensão nas barras de geração, posição de tap do transformador, potência reativa gerada, dentre outros exemplos. O outro tipo de variável presente nos estudos de fluxo de potência, representada pelo vetor \underline{x} , é aquela que informa o estado da rede elétrica, as variáveis dependentes (ou de estado), que são representadas no sistema de potência pelo módulo e ângulo das tensões de fase de cada barra do sistema.

As restrições de igualdade presentes no estudo do FPO geralmente correspondem às equações de balanço de potência da rede elétrica, no qual a potência total entregue por uma

unidade geradora deve corresponder à soma dos fluxos que deixam essa unidade através dos ramos do sistema, ou seja, nada mais que a imposição da Primeira Lei de Kirchoff [98]. É expressa matematicamente como abaixo:

$$\sum_{m \in \Omega_k} P_{km} = P_k \quad (4.2)$$

$$\sum_{m \in \Omega_k} Q_{km} = Q_k + V_i^2 b_{km}^{sh} \quad (4.3)$$

Onde:

Ω_k - conjunto das barras ligadas à barra k ;

P_k - injeção líquida de potência ativa na barra k ;

Q_k - injeção líquida de potência reativa na barra k ;

P_{km} - fluxo de potência ativa no ramo localizado entre as barras k e m ;

Q_{km} - fluxo de potência reativa no ramo localizado entre as barras k e m ;

V_i - magnitude da tensão na barra i ;

b_k^{sh} - susceptância shunt ligada à barra k .

Já as restrições de desigualdade correspondem às inequações que representam as limitações do sistema de potência, tanto físicas, relacionadas à capacidade térmica de transmissão dos ramos da rede, quanto operacionais, relacionadas aos aspectos de segurança da operação do sistema. No problema de FPO é comum haver limites para as seguintes variáveis, que também são usadas neste trabalho:

$$V_k^{min} \leq V_k \leq V_k^{max} \quad (4.4)$$

$$Qg_k^{min} \leq Qg_k \leq Qg_k^{max} \quad (4.5)$$

$$Pg_k^{min} \leq Pg_k \leq Pg_k^{max} \quad (4.6)$$

$$-S_{km}^{max} \leq S_{km} \leq S_{km}^{max} \quad (4.7)$$

Onde:

V_k^{lim} - limite (mínimo ou máximo) de tensão nodal admitida na barra k ;

Qg_k^{lim} - limite (mínimo ou máximo) de potência reativa gerada na barra k ;

Pg_k^{lim} - limite (mínimo ou máximo) de potência ativa gerada na barra k ;

S_{km}^{max} - carregamento máximo no ramo localizado entre as barras k e m .

O estabelecimento de funções objetivo que consigam descrever adequadamente a melhor condição operativa da rede elétrica é o aspecto mais complexo da formulação do problema de FPO. Em certos casos uma expressão matemática não consegue descrever a contento o problema, em outros casos o atendimento das restrições é mais importante do que a otimização da função objetivo. A formulação da função objetivo utilizada neste trabalho será descrita mais adiante, no Capítulo 7.

4.3. MÉTODOS TRADICIONAIS DE SOLUÇÃO DO FPO

4.3.1. MÉTODOS BASEADOS EM PROGRAMAÇÃO LINEAR

Apesar de ser geralmente composto por funções não-lineares, o FPO pode ser representado como um problema de programação linear (que na verdade é um caso particular de programação não-linear) através de um processo de linearização das equações originais do problema (4.1 e 4.2). Essas equações sofrem sucessivas aproximações de forma a linearizar a solução do problema do FPO, tal como abaixo [100]:

$$\underline{F}' = \min_{\underline{x}} \underline{f}'(\underline{x}^0 + \Delta\underline{x}) \quad (4.8)$$

Sujeito a:

$$\begin{cases} \underline{g}'(\underline{x}^0 + \Delta\underline{x}) = \underline{0} \\ \underline{h}'(\underline{x}^0 + \Delta\underline{x}) \geq \underline{0} \end{cases} \quad (4.9)$$

Onde:

$\underline{x}^0 \in \mathbb{R}^n$ - vetor-solução inicial com as n variáveis a serem especificadas;

$\Delta\underline{x} \in \mathbb{R}^n$ - variação em relação ao ponto inicial;

$\underline{F}': \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - aproximação linear do conjunto dos n_{obj} critérios que se deseja otimizar;

$\underline{f}'(\underline{x}^0 + \Delta\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - aproximação linear do conjunto das n_{obj} funções objetivo;

$\underline{g}'(\underline{x}^0 + \Delta\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$ - aproximação linear do conjunto das n_{igual} restrições de igualdade;

$\underline{h}'(\underline{x}^0 + \Delta\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{desig}}$ - aproximação linear do conjunto das n_{desig} restrições de desigualdade.

Dessa forma, a linearização da função objetivo e das restrições é o caminho através do qual cada aproximação sucessiva calcula a direção do ponto ótimo $\Delta\underline{x}$ [70]. Porém, a

resolução do problema linearizado representado nas equações (4.8) e (4.9) não garante a solução do problema não-linear original mostrado nas equações (4.1) e (4.2), sendo necessário, portanto, a execução do fluxo de potência convencional entre cada linearização sucessiva. As vantagens dos métodos de programação linear para resolução do FPO incluem a detecção eficiente de casos sem solução real, a facilidade na resolução de problemas de FPO com análise de segurança e tempos relativamente reduzidos de resolução. Os métodos mais utilizados de programação linear na solução do FPO incluem o método Simplex, o método baseado no Vetor Gradiente e o Método dos Pontos Interiores (MPI) para programação linear [100].

4.3.2. MÉTODOS BASEADOS EM PROGRAMAÇÃO NÃO-LINEAR

Nem sempre é possível realizar a aproximação das equações não-lineares representativas do FPO para funções lineares através da aproximação sucessiva, o que reforça a opção de se resolver diretamente o problema não-linear, através de técnicas de Programação Não-Linear (PNL). Nesse contexto, há uma modelagem mais precisa do problema de otimização, entretanto a resolução mais lenta demonstra um maior consumo de recursos computacionais. Os métodos de PNL utilizados na solução do FPO incluem a Programação Quadrática Sequencial (PQS), Método do Gradiente Reduzido (MGR), Método de Newton e Método dos Pontos Interiores (MPI), historicamente utilizados com sucesso na resolução do FPO com formulação não-linear, sendo que o desempenho de maior destaque, principalmente em sistemas de grande porte, dentre essas metodologias coube ao MPI, notadamente à versão primal-dual [100].

No MPI, o problema do FPO é reformulado de maneira tal que contenha apenas restrições de igualdade, com as restrições de desigualdade incorporadas à função objetivo através de uma função de penalização. O enunciado inicial é como segue:

$$\underline{F} = \min_{\underline{x}} \underline{f}(\underline{x}) \quad (4.10)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{w}^{min} \leq \underline{x} \leq \underline{w}^{max} \end{cases} \quad (4.11)$$

Onde:

$\underline{g}(\underline{x})$: $\mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$ - conjunto das n_{igual} restrições de igualdade;

$\underline{w}^{lim} \in \mathbb{R}^n$ - vetor contendo os limites operativos das n variáveis especificadas.

Com a inclusão das variáveis de folga \underline{s}^{min} e \underline{s}^{max} , as restrições de desigualdade tornam-se restrições de igualdade:

$$\underline{F} = \min_{\underline{x}} \underline{f}(\underline{x}) \quad (4.11)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{x} - \underline{s}^{min} = \underline{w}^{min} \\ \underline{x} + \underline{s}^{max} = \underline{w}^{max} \\ \underline{s}^{min}, \underline{s}^{max} \geq \underline{0} \end{cases} \quad (4.12)$$

As variáveis de folga são incorporadas à função objetivo através de uma função de penalização chamada de barreira logarítmica. Assim, o problema original é transformado em uma sequência de problemas parametrizados pela variável barreira (μ):

$$\underline{F} = \min_{\underline{x}} \left[\underline{f}(\underline{x}) - \mu \sum_{i=1,n} \ln(\underline{s}_i^{min}) - \mu \sum_{i=1,n} \ln(\underline{s}_i^{max}) \right] \quad (4.13)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{x} - \underline{s}^{min} = \underline{w}^{min} \\ \underline{x} + \underline{s}^{max} = \underline{w}^{max} \end{cases} \quad (4.14)$$

Ao incorporar a barreira logarítmica, o MPI busca resolver o problema de otimização proposto na equação (4.13) para cada valor de μ , fazendo com que μ tenda a zero. Assim, para cada valor de μ executa-se uma iteração do método de Newton-Raphson no sistema de equações não-lineares definidos por condições chamadas de condições de otimalidade de primeira ordem de Karush-Kuhn-Tucker (KKT).

4.4. FLUXO DE POTÊNCIA ÓTIMO COM RESTRIÇÕES DE SEGURANÇA (FPORS)

4.4.1. INTRODUÇÃO

O problema do FPORS é formulado em sua forma geral como um caso de otimização não-linear, não-convexo, de larga escala e de regime permanente, podendo conter variáveis tanto discretas quanto contínuas. Sua meta é otimizar uma certa função-objetivo através de ajuste nas variáveis de controle disponíveis, desde que satisfaçam algumas restrições de igualdade (por exemplo, equações do fluxo de potência) e desigualdade (por exemplo, limites

físicos e operacionais dos equipamentos). Essas restrições referem-se tanto ao caso base (sem contingências) quanto aos estados pós-contingência (principalmente casos do tipo “N-1”, ou seja, contingências simples, onde há a falta de apenas um equipamento da rede por vez).

Um programa de FPO otimiza uma certa função objetivo, tais como custos de produção ou perdas, enquanto observa restrições de igualdade (por exemplo, equações do fluxo de potência) e desigualdade (por exemplo, limites físicos e operacionais dos equipamentos). A solução ideal é válida apenas para as condições particulares do sistema e restrições específicas apresentadas para o programa de FPO. O programa de FPORS amplia a capacidade de resolução de problemas do FPO para incluir o efeito de possíveis contingências. Neste contexto, uma contingência é definida como uma mudança na topologia da rede elétrica do caso base, ou seja, uma perda de linha de transmissão, falha de transformador, redução da capacidade de geração de uma unidade geradora, etc.

O programa de FPORS minimiza a função objetivo pré-contingência, observando as restrições do sistema tanto pré-contingência quanto pós-contingência. Se possível, todas as variáveis de controle (tensão do gerador, taps de transformador, dispositivos de controle de reativo, despacho de potência ativa, etc.) são fixadas em uma configuração única que permanece em vigor, tanto antes quanto depois de qualquer uma das contingências. Esta configuração chamada de “modo preventivo” do FPORS, no qual é definido um conjunto de controles que não requer nenhum ajuste pós-contingência para satisfazer qualquer restrição. Caso não exista uma solução preventiva, o FPORS minimiza a quantidade de ações de controle corretivo (ajustes pós-contingência) necessárias para alcançar a viabilidade, o chamado “modo corretivo”. Neste trabalho, o foco estará voltado para o “modo preventivo”.

Em ambas as condições, pré e pós-contingência, o FPORS modela duas restrições não-lineares para cada barra do sistema: as equações de potência ativa e reativa. Assim, para um sistema de 1000 barras, existem 2000 restrições não-lineares para cada condição do sistema. As restrições pós-contingência são da mesma dimensão que as do caso pré-contingência. Se existem $nRest_{FPO}$ restrições em um dado caso base de um problema de FPO, o total de $nRest_{FPORS}$ restrições de um problema de FPORS considerando $nCont$ contingências é dado por:

$$nRest_{FPORS} = (nCont + 1)nRest_{FPO} \quad (4.15)$$

Sabendo que para cada barra do sistema são modeladas duas restrições, é fácil concluir que o número $nRest_{FPO}$ de restrições do caso base é igual ao dobro do número $nBarras$ de

barras do sistema. Assim, o total de $nRest_{FPORS}$ restrições pode ser expresso de maneira alternativa em função do número de barras:

$$nRest_{FPORS} = 2nBarras(nCont + 1) \quad (4.16)$$

Estas propriedades permitem a solução do FPORS apenas com a execução de um programa de análise de contingências (tal como o relatado na subseção 3.3.2) que informe as violações de restrições ocorridas para cada contingência avaliada, além da solução do FPO para o caso base – mesmo quando todas as restrições pós-contingência estão inclusas no problema. Tal como acontece com o FPO, o FPORS pode ser solucionado pelos métodos tradicionais de solução, baseados em programação linear e não-linear, e também por meta-heurísticas evolutivas, que foram as técnicas utilizadas neste trabalho para a solução do problema do FPORS.

4.4.2. FORMULAÇÃO DO PROBLEMA DO FPORS

A meta do FPORS é determinar um ponto de operação viável que minimize uma função objetivo de maneira tal que, mesmo na ocorrência de uma contingência prevista de uma lista pré-estabelecida, o estado pós-contingência continuará viável. O problema do FPORS pode ser compactamente formulado da seguinte forma:

$$\underline{F} = \min_{\underline{x}_0, \dots, \underline{x}_c, \underline{u}_0} \underline{f}(\underline{x}_0, \underline{u}_0) \quad (4.17)$$

Sujeito a:

$$\begin{cases} \underline{g}_k(\underline{x}_k, \underline{u}_0) = \underline{0} \\ \underline{h}_k(\underline{x}_k, \underline{u}_0) \geq \underline{0} \\ k = 0, 1, \dots, c \end{cases} \quad (4.18)$$

Onde:

$k \in \mathbb{N}$ – k -ésimo estado pós-contingência do sistema, onde $k = 0$ corresponde ao caso base e c é o total de contingências consideradas;

$\underline{x}_k \in \mathbb{R}^{2n_{barras}}$ – vetor com as $2n_{barras}$ variáveis de estado para a k -ésima configuração da rede pós-contingência;

$\underline{u}_0 \in \mathbb{R}^n$ – vetor com as n variáveis de controle referentes ao caso base;

$\underline{F}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ – conjunto dos n_{obj} critérios que se deseja otimizar;

$\underline{f}(\underline{x}_0, \underline{u}_0): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ – conjunto das n_{obj} funções objetivo;

$\underline{g}_k(\underline{x}_k, \underline{u}_0): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$ – conjunto das n_{igual} restrições de igualdade para a k -ésima configuração da rede pós-contingência;

$\underline{h}_k(\underline{x}_k, \underline{u}_0): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{desig}}$ – conjunto das n_{desig} restrições de desigualdade para a k -ésima configuração da rede pós-contingência.

As restrições de igualdade referem-se às equações do fluxo de potência para o caso base e para as configurações do sistema pós-contingência, e as restrições de desigualdade referem-se aos limites físicos dos equipamentos (limites de potência ativa e reativa fornecida pelos geradores, de variação de tap dos transformadores, etc.) e aos limites de segurança operacional em regime permanente (limites de fluxo de potência nos ramos e de magnitude de tensão nas barras).

Das equações (4.17) e (4.18), é possível observar que o problema do FPO nada mais é do que um caso particular do FPORS escrito apenas para o caso base ($k = 0$). Portanto, o problema do FPORS possui uma dimensão $c+1$ vezes maior do que o problema do FPO, tal como foi mostrado na equação (4.15).

Também é possível observar que o FPORS atua apenas nas variáveis de controle do caso base (\underline{u}_0), enquanto tenta satisfazer as restrições tanto do caso base quanto das configurações pós-contingência do sistema. De fato, no FPORS não é realizada a reprogramação das variáveis de controle nos estados pós-contingência, exceto em casos especiais em que há resposta automática do sistema à ocorrência de contingências (potência ativa dos geradores participando do controle de frequência, transformadores realizando controle de tensão nas barras, etc.), entretanto essas situações não fazem parte do escopo do presente trabalho, e não foram incluídas na formulação do problema.

Portanto, o objetivo do FPORS é encontrar um conjunto de controles ótimo para o caso base enquanto atende às restrições do sistema tanto para o caso base quanto para as novas topologias pós-contingências do sistema estudado.

5. OTIMIZAÇÃO MULTIOBJETIVO

5.1. INTRODUÇÃO

Um problema de otimização multiobjetivo é definido por um conjunto de funções objetivo a serem otimizadas (maximizadas ou minimizadas) simultaneamente, de modo a contornar os possíveis conflitos apresentados pelos critérios através de uma solução considerada satisfatória para todos os pontos de vista. Além disso, possui restrições que devem ser satisfeitas para que seja encontrada uma solução factível para o problema. Seu enunciado foi definido por Deb em [6].

$$\underline{F} = \min/\max_{\underline{x}} \underline{f}(\underline{x}) \quad (4.1)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{h}(\underline{x}) \geq \underline{0} \\ \underline{w}^{min} \leq \underline{x} \leq \underline{w}^{max} \end{cases} \quad (4.2)$$

Onde:

$\underline{x} \in \mathbb{R}^n$ - vetor-solução com as n variáveis a serem especificadas;

$\underline{F}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto dos n_{obj} critérios que se deseja otimizar;

$\underline{f}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto das n_{obj} funções objetivo;

$\underline{g}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{igual}}$ - conjunto das n_{igual} restrições de igualdade;

$\underline{h}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^{n_{desig}}$ - conjunto das n_{desig} restrições de desigualdade;

$\underline{w}^{lim} \in \mathbb{R}^n$ - vetor contendo os limites operativos das n variáveis especificadas.

Do enunciado acima, observa-se que os limites superior e inferior de cada variável do vetor-solução \underline{x} correspondem ao espaço de variáveis de decisão ou espaço de decisão (S_{dec}), ou seja, os valores possíveis que cada variável de \underline{x} pode assumir. Também é possível verificar que uma solução factível deve atender as $n_{igual} + n_{desig}$ funções de restrição mais os $2n$ limites operativos (n limites máximos + n limites mínimos) existentes no problema, caso contrário a solução não será factível. O conjunto de todas as soluções factíveis formam a região factível (S_{fact}).

Cada função objetivo contida em $\underline{f}(\underline{x}) = [f_1(\underline{x}), f_2(\underline{x}), \dots, f_{n_{obj}}(\underline{x})]^T$ pode ser maximizada ou minimizada, entretanto a manipulação dos algoritmos de otimização exige que

todas essas funções sejam convertidas para apenas maximização ou minimização. O vetor de funções objetivo $\underline{f}(\underline{x})$ compõe um espaço multidimensional chamado *espaço de objetivos* (S_{obj}). Isso significa que, para cada solução \underline{x} no espaço de decisão (S_{dec}), existe um $\underline{f}(\underline{x})$ no espaço de objetivos (S_{obj}). Trata-se de uma diferença fundamental em relação à otimização mono-objetivo, que possui espaço de objetivos unidimensional. Assim, o mapeamento ocorre entre um vetor \underline{x} (de dimensão n) e um vetor $\underline{f}(\underline{x})$ (de dimensão n_{obj}).

5.2. SOLUÇÕES PARETO-ÓTIMAS

5.2.1. INTRODUÇÃO

Geralmente, as funções objetivo a serem aprimoradas por algoritmos de otimização são conflitantes entre si. Isso significa que não é possível melhorar o valor de uma função f_1 sem piorar o valor de outra função f_2 , para uma mesma solução. Um exemplo prático pôde ser observado no capítulo 3 desta mesma dissertação, onde ficou claro que economia e segurança são objetivos conflitantes no que tange à operação de sistemas elétricos de potência, ou seja, uma opção mais barata de despacho das unidades geradoras costuma resultar em violações de limites operativos dos equipamentos da rede, enquanto que um ponto de operação seguro resulta num despacho mais caro. Partindo da premissa de que ambos os objetivos (economia e segurança) possuem a mesma importância (o que nem sempre é verdade – a tendência é que a segurança seja priorizada), não há como afirmar que certo aumento de segurança compense determinado aumento de custos de operação.

Em um problema de otimização multiobjetivo, é empregado o conceito de dominância de Pareto para comparar duas soluções factíveis do problema. Dadas duas soluções \underline{x} e \underline{y} , diz-se que \underline{x} domina \underline{y} (denotado como $\underline{x} \preceq \underline{y}$) caso as seguintes condições sejam satisfeitas:

- Para nenhum objetivo é verificado que a avaliação de \underline{x} seja pior que a avaliação de \underline{y} ;
- Para pelo menos um objetivo a avaliação de \underline{x} é superior à avaliação de \underline{y} .

Assim, conclui-se que há um conjunto de soluções que possuem vantagem em custo, mas que são piores em segurança e vice-versa. Ou seja, existe um conjunto de alternativas ótimas que são não-dominadas entre si nos objetivos economia e segurança. Num problema de otimização multiobjetivo, o conjunto de soluções não-dominadas é chamado de conjunto

Pareto-ótimo e representa as soluções ótimas do problema. A fronteira de Pareto é o conjunto de valores das funções objetivo das soluções conjunto Pareto-ótimo.

5.2.2. DOMINÂNCIA DE PARETO

Esta seção é destinada a formalizar conceito de dominância de Pareto, conforme descrito por Deb em [6], e também apresentar as suas propriedades.

- *Definição 1:* uma solução \underline{x} domina uma solução \underline{y} ($\underline{x} \preceq \underline{y}$) se as seguintes condições abaixo forem satisfeitas.
 - A solução \underline{x} não é pior que \underline{y} em todos os objetivos, ou seja, $f_i(\underline{x}) \leq f_i(\underline{y})$ para todo $i = 1, 2, \dots, n_{obj}$;
 - A solução \underline{x} é estritamente melhor que \underline{y} em pelo menos um objetivo, ou seja, $f_i(\underline{x}) < f_i(\underline{y})$ para pelo menos um valor de i .

Na definição 1, convencionou-se que todas as funções objetivo devem ser minimizadas. Se todas as suas condições forem satisfeitas, é possível dizer que:

- \underline{y} é dominado por \underline{x} ;
- \underline{x} é não-dominado por \underline{y} ;
- \underline{x} não é inferior a \underline{y} .

A relação de dominância possui as seguintes propriedades:

- *Não-reflexiva:* conforme a definição 1, uma solução não pode ser dominada por si mesma;
- *Não-simétrica:* $\underline{x} \preceq \underline{y}$ não implica que $\underline{y} \preceq \underline{x}$;
- *Transitiva:* se $\underline{x} \preceq \underline{y}$ e $\underline{y} \preceq \underline{z}$, então $\underline{x} \preceq \underline{z}$.

Essas propriedades caracterizam a relação de dominância como uma relação de ordem parcial estrita [6]. Um conjunto de soluções para um problema de otimização multiobjetivo pode ser dividido em conjuntos de soluções dominadas e não-dominadas empregando o operador de dominância.

- 1) *Definição 2:* dado um conjunto de soluções P , o conjunto não-dominado P' é descrito pela equação abaixo.

$$P' = \{\underline{x} \in P \mid \nexists \underline{y}: \underline{y} \preceq \underline{x}\} \quad (4.3)$$

Quando o conjunto de soluções P corresponde ao conjunto de soluções factíveis ($P = S_{fact}$), o conjunto não-dominado P' é chamado de conjunto Pareto-ótimo. Esses conjuntos podem ser formados tanto por regiões contínuas quanto pela união de regiões descontínuas do espaço de objetivos.

Nos problemas de otimização multiobjetivo também existe o conceito de otimalidade local. Um conjunto Pareto-ótimo local é definido como abaixo:

- 2) *Definição 3:* dados P (conjunto de soluções) e ϵ (número positivo arbitrariamente pequeno), o conjunto Pareto-ótimo local P'' é formado segundo a equação abaixo.

$$P'' = \{ \underline{x} \in P \mid \nexists \underline{y} : \underline{y} \preceq \underline{x} \wedge \|\underline{y} - \underline{x}\|_{\infty} \leq \epsilon \} \quad (4.4)$$

Por fim, chega-se à definição de fronteira de Pareto:

- 3) *Definição 4:* dado um problema de otimização multiobjetivo com o conjunto de funções objetivo $\underline{f}(\underline{x})$ e cujo conjunto Pareto-ótimo é P' , a fronteira de Pareto FP é formada por:

$$FP = \{ \underline{f}(\underline{x}) \mid \underline{x} \in P' \} \quad (4.5)$$

Da mesma maneira que existe o conjunto Pareto-ótimo, podem existir fronteiras de Pareto locais.

5.3. METAS EM OTIMIZAÇÃO MULTIOBJETIVO

Se a informação adicional sobre a importância relativa dos objetivos é desconhecida, todas as soluções Pareto-ótimas são consideradas igualmente importantes. De acordo com Deb et al. em [6] e [105], existem três importantes metas em otimização multiobjetivo:

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

Enquanto a primeira meta é comum a qualquer processo de otimização, a segunda meta é específica para a otimização multiobjetivo. É necessário assegurar a maior cobertura possível da fronteira. Como em um problema de otimização multiobjetivo trabalha-se tanto com o espaço de decisões quanto com o espaço de objetivos, também é desejável que as soluções estejam adequadamente distribuídas em ambos os espaços. Geralmente a diversidade

de um desses espaços garante também a diversidade do outro, entretanto para alguns problemas isso não acontece. Uma vez que encontrar um conjunto de soluções uniformemente distribuído é uma tarefa que pode exigir alto esforço computacional [80], é necessário que tais soluções sejam obtidas eficientemente.

5.4. DIFERENÇAS PARA A OTIMIZAÇÃO MONO-OBJETIVO

Em [6] Deb lista três importantes características que diferenciam a otimização multiobjetivo da mono-objetivo:

- 1) Em problemas mono-objetivos a meta é encontrar uma solução ótima global, entretanto se a função objetivo desses problemas for multimodal poderá existir mais de um ótimo global. Nesse caso, todos os ótimos são equivalentes. Já em problemas de otimização multiobjetivo determinar o conjunto de soluções da fronteira de Pareto é tão importante quanto preservar a diversidade neste conjunto, ou seja, um algoritmo de otimização multiobjetivo eficiente deve considerar ambos os aspectos;
- 2) Na otimização multiobjetivo trabalha-se com dois espaços de busca (de decisões e de objetivos), enquanto na mono-objetivo trabalha-se apenas com o espaço de decisões, uma vez que buscam apenas uma solução no espaço de objetivos. Manter a diversidade em ambos os espaços complica ainda mais o problema, dado que a proximidade de duas soluções no espaço de variáveis não implica em proximidade no espaço de objetivos;
- 3) Os métodos tradicionais de otimização multiobjetivo reduzem o conjunto de funções objetivo a uma função simples que pondera cada objetivo. Estes métodos também podem tratar cada objetivo separadamente, otimizando um objetivo e utilizando os demais como restrições. Portanto um problema de otimização multiobjetivo pode ser convertido em mono-objetivo mediante algumas técnicas.

5.5. TÉCNICAS TRADICIONAIS DE OTIMIZAÇÃO MONO-OBJETIVO

5.5.1. SOMATÓRIO DE PESOS

O método do somatório de pesos consiste na soma ponderada dos custos de cada função objetivo [6]. Os pesos são fornecidos como parâmetros e são atribuídos de acordo com a relevância de cada objetivo. É necessário realizar a normalização de cada função objetivo,

uma vez que os diferentes objetivos podem ter ordens de grandeza diversas. Com os objetivos normalizados, formula-se uma função que soma os objetivos normalizados multiplicados pelos seus respectivos pesos, sendo descrita como abaixo:

$$F = \min_{\underline{x}} \sum_{m=1}^{n_{obj}} \omega_m f_m(\underline{x}) \quad (4.6)$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{h}(\underline{x}) \geq \underline{0} \\ \underline{w}^{min} \leq \underline{x} \leq \underline{w}^{max} \end{cases} \quad (4.7)$$

Onde:

$\underline{\omega}: \mathbb{R}^n \rightarrow [0,1]^{n_{obj}}$ - vetor contendo os pesos de cada função objetivo.

É possível demonstrar que a solução do problema descrito pelas equações (4.6) e (4.7) se os pesos são positivos para todos os objetivos. Também é possível garantir que se um problema de otimização multiobjetivo é convexo [6], qualquer solução Pareto-ótima pode ser encontrada utilizando o método de somatório dos pesos, empregando diferentes combinações de valores de $\underline{\omega}$.

Dado um vetor de pesos $\underline{\omega}$ é possível plotar o contorno de F no espaço de objetivos. Uma vez que F é uma combinação linear dos objetivos, obtém-se uma linha reta, portanto encontrar o mínimo valor da equação (4.6) equivale a achar uma linha de contorno com um valor mínimo para F .

Embora este método seja simples, são necessárias várias iterações para atingir toda a fronteira de Pareto. No caso de um problema de otimização multiobjetivo não-convexo, este método não é capaz de determinar todas as soluções. Além disso, a aplicação de vetores de pesos uniformemente distribuídos não garante que seja obtido um conjunto de soluções uniformemente distribuídas.

5.5.2. MÉTODO DE RESTRICÇÕES ϵ

Em [106] Haimes et al. sugeriram uma reformulação dos problemas de otimização multiobjetivo, considerando qualquer objetivo e mantendo restritos os demais objetivos com valores definidos pelo usuário. A formulação é descrita a seguir:

$$F = \min_{\underline{x}} f(\underline{x}) \quad (4.8)$$

Sujeito a:

$$\begin{cases} f'(\underline{x}) \leq \varepsilon \\ \underline{g}(\underline{x}) = \underline{0} \\ \underline{h}(\underline{x}) \geq \underline{0} \\ \underline{w}^{min} \leq \underline{x} \leq \underline{w}^{max} \end{cases} \quad (4.9)$$

Onde:

$\varepsilon \in \mathbb{R}$ - limite máximo definido pelo usuário para o valor de f' .

Por exemplo, para um problema de otimização multiobjetivo não convexo de dois objetivos, f_1 e f_2 , escolhe-se f_2 para ser minimizado e mantém-se f_1 com a restrição $f_1 \leq \varepsilon_1$. Considerando um determinado espaço de objetivos e vários valores para ε_1 , o mínimo valor para f_2 dependerá do ε_1 escolhido, portanto empregando-se diferentes valores de ε_1 encontram-se diferentes soluções Pareto-ótimas.

Desta forma, o método de restrições ε pode ser utilizado para gerar as soluções Pareto-ótimas independentemente do espaço de objetivos ser convexo, não convexo ou discreto [6]. Este método necessita que a escolha do vetor ε esteja em uma região factível para cada objetivo. Assim como no somatório de pesos, são necessárias várias iterações e o uso de uma distribuição uniforme de ε não garante um conjunto de soluções uniformemente distribuídas.

5.5.3. PROGRAMAÇÃO POR METAS

Esta técnica tenta encontrar soluções que possam atingir uma meta pré-determinada para uma ou mais funções objetivo. Caso não exista uma solução factível que alcance as metas para todos os objetivos, ela minimiza os desvios em relação às metas.

Seja um conjunto de funções $\underline{f}(\underline{x})$ para ser minimizada dentro do espaço de busca S_{fact} . Para cada objetivo é escolhido pelo um valor, inserido no vetor de metas \underline{z} . Então, o problema é formulado para encontrar uma solução cujo valor de \underline{f} seja igual a \underline{z} .

$$\underline{F} = \text{meta} \left[\underline{f}(\underline{x}) = \underline{z} \right], \quad \underline{x} \in S_{fact} \quad (4.10)$$

Para resolver um problema de programação por metas, primeiramente cada meta é convertida em uma restrição de igualdade. Então busca-se minimizar todos os desvios em

relação às metas. Existem várias formas de trabalhar com esse tipo de problema, como veremos a seguir:

- *Programação por metas com pesos*: para um problema com n_{obj} objetivos, formula-se uma função somando os desvios para cada um dos n_{obj} objetivos, tal como descrito abaixo.

$$F = \min_{\underline{x}} \sum_{m=1}^{n_{obj}} (\alpha_m \phi_m + \beta_m \eta_m) \quad (4.11)$$

Sujeito a:

$$\begin{cases} \underline{f}(\underline{x}) - \underline{\phi} + \underline{\eta} = \underline{z} \\ \underline{x} \in S_{fact} \\ \underline{\phi}, \underline{\eta} \geq \underline{0} \end{cases} \quad (4.12)$$

Onde:

$\underline{\alpha}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto de pesos dos desvios positivos;

$\underline{\beta}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto de pesos dos desvios negativos;

$\underline{\phi}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto dos desvios positivos;

$\underline{\eta}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto dos desvios negativos;

$\underline{z}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - conjunto das metas para o conjunto de funções objetivo $\underline{f}(\underline{x})$.

As soluções obtidas por este método dependem consideravelmente da escolha dos valores para $\underline{\alpha}$ e $\underline{\beta}$. Além disso, de acordo com Deb [27], este método possui dificuldades similares ao método do somatório de pesos;

- *Programação por metas lexicográficas*: aqui as metas são organizadas em níveis de prioridade, resolvendo-se sequencialmente vários problemas de programação por metas. Inicialmente, as metas de primeira ordem de prioridade são consideradas na formulação do problema. Caso existam múltiplas soluções, as metas de segunda ordem de prioridade são consideradas, formulando outro problema para minimizar apenas os desvios para as metas de segunda ordem. O processo continua com os demais níveis de prioridade até que seja encontrada uma única solução;
- *Programação de metas min-max*: neste método é minimizado o máximo desvio em relação às metas. É adotada a formulação abaixo.

$$\underline{\Delta} = \min_{\underline{x}} \underline{\delta} \quad (4.13)$$

Sujeito a:

$$\begin{cases} \underline{\alpha} \otimes \underline{\phi} + \underline{\beta} \otimes \underline{\eta} \leq \underline{\delta} \\ \underline{f}(\underline{x}) - \underline{\phi} + \underline{\eta} = \underline{z} \\ \underline{x} \in S_{fact} \\ \underline{\phi}, \underline{\eta} \geq \underline{0} \end{cases} \quad (4.14)$$

Onde:

$\underline{\delta}: \mathbb{R}^n \rightarrow \mathbb{R}^{n_{obj}}$ - desvio máximo para qualquer meta.

Este método requer também a escolha dos pesos $\underline{\alpha}$ e $\underline{\beta}$.

5.5.4. VANTAGENS E DESVANTAGENS DAS TÉCNICAS TRADICIONAIS

A principal vantagem das técnicas tradicionais é que possuem provas de convergência que garantem encontrar pelo menos uma solução Pareto-ótima [6], [107]. Todas essas técnicas reduzem o problema de otimização multiobjetivo em mono-objetivo, cada uma de uma maneira diferente e introduzindo parâmetros adicionais. A escolha desses parâmetros afeta diretamente os resultados obtidos, assim cada vez que os parâmetros são modificados é necessário resolver um novo problema de otimização simples. Portanto, para encontrar cada solução Pareto-ótima, deve-se resolver um problema de otimização mono-objetivo.

Alguns métodos não garantem soluções ao longo de toda a fronteira de Pareto. Se a função objetivo não for convexa, o método de somatório de pesos não encontra certas soluções, independentemente dos pesos escolhidos.

Finalmente, todas as técnicas precisam de parâmetros adicionais, tais como pesos, metas e vetores de restrição. Além disso, a distribuição uniforme desses parâmetros não garante a diversidade das soluções Pareto-ótimas. Entretanto, existem técnicas alternativas para tratar dos problemas de otimização multiobjetivo, dentre as quais se destacam os Algoritmos Evolutivos (AE) [108], que apresentam vários aspectos positivos que motivam a sua aplicação, conforme será visto no próximo capítulo.

6. ALGORITMOS EVOLUTIVOS

6.1. INTRODUÇÃO

Os Algoritmos Evolutivos são inspirados na teoria de evolução proposta pelo naturalista britânico Charles Robert Darwin, quando da sua viagem de expedição pela costa sul-americana, mais precisamente na ilha de Galápagos, no litoral do Equador. Construída após 5 anos de expedição (eram previstos inicialmente dois anos de viagem), a Teoria da Seleção Natural foi apresentada no livro “*A Origem das Espécies*” de 1859. Sua proposta é de que as características benéficas de um indivíduo tornam-se mais comuns em elementos da mesma espécie com o passar das gerações de uma população com reprodução sexuada (onde há cruzamento), e as características desfavoráveis tornam-se cada vez mais raras, até desaparecerem por completo.

Esta seleção, por sua vez, atua no fenótipo do indivíduo, que nada mais são do que suas características observáveis. Assim, quem possui um fenótipo favorável tende a sobreviver e reproduzir mais do que os organismos que possuem fenótipos desfavoráveis. Sendo o fenótipo uma característica genética do indivíduo, diz-se que cada fenótipo tem um genótipo associado, ou seja, as características de um organismo estão codificadas como uma cadeia do que mais tarde seria chamado de genes.

Porém, para dar sustentação à Teoria de Seleção Natural, faltava explicar como uma característica individual pode ser transmitida ao longo das gerações de um organismo. Isso aconteceu através dos estudos de Gregor Johann Mendel, em 1865, no qual ele observa o processo de cruzamento de feijões, ervilhas e abelhas e então formula as primeiras leis da hereditariedade, conhecidas como Leis de Mendel, que o consagrou como o pai da Genética. Basicamente elas definem como hereditariedade um conjunto de processos biológicos e químicos que asseguram que cada ser vivo receba e transmita suas informações genéticas através dos seus genes através da reprodução sexuada.

Um gene é definido como uma sequência de ácidos nucleicos que corresponde a uma das informações presentes no fenótipo de um indivíduo. Um conjunto de genes é chamado de cromossomo, o que significa que um cromossomo contém todas as informações do fenótipo de seu indivíduo. Dessa forma aparentemente simples, a natureza consegue soluções engenhosas para problemas altamente complexos, como por exemplo, o padrão de cores da borboleta-coruja, que torna a parte externa de suas asas parecida com a face de uma coruja, espantando possíveis predadores como pássaros, ratos e etc., que por sua vez são presas das

corujas, tornando essa espécie de borboleta mais apta à sobrevivência do que suas congêneres com desenhos diferentes nas asas.

Inspirado nessas soluções engenhosas da natureza surgia entre as décadas de 1960 e 1970 um ramo da computação que tinha o objetivo de simular esses processos naturais para resolver problemas específicos: os Algoritmos Evolutivos. Trata-se de um nicho de heurísticas de otimização inspiradas nos mecanismos evolutivos encontrados na natureza, como auto-organização e comportamento adaptativo. Existem técnicas de otimização baseadas em enxame de abelhas, colônia de formigas, evolução das espécies, dentre outros. Surgiram em meados das décadas de 1960 e 1970 com a computação evolucionista, quando pesquisadores dos EUA e Europa convergiram para o que Rosenberg chamou em 1967 de Algoritmos Evolutivos (AE) [38].

Os AE usam modelos computacionais probabilísticos para copiar os processos utilizados por Darwin em suas pesquisas, para resolver problemas encontrando soluções ótimas e subótimas. Em todos os modelos computacionais desenvolvidos, os Algoritmos Evolucionários simulam a evolução das espécies através dos métodos de seleção, reprodução e mutação dos indivíduos, fazendo com que o desempenho médio das populações (conjunto de soluções candidatas) no problema proposto melhore com o passar das gerações (iterações).

6.2. OPERADORES GENÉTICOS

6.2.1. INTRODUÇÃO

Os operadores genéticos são os responsáveis por transformar a população de soluções candidatas dos AEs através de sucessivas gerações, possibilitando a sua evolução e estendendo a busca até atingir um resultado satisfatório. Trata-se de um processo indispensável para que a população se diversifique e mantenha características de adaptação adquiridas durante as etapas anteriores do processo. Para a perfeita compreensão do processo, é necessário conhecer três definições:

- 1) *População*: conjunto de possíveis soluções para o problema descrito, gerado *a priori* de forma aleatória e *a posteriori* através de recombinações da população inicial. Cada uma dessas possíveis soluções é um *indivíduo*, que carrega consigo as informações que o tornam mais ou menos aptos em relação ao critério avaliado. Essas informações, por sua vez, estão impressas em seu “código genético”, que é matematicamente representado como um vetor numérico;

- 2) *Indivíduo*: também chamado de cromossomo, trata-se de uma codificação de uma possível solução do problema proposto. Este cromossomo, por sua vez, é dividido em várias partes, chamadas de *genes*, que codificam uma característica do indivíduo. Cada gene corresponde a um escalar que compõe o vetor-cromossomo;
- 3) *Geração*: é o nome conferido a cada iteração do processo de execução de um AE. Após várias gerações, existe uma grande probabilidade de que a população tenha aumentado a sua qualidade média, isto é, seja composta por indivíduos mais bem adaptados ao ambiente em questão – o problema.

As melhores soluções contam com uma maior probabilidade de “sobreviver” e, através de operadores genéticos, gerarem outras soluções (ou “descendentes”) de boa qualidade. Da combinação de bons indivíduos podem surgir outros ainda melhores, que tenham herdado as boas características daqueles que lhes deram origem.

6.2.2. SELEÇÃO

A seleção é a responsável pela perpetuação de boas características na espécie. É no estágio de seleção que os indivíduos são escolhidos para posterior cruzamento, formando o *matting pool*. Nesse ponto, faz-se uso do grau de adequação (*fitness*) de cada um, sendo efetuado um sorteio onde os mais aptos têm maiores probabilidades de reprodução. Este grau é calculado a partir da função de avaliação de cada indivíduo, e determina o quão apto ele está para a reprodução em relação à população que ele pertence.

O mecanismo de seleção pode ainda ser aprimorado através do elitismo, onde dentre os indivíduos de uma população, escolhe-se o melhor deles para sobreviver e compor a próxima geração, evitando a perda da informação devido à ação dos operadores genéticos. O procedimento é simples: antes da execução dos demais operadores genéticos (cruzamento e mutação), os melhores indivíduos são copiados para a próxima população. Costuma aumentar rapidamente o desempenho do AE, pois previne a perda da melhor solução encontrada até o momento.

6.2.3. CRUZAMENTO

Uma vez selecionados estes indivíduos, estes passam com uma probabilidade pré-estabelecida pelo processo de cruzamento (*crossover*), onde uma parte dos genes dos pais é combinada para a geração dos filhos. Espera-se obviamente uma evolução da prole em relação aos pais, devido à combinação das boas características tanto do pai quanto da mãe.

Porém, pode haver piora de alguns membros resultantes de crossover, que neste caso são descartados do *matting pool* seguinte. O cruzamento por vezes pode ser complicado, e excessivamente dependente da codificação dos cromossomos. Cruzamentos específicos feitos para problemas específicos podem melhorar o desempenho do AE.

6.2.4. MUTAÇÃO

O operador de mutação é responsável pelo aumento da diversidade da população através da alteração aleatória de um ou mais genes com uma probabilidade denominada taxa de mutação. A importância desse operador está na prevenção da convergência prematura do AE, ou seja, evita que as soluções geradas caiam em um ponto de ótimo local, permitindo a exploração de regiões mais afastadas donde a maioria da população se encontra.

6.3. ALGORITMOS EVOLUTIVOS PARA OTIMIZAÇÃO MULTIOBJETIVO

Os Algoritmos Evolutivos têm sido largamente explorados em problemas de otimização. Uma das características mais importantes dos AEs é que possibilitam encontrar soluções ótimas ou adequadas para um problema complexo sem usar informação adicional, como cálculo de derivadas de funções [109]. Como será visto a seguir, outro grande diferencial dos AEs tem sido a solução de problemas de otimização multiobjetivo.

A possibilidade de se trabalhar com várias soluções simultaneamente, não precisar de informações adicionais e poder escapar de ótimos locais fazem dos AEs uma técnica promissora para a resolução de problemas de otimização multiobjetivo. A primeira aplicação de AEs na resolução deste tipo de problema foi proposta por Schaffer em [110], sendo o modelo sugerido chamado de VEGA (do inglês *Vector Evaluated Genetic Algorithm* – Algoritmo Genético de Avaliação de Vetores). Schaffer realizou uma modificação no Algoritmo Genético (AG) convencional para avaliar cada objetivo separadamente. Entretanto, o método desenvolvido não permitia obter uma diversidade adequada nas soluções ao longo da fronteira de Pareto.

Goldberg propôs em [109] várias abordagens para estender as aplicações de AGs para problemas de otimização multiobjetivo. Uma das propostas utiliza um procedimento para ordenação de soluções baseado no conceito de dominância: neste método, o valor de aptidão para uma solução \underline{x} é proporcional ao número de soluções que \underline{x} domina. Assim, as soluções não-dominadas são enfatizadas, obtendo maior quantidade de cópias na lista de reprodução.

Para manter a diversidade das soluções, Goldberg sugeriu em [109] o emprego de um método de compartilhamento que permite levar em conta a densidade de soluções em uma vizinhança do espaço de busca. Assim, soluções que estejam mais bem espalhadas na fronteira de Pareto possuem um melhor valor de compartilhamento. Baseados nessas ideias iniciais foram propostos uma série de modelos de Algoritmos Evolutivos Multiobjetivos (AEMO).

A diferença fundamental dos AEMOs em relação aos AEs tradicionais reside no operador de seleção, uma vez que a comparação entre duas soluções é efetuada com base no conceito de dominância de Pareto. Em alguns métodos, o valor de aptidão é proporcional à dominância da solução, já outros métodos utilizam apenas a dominância de Pareto e não calculam o valor da aptidão com base no nível de dominância. A aplicação de AEMOs em problemas de otimização multiobjetivo apresentam três grandes vantagens em relação às técnicas tradicionais [111]:

- Não introduzem parâmetros adicionais ao problema;
- Trabalham diretamente com várias funções usando o conceito de dominância de Pareto;
- Um conjunto diversificado de soluções pode ser encontrado em apenas uma execução de um AEMO.

Os modelos de AEMOs são classificados por Deb em [6] em dois tipos:

- *Não-elitistas*: são os modelos que não utilizam nenhuma forma de elitismo nas suas iterações;
- *Elitistas*: são os modelos que empregam alguma forma de elitismo. Alguns modelos, como o SPEA (do inglês *Strength Pareto Evolutionary Algorithm* – Algoritmo Evolutivo de Força Pareto), proposto por Zitzler et al. em [112], e o PESA (do inglês *Pareto Envelope-based Selection Algorithm* – Algoritmo de Seleção baseado em Invólucro de Pareto), proposto por Corne et al. em [113], utilizam uma população externa onde são armazenadas as soluções não-dominadas encontradas até o momento. Outros métodos, como o NSGA-II (do inglês *Elitist Non-dominated Sorting Genetic Algorithm* – Algoritmo Genético de Classificação Elitista por Não-dominância), combinam a população atual com a população anterior para preservar as melhores soluções de ambas.

O estudo conduzido por Zitzler et al. em [114] concluiu que o elitismo melhora as soluções encontradas por um modelo de AEMO, assim a partir desse trabalho os novos modelos surgidos passaram a incorporar alguma estratégia de elitismo.

6.4. TÉCNICAS DE OTIMIZAÇÃO MULTIOBJETIVO

6.4.1. NSGA-II

O algoritmo NSGA-II é uma adaptação do algoritmo genético (AG) clássico para a otimização multiobjetivo através da relação de dominância entre as soluções encontradas. O AG clássico foi introduzido por John Holland em 1975 [115] e consiste na combinação da lei da sobrevivência do mais apto com uma estrutura de troca de informações em uma população de criaturas artificiais, assemelhando-se a amostras do espaço de busca do problema. Durante as últimas duas décadas tem sido aplicado com sucesso na solução de diversos problemas complexos de otimização em ciência, engenharia e negócios [116].

Uma versão multiobjetivo do AG é o NSGA-II, desenvolvido por Kalyanmoy Deb et al. em 2000 [117] e considerado um dos mais eficazes métodos para resolução de problemas multiobjetivos [116], que consiste na mesma estrutura do AG clássico, diferenciando-se apenas no método com o qual os indivíduos são selecionados (operador de seleção). Nesta etapa é implementada uma ordenação elitista por dominância (*Pareto ranking*), que consiste em classificar as soluções de um conjunto M em diversas fronteiras $FP_1, FP_2, \dots, FP_{n_{front}}$, de acordo com o grau de dominância das soluções. Assim, a fronteira FP_1 contém todas as soluções não-dominadas de M , enquanto FP_2 possui as soluções não-dominadas do conjunto $M - FP_1$ e FP_3 contém as soluções de $M - (FP_1 \cup FP_2)$, e assim sucessivamente.

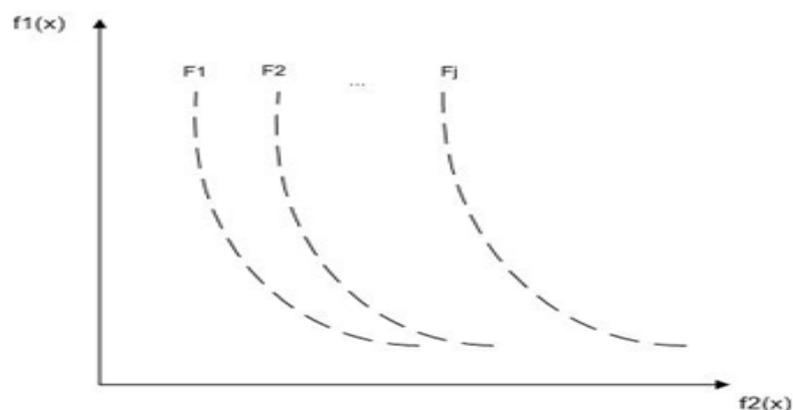


Figura 4 – Camadas ilustrando as fronteiras

O algoritmo NSGA-II trabalha com duas populações, denotadas como P e Q , cada uma com tamanho n_{ind} . As populações P e Q em cada geração $t = 1, 2, \dots, n_{ger}$ são denominadas como P_t e Q_t , respectivamente. Na primeira geração, os indivíduos iniciais de P_1 geram as soluções em Q_1 pela aplicação dos operadores genéticos. A seguir, é estabelecido um processo competitivo para preencher n_{ind} vagas na população P_{t+1} entre $2n_{ind}$ contidos em $R_t = P_t \cup Q_t$. Esta operação é realizada usando ordenação por dominância em R_t , encaminhando as soluções não-dominadas contidas nas fronteiras diretamente para a próxima geração (elitismo).

Sendo um indivíduo i , o *ranking* r_i é o número de soluções que dominam i na geração t . Assim, todas as soluções que possuem $r_i = 0$ são armazenadas na fronteira FP_1 ; $r_i = 1$ em FP_2 e assim por diante, de modo que ao final da iteração todos os indivíduos estejam classificados em uma fronteira.

Para garantir a diversidade na fronteira calculada, o NSGA-II estima a quantidade de soluções no entorno de um indivíduo através do cálculo da média da distância das duas soluções adjacentes a cada indivíduo para todos os objetivos. Esse valor é denominado como *distância de multidão* ou *crowding distance*.

$$d_i = \sum_{m=1}^{n_{obj}} \left[\frac{f_m^{suc(i)} - f_m^{pred(i)}}{f_m^{max} - f_m^{min}} \right] \quad (5.1)$$

Onde $f_m^{suc(i)}$ e $f_m^{pred(i)}$ são respectivamente os valores do sucessor e predecessor de i , enquanto f_m^{max} e f_m^{min} são os valores máximo e mínimo da função objetivo m . Portanto, quanto maior for o valor de d_i , mais distantes estão os pontos, indicando a necessidade de gerar mais soluções nessa região.

Calculados *ranking* e *crowding distance*, é realizado um reordenamento da população da seguinte forma: sendo duas soluções distintas i e j , i domina j se $(r_i < r_j)$, ou então se $[(r_i = r_j) \text{ e } (d_i > d_j)]$. Então a nova população é composta pelos n_{ind} primeiros indivíduos selecionados, formando o conjunto P_{t+1} , enquanto os n_{ind} indivíduos seguintes, pertencentes ao conjunto Q_{t+1} , são resultado da ação dos operadores genéticos sobre P_{t+1} .

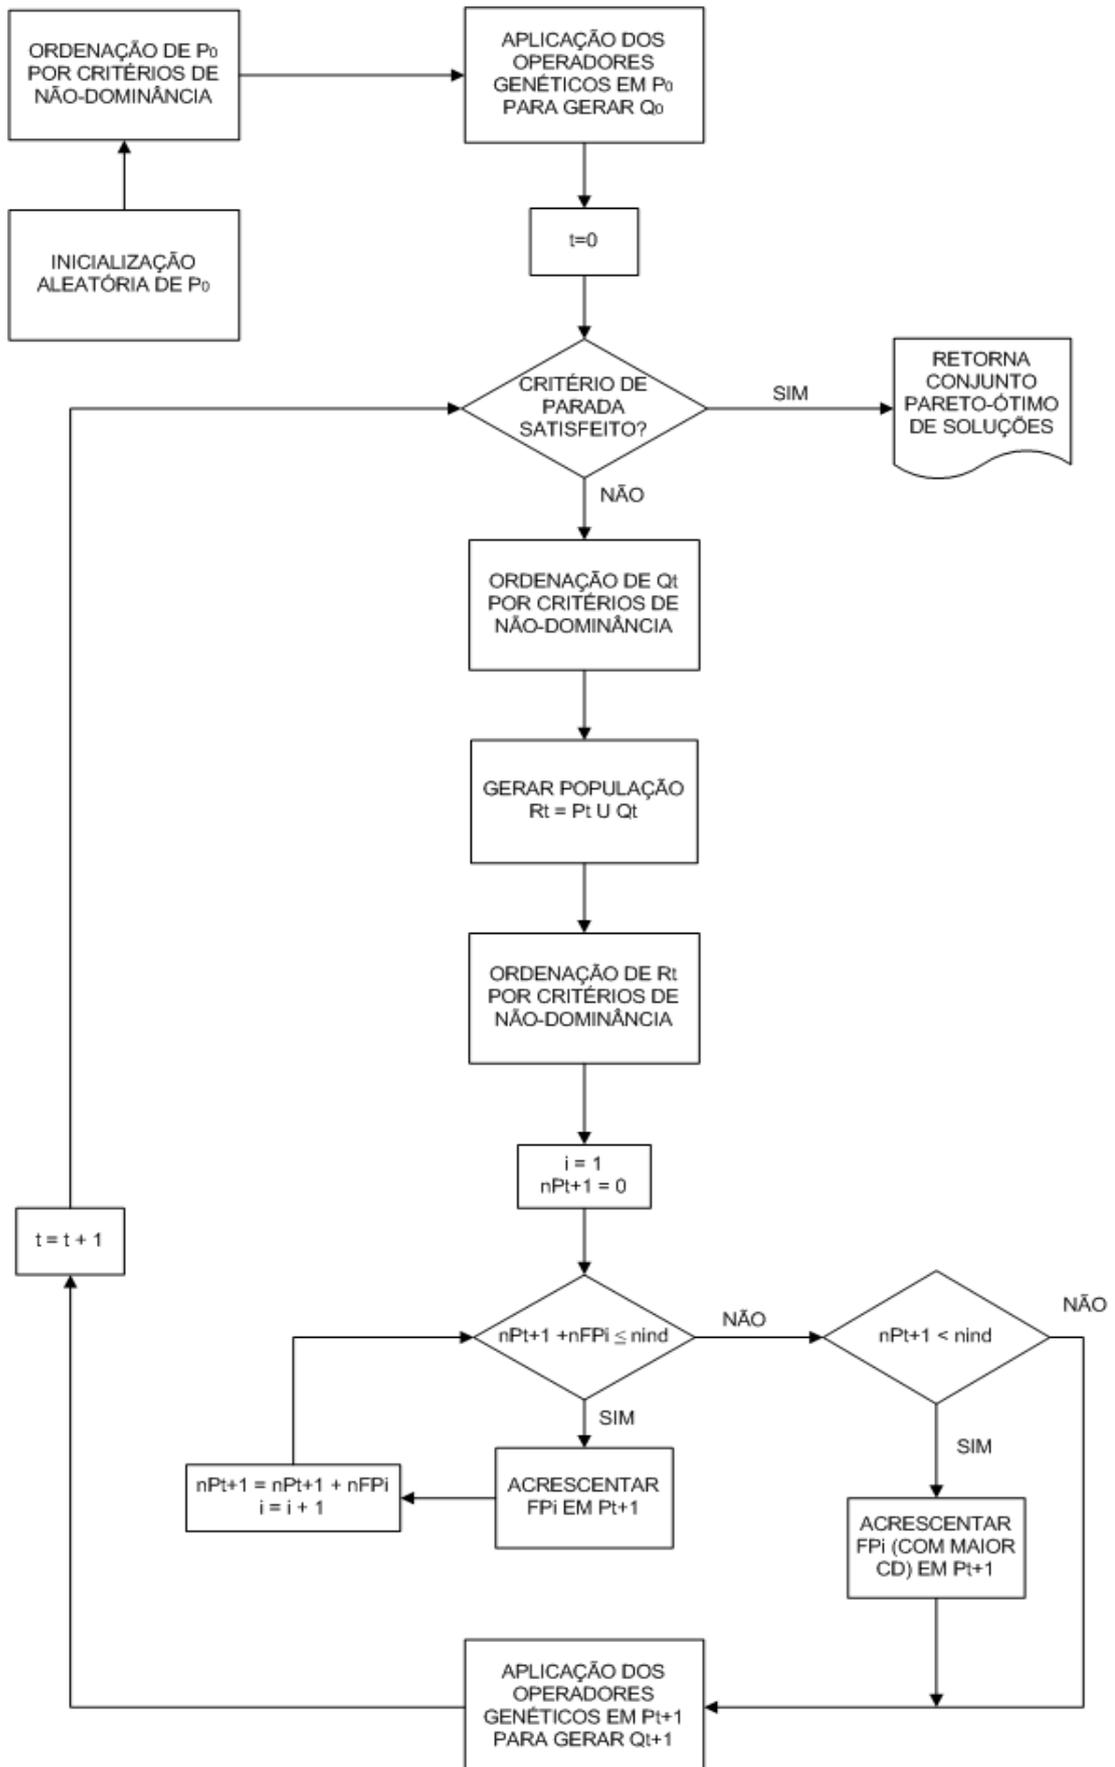


Figura 5 – Fluxograma do NSGA-II

6.4.2. MOEPSO

Assim como ocorreu com o NSGA-II, o algoritmo MOEPSO (do inglês *Multi Objective Evolutionary Particle Swarm Optimization* – Otimização por Enxame de Partículas Evolutivo Multiobjetivo) também é uma melhoria de uma heurística de otimização pré-existente, o enxame de partículas (EP). O EP clássico é um método de otimização natural inspirado no comportamento de enxame de algumas espécies de animais, criado na década de 90 por Russ Eberhart e James Kennedy [118] e consiste de um conjunto de soluções iniciais, geradas de forma aleatória, arbitrária ou utilizando algum conhecimento sobre o problema, e não requer conhecimento prévio da função a ser otimizada, ou seja, a função objetivo é utilizada apenas como medida da qualidade da solução de uma partícula. Além das soluções iniciais, o EP requer a definição da velocidade inicial de cada partícula. A partícula é equivalente ao cromossomo no EP e representa as soluções candidatas, já o conceito de população possui o mesmo significado em ambos os métodos.

O algoritmo MOEPSO na verdade é uma combinação de duas diferentes abordagens do EP clássico: o MOPSO (do inglês *Multi Objective Particle Swarm Optimization* – Otimização por Enxame de Partículas Multiobjetivo), que foi proposto por Carlos Coello et al. em 2002 ([119] e [120]) e aperfeiçoa o EP clássico utilizando o conceito de dominância de Pareto para a manipulação do problema de otimização multiobjetivo; e o EPSO (do inglês *Evolutionary Particle Swarm Optimization* – Otimização por Enxame de Partículas Evolutivo), proposto por Vladimiro Miranda et al. em 2002 ([121] e [122]) e que combina a abordagem tradicional do EP com as estratégias evolutivas de auto-adaptação (mutação, recombinação e seleção).

Assim, o algoritmo MOEPSO, proposto por Hiroyuki Mori et al. [123], se dispõe a avaliar as melhores soluções de Pareto. Tomados isoladamente, o MOPSO tem a desvantagem de se limitar a avaliar as soluções de Pareto locais, enquanto o EP tradicional frequentemente estagna em mínimos locais. Logo, a estrutura evolutiva tem papel essencial no funcionamento do algoritmo, uma vez que suas propriedades de auto-ajuste adaptativo fornece meios para que o programa escape de soluções locais. Isso amplia a busca de uma dada partícula para várias direções, provocando um movimento das partículas replicadas para outras soluções através das mutações sofridas nas várias posições ótimas possíveis do enxame. Os parâmetros das partículas replicadas são mutantes e considerados como prole.

Depois da movimentação e avaliação de pais e filhos, a solução de um dos pais é comparada com as soluções da prole. Se a solução do pai é dominada pela sua descendência, a

prole torna-se o pai da geração seguinte. Caso contrário, se as soluções da prole forem dominadas pelo seu progenitor, a prole é excluída. Resumindo, os melhores sobrevivem. Além disso, se as soluções de ambos, pais e filhos, forem não-dominadas, todas são guardadas e os pais da próxima geração serão determinados aleatoriamente. Estas operações dão ao MOEPSO a capacidade de realizar um auto-ajuste adaptativo de seus parâmetros.

O enxame inicial E_i é gerado aleatoriamente, classificado por não-dominância e replicado (E'_i). Sobre E_i é aplicado o operador de reprodução (equação de movimento do MOEPSO), gerando uma prole. Já sobre E'_i é aplicada antes uma mutação dos parâmetros estratégicos, para que a réplica mutada gere uma prole distinta da original. Por fim, pais e filhos de E_i e E'_i são combinados em uma única lista e ordenados, com os $|E_i|$ primeiros sobrevivendo e formando E_{i+1} , repetindo o processo até atingir o critério de parada. Lembrando que o conjunto final de soluções Pareto-ótimas é armazenado numa lista externa chamada de Lista de Pareto (LP).

A movimentação no MOEPSO é mostrada a seguir:

$$v_i^{k+1} = w_{i0}^* v_i^k + w_{i1}^* (p_{best_i} - s_i^k) + w_{i2}^* [g_{best}^*(h) - s_i^k] \quad (5.2)$$

$$s_i^{k+1} = s_i^k + v_i^{k+1} \quad (5.3)$$

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (5.4)$$

Onde v_i^k e s_i^k são, respectivamente, a velocidade e a posição da partícula i durante a k -ésima iteração, p_{best_i} é a melhor solução da partícula i , $g_{best}(h)$ é a melhor solução de um enxame h , w_{ik} é o $(k+1)$ -ésimo fator de ponderação da partícula i , $N(0,1)$ é um número aleatório de distribuição normal e τ é o parâmetro de aprendizado do enxame. Deve-se observar que a presença do símbolo * significa que a variável em questão sofre mutação. Além disso, $g_{best}(h)$ realiza a mutação para avaliar melhor as soluções, como mostrado abaixo:

$$g_{best}^*(h) = g_{best}(h) + w_{i3}^* N(0,1) \quad (5.5)$$

$$w_{i3}^* = w_{i3} + \tau' N(0,1) \quad (5.6)$$

Onde τ' é o parâmetro de tamanho da vizinhança de $g_{best}(h)$. O parâmetro de (5.5) é o tamanho da vizinhança que permite às partículas melhorar $g_{best}(h)$, sendo atualizado em (5.6).

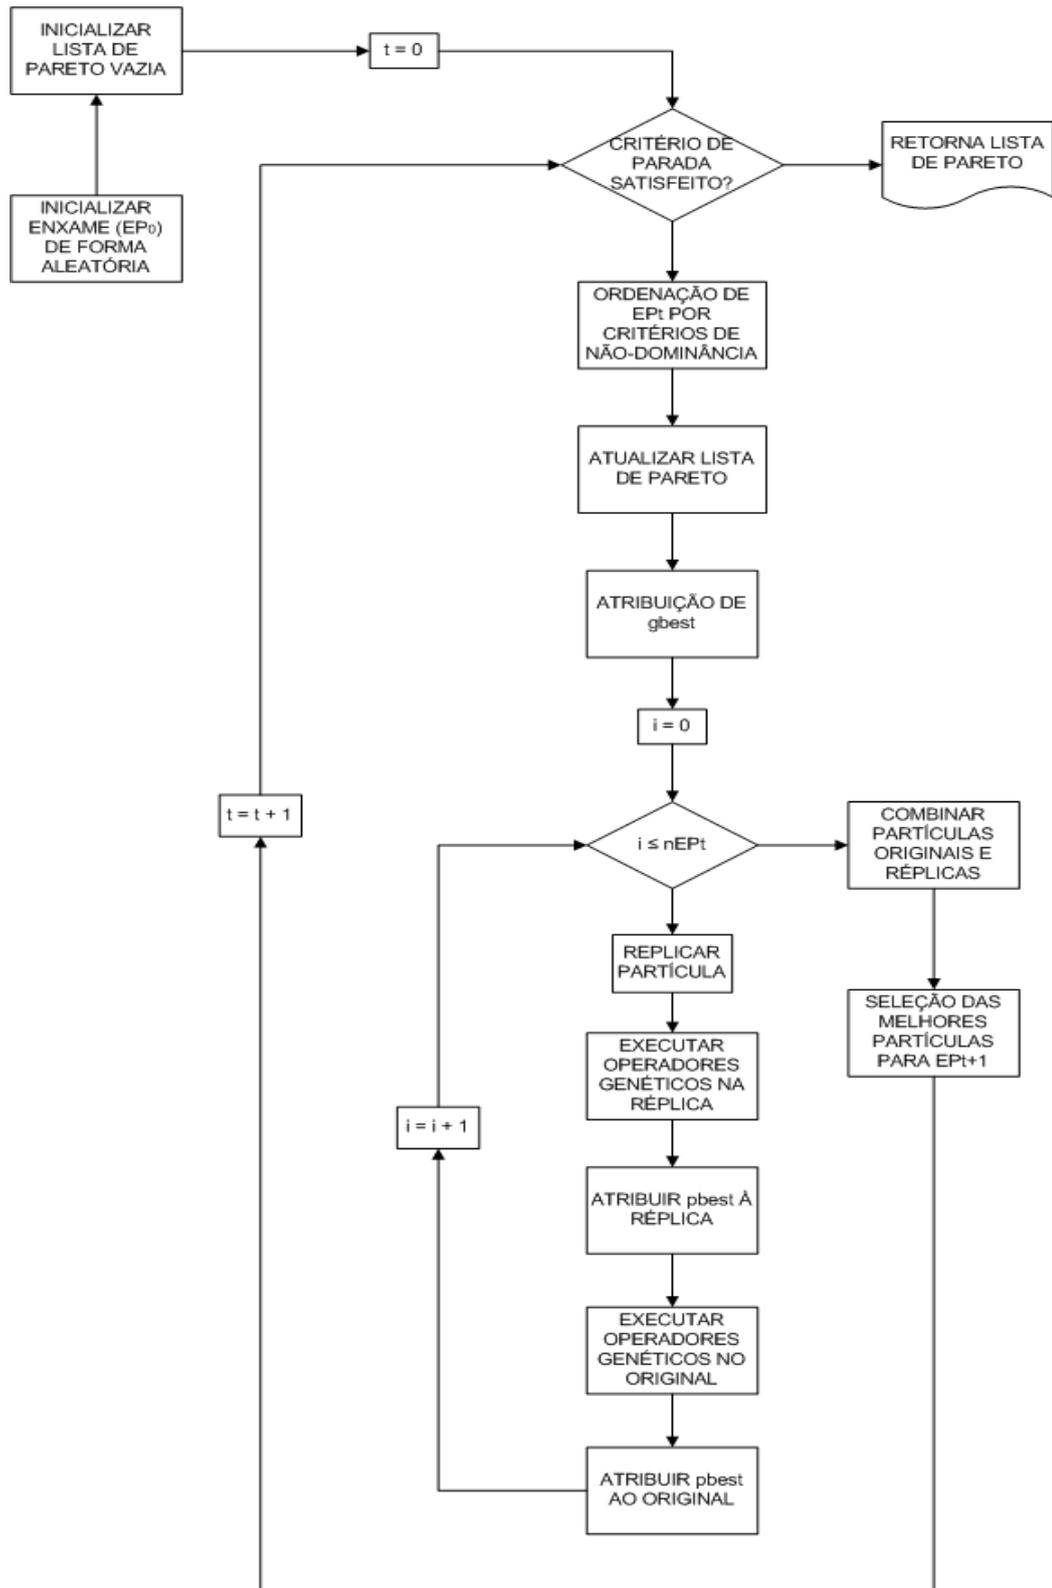


Figura 6 – Fluxograma do MOEPSO

7. FORMULAÇÃO DO PROBLEMA

7.1. INTRODUÇÃO

Um ponto de operação é considerado seguro se, tanto para a rede completa quanto para uma lista de contingências, o suprimento de energia é assegurado sem violar limites operativos. A busca por este ponto de operação pode ser formulada como um problema de otimização, onde o objetivo é a especificação de um conjunto de controles que minimiza o número de restrições não atendidas, com o ponto de operação seguro sendo obtido quando todas as restrições são satisfeitas. Matematicamente, este problema pode ser formulado como segue:

$$\min_{\underline{x}} \sum_{i=1}^{n_{rest}} rest_i(\underline{x}) \quad (7.1)$$

Onde:

$rest_i(\underline{x}): \mathbb{R}^n \rightarrow [0,1]$ - restrições operativas da rede

$rest_i(\underline{x})$ é igual a zero se a i -ésima restrição for atendida e igual a um em caso contrário. Como a função objetivo dada em (6.1) não é continuamente diferenciável, métodos clássicos de programação não-linear não podem ser utilizados para resolver este problema. Considerando como variáveis de controle somente as tensões em barras de geração e os despachos de potência ativa, e como restrições os limites de carregamento em linhas de transmissão, os limites de geração de potência ativa e reativa das unidades geradoras, os limites de tensão nos barramentos e o comportamento em regime permanente da rede, a solução do problema formulado em (6.1) permite a obtenção de um ponto de operação seguro sob o ponto de vista de segurança estática.

7.2. MODELAGEM MATEMÁTICA

A busca por um ponto de operação visando somente aspectos de segurança pode dar origem a despachos que não atendam outros critérios, por exemplo, questões econômicas. Conforme já observado, segurança e economicidade constituem objetivos conflitantes que devem ser balanceados. Neste ponto é percebida a importância de uma abordagem multiobjetivo do problema do FPORS, que permite encontrar um ponto de operação seguro sem deixar de observar o quão custoso o mesmo pode ser. Considerando que o ponto de

operação inicial do caso base (rede completa, sem contingências) foi previamente especificado via despacho econômico, ou seja, foi escolhido o despacho de menor custo dentre os possíveis, o problema de obtenção do despacho seguro pode ser reformulado da seguinte maneira para cada novo ponto de operação $\underline{x} \in \mathbb{R}^n$:

$$\underline{F} = \min_{\underline{x}} \underline{f}(\underline{x}) \quad (7.2)$$

$$\underline{f}(\underline{x}) = [\Delta_{ponto}(\underline{x}), \Delta_{rest}(\underline{x}), \Delta_{conv}(\underline{x})]^T \quad (7.3)$$

$$\Delta_{ponto}(\underline{x}) = \sum_{j=1}^{n_{varctrl}} \frac{|x_j - x_j^{esp}|}{x_j^{esp}} \quad (7.4)$$

$$\Delta_{rest}(\underline{x}) = \sum_{i=1}^{n_{cont}} \sum_{k=1}^{n_{rest}} \Omega_{ik}(\underline{x}) \quad (7.5)$$

$$\Delta_{conv}(\underline{x}) = 2n_{barras}(n_{cont} + 1)c(\underline{x}) \quad (7.6)$$

Nas expressões acima, $\Delta_{ponto}(\underline{x}) \in \mathbb{R}$ representa o somatório dos desvios percentuais de cada uma das $n_{varctrl}$ variáveis de controle do novo ponto de operação $\underline{x} \in \mathbb{R}^n$ em relação ao ponto de operação inicial do caso base $\underline{x}^{esp} \in \mathbb{R}^n$. Uma vez estabelecida a premissa de que \underline{x}^{esp} é o ponto de operação de menor custo possível, é fácil perceber que quanto maior o desvio entre \underline{x} e \underline{x}^{esp} , maior é o custo do ponto de operação encontrado. Daí conclui-se que $\Delta_{ponto}(\underline{x})$ é a função que indica o quão custoso é o ponto de operação \underline{x} encontrado.

Já $\Delta_{rest}(\underline{x}) \in \mathbb{R}$ representa o somatório dos desvios percentuais das n_{rest} variáveis monitoradas do novo ponto de operação em relação aos seus limites, com os resultados somados para cada uma das n_{cont} contingências, sendo a função $\Omega_k(\underline{x})$ calculada como:

$$\Omega_k(\underline{x}) = \begin{cases} 0, & w_k^{min}(\underline{x}) \leq w_k(\underline{x}) \leq w_k^{max}(\underline{x}) \\ \frac{|w_k(\underline{x}) - w_k^{lim}(\underline{x})|}{w_k^{lim}(\underline{x})}, & \text{caso contrário} \end{cases} \quad (7.7)$$

Onde $w_k^{lim}(\underline{x}) \in \mathbb{R}$ responde pelo limite violado pela variável monitorada, por exemplo, $w_k^{lim}(\underline{x}) = w_k^{max}(\underline{x})$ se $w_k(\underline{x}) \geq w_k^{max}(\underline{x})$. Caso ocorra alguma violação de limite operativo, a função objetivo $\Delta_{rest}(\underline{x})$ receberá o valor percentual da diferença entre o valor da variável monitorada e o limite (máximo ou mínimo) estabelecido para essa variável. Em caso contrário ela receberá valor zero.

Por fim, $\Delta_{conv}(\underline{x}) \in \mathbb{R}$ representa a violação de todas as restrições do problema de FPORS, conforme a equação (4.16), considerando uma penalização de uma unidade por violação, devido à não-convergência do fluxo de potência do caso base (o método de análise de contingências pela matriz Z_{barras} dispensa a simulação do fluxo de potência para cada contingência) para o novo ponto de operação \underline{x} , com a função $c(\underline{x})$ dada por:

$$c(\underline{x}) = \begin{cases} 0, & \text{caso o fluxo de potência convirja} \\ 1, & \text{caso contrário} \end{cases} \quad (7.8)$$

Caso haja convergência a função $\Delta_{conv}(\underline{x})$ retorna o valor zero, em caso contrário ela retorna a violação de 100% das restrições do problema de FPORS. A intenção ao inserir essa função objetivo no problema era garantir que não haveria soluções com fluxo de potência divergente na população final, conferindo-lhes um valor suficientemente alto na função objetivo para que fossem descartadas nas primeiras iterações da meta-heurística utilizada.

Para este trabalho, foram considerados os seguintes limites operativos e penalizações:

Tabela 3 – Limites operativos avaliados pela heurística

Limite Operativo	Descrição
P_{ij}^{max}	Carregamento máximo no ramo entre as barras i e j
Q_g^{lim}	Limite (máximo ou mínimo) de geração de reativo na barra g
V_g^{lim}	Limite (máximo ou mínimo) de tensão no barramento g

Tabela 4 – Penalizações correspondentes a cada restrição violada

Restrição Violada	Penalização (unid.)
V_g^{lim}	1
Q_g^{lim}	1
P_{ij}^{max}	1
Despacho total sem a barra swing superior à demanda	$2n_{barras}(n_{cont} + 1)$
Não convergência do fluxo de carga	$2n_{barras}(n_{cont} + 1)$

Para cada limite operativo avaliado pela heurística, foi definida uma penalização de uma unidade no *fitness* da função objetivo pela sua violação. Já para o caso do despacho total de uma solução ser superior à demanda desconsiderando a barra swing foi definida uma penalização correspondente à violação de todas as restrições do problema do FPORS, conforme descrito na equação (4.16). A mesma penalização é aplicada no caso de não-convergência do fluxo de potência, também de acordo com a equação (4.16).

7.3. ESTRUTURA DO VETOR-SOLUÇÃO

O vetor-solução representa as variáveis de controle trabalhadas no presente problema de FPORS, ou seja, aquelas que são alteradas durante o processo de solução para obter o ponto de operação ótimo do sistema de potência. Neste trabalho as variáveis de controle selecionadas para lidar com o problema foram o despacho de potência ativa e a magnitude de tensão nas barras geradoras, ou seja, a ferramenta de FPORS irá essencialmente manipular as variáveis conhecidas das barras PV na modelagem do fluxo de potência, apresentando diversos valores para a mesma até encontrar uma configuração de barras PV que retorne um ponto de operação ótimo segundo os critérios das funções objetivo anteriormente definidas.

O vetor-solução modelado para o problema abordado nesse trabalho foi codificado em números reais, representando o despacho de potência ativa nas unidades geradoras, bem como a magnitude de tensão nessas mesmas unidades geradoras, que são representadas no fluxo de potência pela barra PV (em ambos os casos, a barra SW foi excluída). Sendo assim, têm-se dois tipos de campos no vetor:

- *Despacho de potência ativa:* este campo é representado por números reais no intervalo $[P_g^{min}, P_g^{max}]$, onde P_g^{max} e P_g^{min} são os limites de geração para cada unidade geradora g em pu. Convém lembrar que cada máquina possui limites de geração distintos, estes dados podem ser encontrados em [124].
- *Magnitude de tensão:* este campo é representado por números reais no intervalo $[V_g^{min}, V_g^{max}]$, onde V_g^{max} e V_g^{min} são os limites da magnitude de tensão para a unidade geradora g . Neste trabalho, a faixa de operação de tensão compreende valores entre 0,95 e 1,05 pu, tensão emergencial para contingências segundo [3].

Assim os dados de despacho de potência ativa e magnitude de tensão das unidades geradoras são concatenados em um vetor de 46 posições, sendo as 23 primeiras posições reservados para o campo de despacho de potência ativa e as 23 últimas posições para o campo de magnitude de tensão, correspondendo às 23 barras de geração (PV) que há no sistema-teste utilizado, que será descrito na próxima seção.

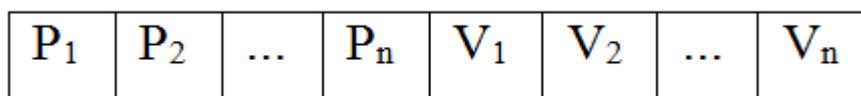


Figura 7 – Vetor-solução

7.4. ALGORITMOS IMPLEMENTADOS PARA A RESOLUÇÃO DO FPORS

7.4.1. INTRODUÇÃO

Durante os testes da ferramenta recém-implementada de FPORS, foi verificado um tempo de simulação excessivamente alto da mesma, sendo necessária, portanto, a adoção de medidas que pudessem reduzir esse tempo de execução do algoritmo projetado. As melhorias realizadas deram origem a um novo programa, e para fins de comparação os resultados da versão anterior foram mantidos, de forma a mostrar com números o quão necessárias eram as melhorias. Os resultados retornados por ambas as versões estão no Capítulo 8.

A primeira implementação do programa foi simplesmente o FPORS baseado em fluxo de potência completo, com a população inicial de despachos gerada de maneira totalmente estocástica. A diferença para a segunda implementação é que nesta última a população inicial gerada aleatoriamente passa por um refinamento via FPORS antes de ser avaliada pelo algoritmo. Esse refinamento é feito por um programa de FPORS baseado em fluxo de potência linearizado, tal como exibido na Figura 15.

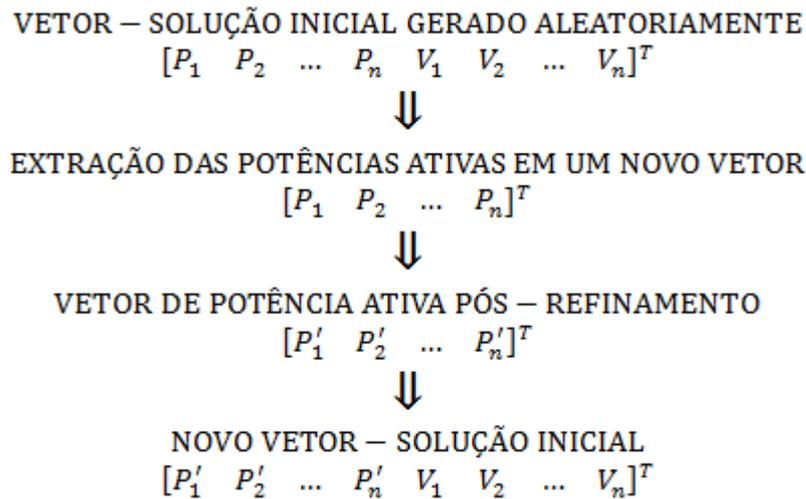


Figura 8 – Refinamento da solução inicial pelo FPORS CC

Como as variáveis do vetor-solução correspondentes à potência ativa foram previamente otimizadas, os algoritmos evolutivos tenderão a convergir mais rapidamente para o conjunto de soluções Pareto-ótimo, e conseqüentemente reduzirão o tempo de execução das simulações, mesmo considerando o tempo de execução do próprio refinamento. Mais detalhes sobre as implementações nas duas subseções seguintes.

7.4.2. OTIMIZAÇÃO BASEADA APENAS EM FLUXO DE POTÊNCIA CA

Foi a primeira implementação realizada, totalmente baseada em fluxo de potência completo. Nela, para cada solução inicial de um conjunto gerado aleatoriamente é executado um fluxo de potência CA do caso base (rede sem contingências) para subsidiar a análise de contingências CA subsequente, e então a solução é avaliada pela função de aptidão para que possa ser classificada e ordenada de acordo com sua pontuação nas funções objetivo. Então a solução é entregue para a meta-heurística multiobjetivo, que aplica seus operadores específicos e reavalia a nova solução, passando antes pela execução do fluxo de potência CA e análise de contingências CA, até encontrar a solução otimizada. Nesta primeira implementação, o MOEPSO possui um mecanismo de atualização de p_{best} e g_{best} em que é escolhido como melhor elemento do enxame a partícula com o maior valor de *crowding distance* dentre todas as soluções não-dominadas, característica que foi modificada para a segunda implementação.

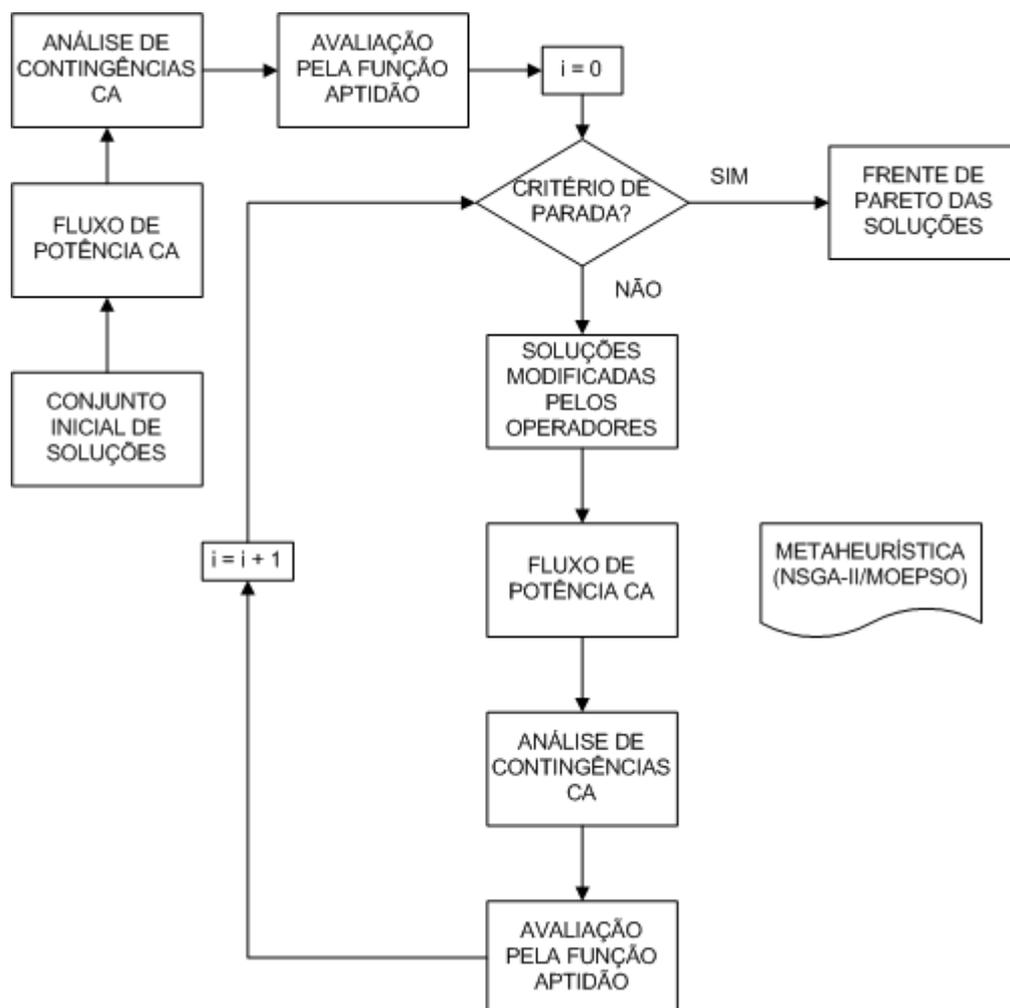


Figura 9 – Otimização baseada apenas em fluxo de potência CA

7.4.3. OTIMIZAÇÃO EM FLUXO DE POTÊNCIA CA COM REFINAMENTO CC

Com o objetivo de obter um tempo de execução do programa de FPORS menor do que o retornado pela primeira implementação, foi elaborada uma nova implementação do programa de FPORS, no qual é inserido um refinamento da solução inicial gerada aleatoriamente. Esse refinamento é baseado em fluxo de potência linearizado e atua na solução inicial tal como indicado na Figura 14. Em cada elemento do novo conjunto de vetores de potência ativa é executado um fluxo de potência CC do caso base, seguido da análise de contingências CC, para então a solução ser avaliada pela função de aptidão e assim classificada e ordenada (na função de aptidão específica para o refinamento CC não há a função objetivo $\Delta_{conv}(\underline{x})$ pois o método de resolução não é iterativo). Então o conjunto de soluções classificadas e ordenadas é repassado para a meta-heurística, que aplica seus operadores, obtêm novas soluções candidatas e as reavalia, retornando uma frente de Pareto de vetores de potência ativa, que são concatenados com os vetores de tensão da solução inicial para obter a solução inicial refinada.

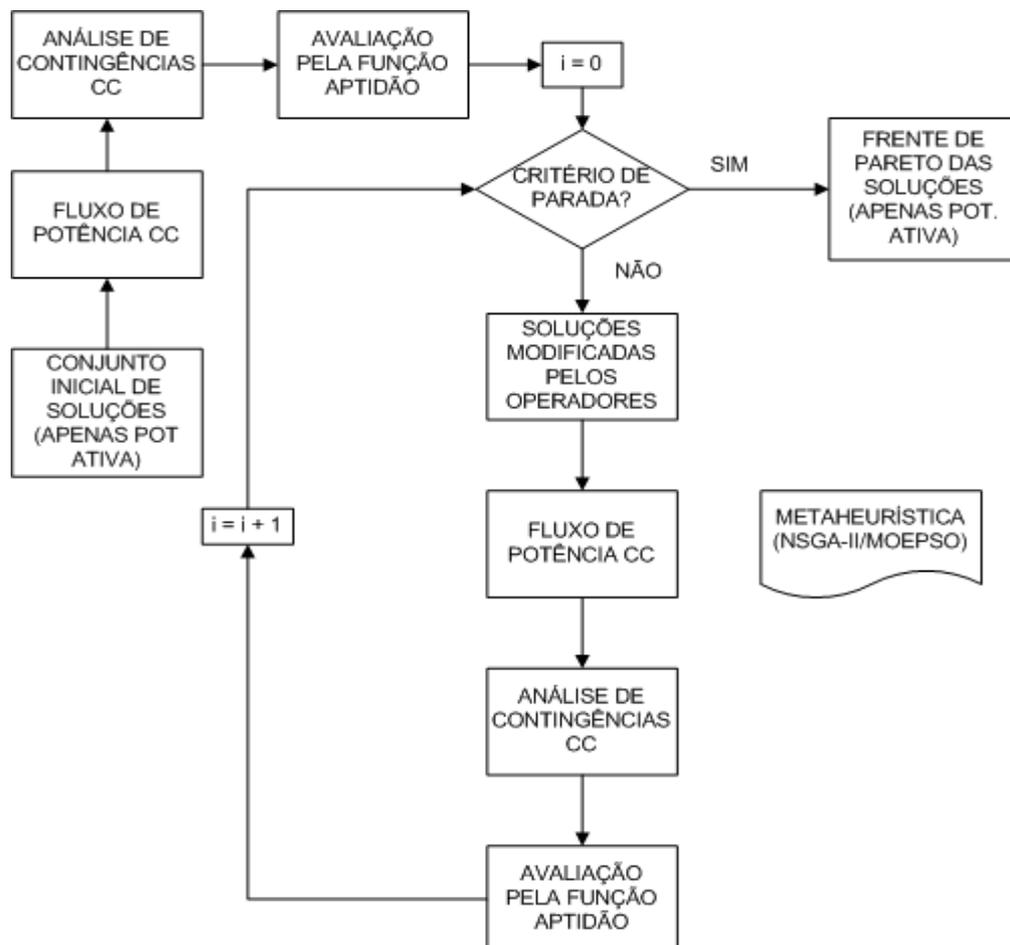


Figura 10 – Refinamento via FPORS CC

Partindo do conjunto de soluções iniciais refinadas, o algoritmo da segunda implementação do programa de FPORS é bastante semelhante à primeira, com a execução do fluxo de potência CA seguido da análise de contingências CA para cada elemento do conjunto, que será classificado e ordenado pela função aptidão antes de seguir para o processamento da meta-heurística, que aplicará seus operadores para obter novas soluções candidatas e reavaliá-las até obter a frente de Pareto com as soluções otimizadas. A diferença reside no mecanismo de atualização para p_{best} e g_{best} escolhido para o MOEPSO na segunda implementação: enquanto a primeira implementação escolhe a partícula com maior valor de *crowding distance* dentre as soluções não-dominadas como melhor elemento do enxame, a segunda implementação atribui esse posto às soluções com as menores distâncias euclidianas em relação à origem, selecionando assim o elemento mais próximo da solução ideal do problema, uma vez que o ideal seria que todas as funções objetivo retornassem valor nulo.

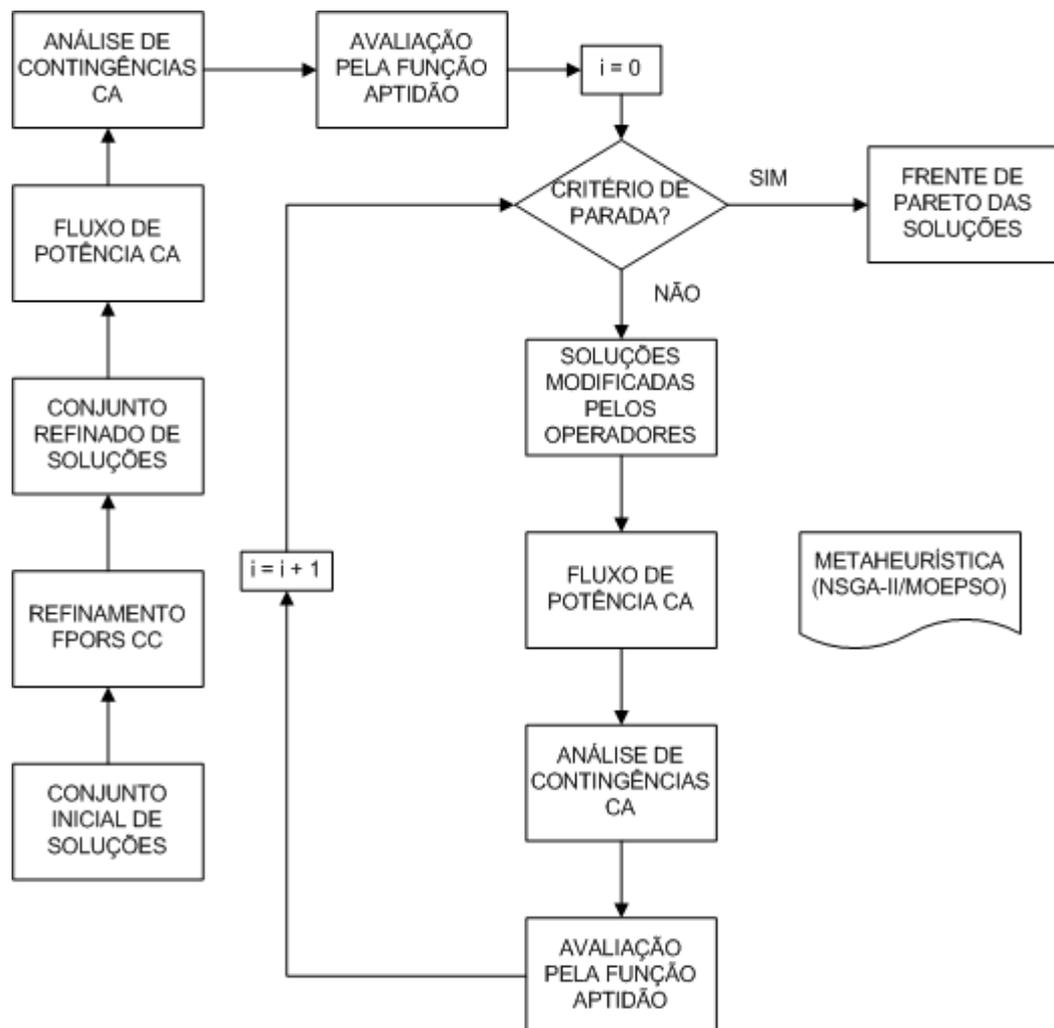


Figura 11 – Otimização em fluxo de potência CA com refinamento CC

linhas mais carregadas do caso base, ou seja, as linhas mais carregadas no ponto de operação original da rede, que naturalmente estão entre as que mais prejudicam o sistema em caso de queda, daí a importância da rede estar preparada para a sua ocorrência. Também podem ser usados outros critérios, como probabilidade de saída do equipamento. A Tabela 5 apresenta a lista das contingências consideradas, onde é apresentado o nome da linha de transmissão defeituosa e dos seus barramentos de origem e destino, além do seu carregamento inicial no caso base.

Tabela 5 – Lista de contingências

Contingência	Nome da Linha	Barra DE	Barra PARA	S (MVA)
1	Segredo-Areia	856	933	1960,336
2	Areia-Bateias	933	895	1280,854
3	Areia-Curitiba	933	959	1184,858
4	Itá-Salto Santiago	995	1060	976,7270
5	Machadinho-C. Novos	1030	955	962,9778

O próximo passo é definir os parâmetros dos algoritmos de otimização usados. As Tabelas 6 e 7 apresentam os parâmetros especificados para o NSGA-II e MOEPSO, respectivamente. Cabe observar que o MOEPSO também utiliza um operador de seleção no seu algoritmo, devido à sua aplicação do método de classificação por não-dominância, que possui a mesma configuração utilizada no NSGA-II, ou seja, o trecho de algoritmo utilizado para implementar o método de ordenação por não-dominância no NSGA-II foi aproveitado para implementar o mesmo método também no MOEPSO. Cabe observar também que os parâmetros de simulação de ambos os métodos foram escolhidos empiricamente, ou seja, foram executadas simulações de teste de cada heurística para avaliar quais parâmetros ajustavam melhor a simulação para o problema em questão.

Para possibilitar uma comparação justa do tempo de simulação gasto pelas duas implementações do FPORS, foi estabelecido um número de gerações igual para ambos os casos, de 150 iterações no total. Lembrando que o Refinamento CC também é uma implementação meta-heurística, portanto também precisa executar gerações, que no caso também foram fixadas no número de 150 gerações para se obter o conjunto de Pareto dos despachos de potência ativa que comporão a nova solução inicial devidamente refinada. Há ainda a distinção dos métodos para obter p_{best} e g_{best} para cada implementação do FPORS e para a ferramenta de refinamento. Todos esses parâmetros também foram estabelecidos empiricamente.

Tabela 6 – Parâmetros do NSGA-II

Parâmetro		Atribuição
Número de Gerações	1ª Implementação	150
	2ª Implementação	150
	Refinamento CC	150
Tamanho da população		40 indivíduos
Criação da população inicial		Distribuição gaussiana centrada no caso base
Tamanho do <i>mating pool</i>		20 indivíduos
Método de seleção		Torneio
Tamanho do torneio		2 indivíduos
Método de cruzamento		Cruzamento Binário Simulado (SBX)
Probabilidade de cruzamento		90%
Método de mutação		Mutação Polinomial
Probabilidade de mutação		10%

Tabela 7 – Parâmetros do MOEPSO

Parâmetro		Atribuição
Número de Gerações	1ª Implementação	150
	2ª Implementação	150
	Refinamento CC	150
Tamanho do enxame		40 indivíduos
Criação do enxame inicial		Distribuição gaussiana centrada no caso base
Criação do vetor de velocidade inicial		Distribuição uniforme
Peso de inércia inicial ($w_{i0}^{inicial}$)		0,7
Peso de inércia final (w_{i0}^{final})		0,4
Peso de cooperação inicial (w_{i1})		2
Peso de memória inicial (w_{i2})		2
Operador de mutação inicial de g_b (w_{i3})		1
Parâmetro de aprendizagem (τ)		0,02
Parâmetro de exploração da vizinhança de g_b (τ')		0,01
Método de atribuição de p_{best} e g_{best}	1ª Implementação	<i>Crowding Distance</i>
	2ª Implementação	Distância Euclidiana
	Refinamento CC	Distância Euclidiana

8. RESULTADOS

8.1. METODOLOGIA DE ANÁLISE DOS RESULTADOS

Neste trabalho foram executadas, para dar relevância estatística ao resultado, 10 simulações de cada heurística de otimização, sendo que os resultados de cada uma dessas simulações, para cada heurística, foram comparados entre si de modo a escolher o melhor e o pior resultado. Por exemplo, foram feitas 10 execuções do NSGA-II e as 10 fronteiras de Pareto retornadas foram comparadas entre si de acordo com o critério de dominância, sendo feito o mesmo para o MOEPSO. Realizadas as execuções de ambos os métodos, são escolhidas as melhores fronteiras de Pareto retornadas pela execução de cada método para serem comparadas entre si, estabelecendo assim qual dos dois métodos possui o melhor desempenho.

Os resultados obtidos aqui serão comparados também com os resultados da otimização mono-objetivo do mesmo problema, descrito em [8]. Neste trabalho também foram testadas diversas heurísticas de otimização, sendo que os melhores resultados foram obtidos pela aplicação do Algoritmo Genético (AG), no caso mono-objetivo executado através da *toolbox* específica do MATLAB. O AG neste caso trabalha com as mesmas funções objetivo descritas nas equações (7.4), (7.5) e (7.6), entretanto utiliza um esquema de agregação de objetivos para avaliá-las, ou seja, o seu algoritmo é voltado para a minimização da soma dos resultados retornados pelas funções objetivo em questão.

A comparação entre os resultados da otimização multi-objetivo com o caso mono-objetivo será feita da seguinte forma: de cada fronteira de Pareto retornada por cada método, será extraído o indivíduo com a menor distância euclidiana em relação à origem (0,0), uma vez que a origem seria o resultado ideal para um indivíduo, no qual não há penalizações tanto de economia quanto de segurança. Assim, para cada método são extraídos 10 indivíduos, que são comparados entre si tendo como critério a distância euclidiana em relação à origem. Por fim, as soluções obtidas são comparadas com o resultado do AG, de forma a estabelecer o desempenho da otimização multi-objetivo frente ao caso mono-objetivo.

Os resultados foram divididos em duas partes, de acordo com as implementações descritas na Seção 7.4, do Capítulo 7. Na primeira implementação, o FPORS foi baseado apenas em fluxo de potência completo, tal como descrito na Subseção 7.4.2 e exibido na Figura 9, no que foi verificado que possuía um tempo de simulação excessivamente alto, necessitando de melhorias para uma execução mais rápida. O MOEPSO projetado na primeira

implementação possui um mecanismo de atualização de p_{best} e g_{best} em que é escolhido como melhor elemento do enxame a partícula com o maior valor de *crowding distance* dentre todas as soluções não-dominadas presentes, característica que foi modificada para a segunda análise.

Na segunda implementação, para reduzir o tempo de duração de cada simulação, foi projetado inicialmente um refinamento baseado em FPORS CC, de execução mais rápida e capaz de fornecer o despacho ótimo de potência ativa, embora não forneça o perfil de tensão dos geradores. O refinador implementado é descrito na Subseção 7.4.3 e exibido na Figura 10. O refinador atua em cima da solução inicial gerada aleatoriamente e gera uma solução inicial refinada, tal como exibido na Figura 8, e então se inicia o programa de FPORS de fato, como exibido na Figura 11. Como as variáveis do vetor-solução correspondentes à potência ativa foram previamente otimizadas, os algoritmos evolutivos tenderão a se aproximar mais rapidamente do conjunto de soluções Pareto-ótimo e consequentemente reduzirão o tempo de execução das simulações. No MOEPSO desenvolvido para a segunda implementação, p_{best} e g_{best} foram atribuídos como as soluções com as menores distâncias euclidianas em relação à origem de seus respectivos conjuntos de soluções, considerando que neste problema em particular o ideal seria obter um valor nulo para todas as funções objetivo.

Antes da análise dos resultados, uma observação: a função objetivo $\Delta_{conv}(\underline{x})$, referente à penalização recebida por um ponto de operação cujo cálculo do fluxo de potência seja divergente, não precisa ser analisada, uma vez que a população final de todos os três métodos de otimização estudados contam apenas com indivíduos cujo cálculo do fluxo de potência convergiu, ou seja, para todos os casos o valor retornado por essa função objetivo será nulo, não sendo necessário avaliá-la.

As simulações foram realizadas numa máquina Dell com processador Intel® Core™ i7 vPro™ dois núcleos de 3,4 GHz, 8 GB de memória RAM, Windows 7 64-bits e implementadas em MATLAB®.

8.2. AVALIAÇÃO DO CASO BASE

Para verificar a necessidade de executar o FPORS para a referida rede elétrica, foi feita uma avaliação do despacho original do caso base do sistema-teste utilizado neste trabalho, segundo as funções objetivo implementadas neste trabalho, para verificar seu desempenho quando da ocorrência de alguma das contingências presentes na lista, exibida na Tabela 8:

Tabela 8 – Avaliação do despacho ativo original do caso base

BARRA	Pg (pu)	Vg (pu)
12	3,00	1,00
16	8,00	1,00
20	9,00	1,01
21	1,40	1,00
22	1,50	1,00
35	2,00	1,00
48	0,00	1,00
300	7,00	1,02
301	3,00	1,01
302	4,00	1,02
303	2,00	1,02
305	3,00	1,00
500	8,00	1,02
800	11,00	1,02
808	11,50	1,02
810	12,00	1,02
904	7,00	1,02
915	7,00	1,02
919	7,00	1,00
925	9,50	1,02
4523	0,50	1,01
4596	2,30	1,00
4804	0,50	1,00
$\Delta_{ponto}(\underline{x})$	0	
$\Delta_{rest}(\underline{x})$	1282,52	
$\Delta_{conv}(\underline{x})$	0	

Vê-se que o despacho do caso base possui, obviamente, $\Delta_{ponto}(\underline{x})$ igual à zero, uma vez que se trata do próprio ponto de operação pré-especificado como referência na equação (7.4), assim como possui Δ_{conv} também nulo, pois o despacho original do sistema-teste converge para o fluxo de potência do caso base (lembrando que com a análise de contingências baseada em Z_{BARRA} o fluxo de potência é executado uma única vez por despacho, e apenas para o caso base). Entretanto, para função objetivo Δ_{rest} , o despacho do caso base mostrou possuir um altíssimo custo, demonstrando que não é o ponto de operação ideal para deixar o sistema de potência prevenido para a ocorrência de alguma das contingências da lista.

Portanto, é necessário buscar pontos de operação melhores do ponto de vista da segurança, sem deixar de observar o aspecto econômico, para deixar a rede preparada para a referida lista de contingências, o que será feito através da resolução do FPORS.

8.3. PRIMEIRA IMPLEMENTAÇÃO (I1)

Nas figuras 13 e 14, estão as frentes de Pareto retornadas pelo NSGA-II e MOEPSO.

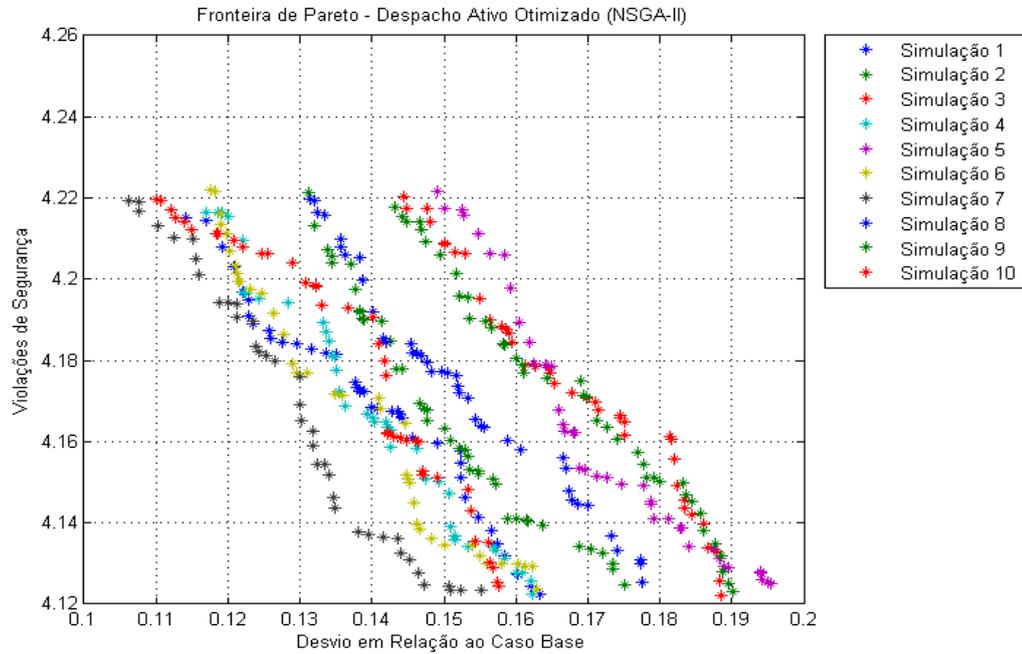


Figura 13 – Fronteiras de Pareto retornadas pela execução do NSGA-II (I1)

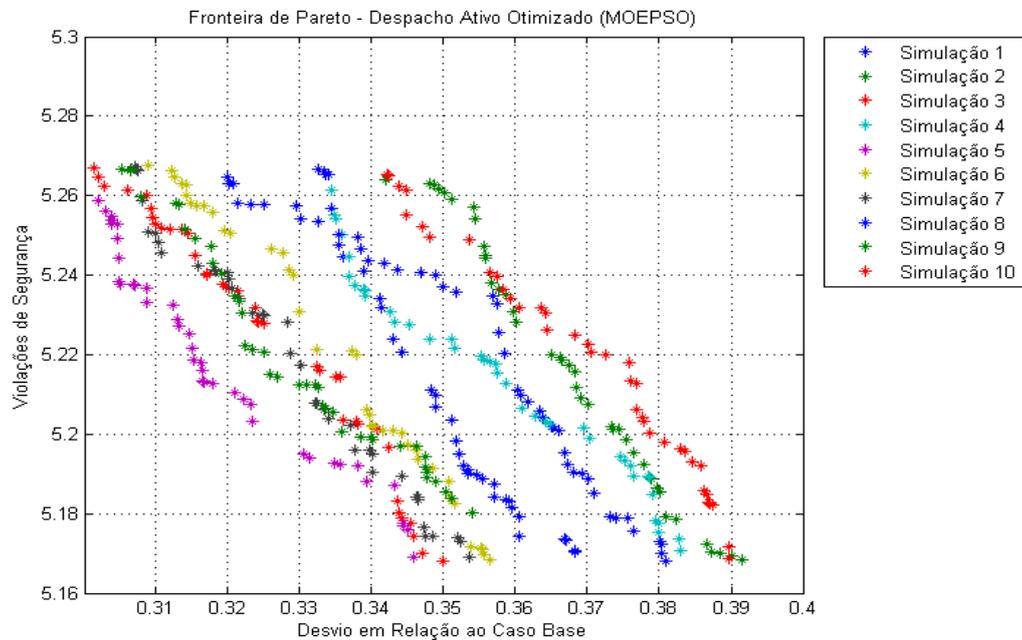


Figura 14 – Fronteiras de Pareto retornadas pela execução do MOEPSO (I1)

As 10 execuções do NSGA-II e do MOEPSO duraram, somadas, aproximadamente 11,78 horas e 10,30 horas, respectivamente. Na Figura 13, nota-se que a melhor frente de Pareto obtida em 10 simulações do NSGA-II foi a retornada pela 7ª simulação, de cor preta. Já na Figura 14, nota-se que a melhor frente de Pareto obtida em 10 simulações do MOEPSO foi a retornada pela 5ª simulação, de cor roxa. A partir daí, é feita uma comparação de dominância entre os dois métodos, de modo a verificar qual deles possui o melhor desempenho. Na Figura 15, os conjuntos de soluções do NSGA-II estão em vermelho e os do MOEPSO estão em azul.

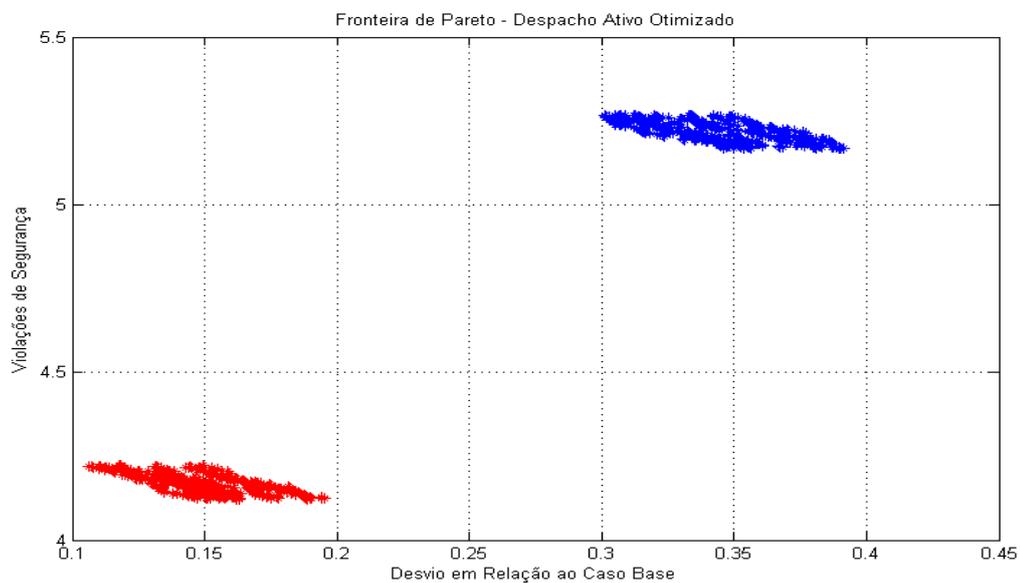


Figura 15 – Comparação entre as frentes de Pareto de cada método (II)

Na Figura 15, nota-se que nenhuma solução retornada pelo método NSGA-II (em vermelho) é dominada por nenhuma das soluções encontradas pelo método MOEPSO (em azul), no entanto todas as soluções NSGA-II dominam pelo menos uma solução MOEPSO, na verdade todas as soluções NSGA-II dominam todas as soluções MOEPSO. Portanto, no que tange à otimização multi-objetivo, o método NSGA-II se mostrou bem superior ao MOEPSO nesta primeira análise.

No Apêndice A estão os indivíduos de menor distância euclidiana em relação à origem de cada frente de Pareto retornada pelas 10 simulações (S1 até S10) de cada método, e nas Tabelas 9 e 10 estão os valores da função objetivo e do tempo de simulação para cada um dos melhores despachos de cada método. As variáveis P1 até P23 representam o despacho de potência ativa das unidades geradoras e estão representadas em p.u, enquanto as variáveis de V1 até V23 são as tensões das unidades geradoras, também representadas em p.u.

Tabela 9 – Valores de função objetivo e tempo de simulação para o NSGA-II (II)

Simulação	Tempo (h)	Dist. Eucl.	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	Agregação
S1	1,1660	4,1256	4,1224	0,1633	4,2857
S2	1,1734	4,1285	4,1248	0,1750	4,2998
S3	1,1808	4,1264	4,1221	0,1886	4,3107
S4	1,1739	4,1257	4,1225	0,1622	4,2847
S5	1,1935	4,1296	4,1250	0,1954	4,3204
S6	1,1711	4,1269	4,1236	0,1630	4,2866
S7	1,1914	4,1263	4,1234	0,1552	4,2786
S8	1,1773	4,1290	4,1252	0,1776	4,3028
S9	1,1562	4,1274	4,1230	0,1902	4,3132
S10	1,1979	4,1276	4,1246	0,1577	4,2823
Mínimo	1,1562	4,1256	4,1221	0,1552	4,2786
Máximo	1,1979	4,1296	4,1252	0,1954	4,3204
Média	1,1782	4,1273	4,1237	0,1728	4,2965
Desv. Pad	0,0130	0,0014	0,0012	0,0146	0,0148

Da análise da Tabela 9, nota-se que na função objetivo $\Delta_{ponto}(\underline{x})$, que avalia o desvio percentual do despacho em relação à referência, o menor valor foi obtido por S3, enquanto o maior valor foi obtido por S8, sendo a variável com o menor desvio padrão avaliada para o NSGA-II, o que indica as simulações são muito parecidas sob esse ponto de vista. Para $\Delta_{rest}(\underline{x})$, que avalia a severidade das violações, o menor valor foi obtido por S7 e o maior valor por S5, entretanto obteve um desvio padrão bem mais alto, sendo possível priorizar a segurança no momento de escolher o ponto de operação ideal, podendo optar por um custo de segurança mais baixo sabendo que o desvio para a referência será basicamente muito parecido qualquer que seja a escolha.

Em relação à agregação de objetivos, o menor valor foi retornado por S7 enquanto o maior valor foi retornado por S5, com uma forte influência de $\Delta_{rest}(\underline{x})$ demonstrada pelo alto desvio padrão, enquanto que para a distância euclidiana o menor valor foi retornado por S1 e o maior por S5, com forte influência de $\Delta_{ponto}(\underline{x})$ demonstrada pelo baixo desvio padrão. Quanto ao tempo, a menor marca foi de S9 e a maior marca de S10, também com um alto desvio padrão, o que mostra certa variação entre a duração de cada simulação.

Da bateria de simulações do NSGA-II para a primeira implementação, conclui-se que o melhor resultado do ponto de vista multiobjetivo (distância euclidiana) veio de S1, enquanto que do ponto de vista mono-objetivo (agregação de objetivos) o melhor resultado veio de S7, o que mostra o quanto uma abordagem distinta de um mesmo problema pode influenciar no resultado final, mesmo considerando as mesmas funções objetivo.

Tabela 10 – Valores de função objetivo e tempo de simulação para o MOEPSO (II)

Simulação	Tempo (h)	Dist. Eucl.	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	Agregação
S1	1,0294	5,1821	5,1680	0,3810	5,5490
S2	1,0011	5,1832	5,1683	0,3915	5,5599
S3	1,0206	5,1798	5,1680	0,3499	5,5179
S4	1,0357	5,1849	5,1708	0,3829	5,5537
S5	1,0487	5,1806	5,1690	0,3459	5,5149
S6	1,0390	5,1806	5,1684	0,3564	5,5247
S7	1,0450	5,1812	5,1691	0,3536	5,5227
S8	1,0302	5,1835	5,1704	0,3683	5,5387
S9	1,0382	5,1922	5,1801	0,3539	5,5341
S10	1,0089	5,1833	5,1686	0,3896	5,5582
Mínimo	1,0011	5,1798	5,1680	0,3459	5,5149
Máximo	1,0487	5,1922	5,1801	0,3915	5,5599
Média	1,0297	5,1831	5,1701	0,3673	5,5374
Desv. Pad	0,0154	0,0036	0,0037	0,0175	0,0171

Da análise da Tabela 10, nota-se que na função objetivo $\Delta_{ponto}(\underline{x})$, que avalia o desvio percentual do despacho em relação à referência, o menor valor foi obtido por S3, enquanto o maior valor foi obtido por S9, sendo uma variável com baixo desvio padrão avaliada para o MOEPSO, o que indica as simulações são muito parecidas sob esse ponto de vista. Para $\Delta_{rest}(\underline{x})$, que avalia a severidade das violações, o menor valor foi obtido por S5 e o maior valor por S2, entretanto obteve um desvio padrão bem mais alto, sendo possível priorizar a segurança no momento de escolher o ponto de operação ideal, podendo optar por um custo de segurança mais baixo sabendo que o desvio para a referência será basicamente muito parecido qualquer que seja a escolha.

Em relação à agregação de objetivos, o menor valor foi retornado por S5 enquanto o maior valor foi retornado por S2, com uma forte influência de $\Delta_{rest}(\underline{x})$ demonstrada pelo alto desvio padrão, enquanto que para a distância euclidiana o menor valor foi retornado por S3 e o maior por S9, com forte influência de $\Delta_{ponto}(\underline{x})$ demonstrada pelo baixo desvio padrão. Quanto ao tempo, a menor marca foi de S2 e a maior marca de S5, também com um alto desvio padrão, o que mostra uma certa variação entre a duração de cada simulação.

Da bateria de simulações do MOEPSO para a primeira implementação, conclui-se que o melhor resultado do ponto de vista multiobjetivo (distância euclidiana) veio de S3, enquanto que do ponto de vista mono-objetivo (agregação de objetivos) o melhor resultado veio de S5, o que mostra mais uma vez o quanto uma abordagem distinta de um mesmo problema pode influenciar no resultado final, mesmo considerando as mesmas funções objetivo.

O próximo passo é a comparação entre as abordagens mono-objetivo e multiobjetivo. Para a Tabela 11 são escolhidos, além do despacho do caso base, os despachos com a menor distância euclidiana para as simulações do NSGA-II e MOEPSO e o despacho retornado pelo AG em [8]. O despacho escolhido para representar o NSGA-II foi retornado pela simulação S1, enquanto o despacho retornado pela simulação S3 irá representar o MOEPSO.

Tabela 11 – Despachos do caso base e obtidos pelos métodos de otimização (II)

Variável		Caso Base		NSGA-II		MOEPSO		AG	
P1	V1	3,00	1,000	4,10	0,978	3,80	0,969	5,01	1,000
P2	V2	8,00	1,000	7,11	1,002	7,21	0,971	7,78	1,022
P3	V3	9,00	1,010	8,30	1,020	8,14	1,031	9,17	1,025
P4	V4	1,40	1,000	1,44	0,982	0,92	0,963	1,40	0,986
P5	V5	1,50	1,000	1,65	0,992	1,46	1,017	1,70	1,012
P6	V6	2,00	1,000	2,79	1,043	2,69	0,978	2,11	0,995
P7	V7	0,00	1,000	0,00	0,999	0,00	0,999	0,00	1,000
P8	V8	7,00	1,020	7,09	1,000	6,97	0,972	6,17	1,007
P9	V9	3,00	1,010	2,61	1,021	2,51	1,002	3,06	1,021
P10	V10	4,00	1,020	3,58	1,031	3,23	1,018	3,68	1,017
P11	V11	2,00	1,020	3,75	1,003	3,23	1,024	5,32	0,989
P12	V12	3,00	1,000	2,66	0,996	2,87	0,993	2,92	0,990
P13	V13	8,00	1,020	8,06	0,999	7,68	0,963	7,87	1,012
P14	V14	11,00	1,020	8,99	0,999	11,52	0,978	10,02	1,001
P15	V15	11,50	1,020	9,56	1,010	6,53	0,992	7,18	0,961
P16	V16	12,00	1,020	8,31	1,004	9,48	1,020	9,90	1,005
P17	V17	7,00	1,020	6,44	0,975	9,76	1,048	6,78	1,014
P18	V18	7,00	1,020	7,46	1,011	5,53	1,026	7,04	1,006
P19	V19	7,00	1,000	6,21	0,968	4,89	0,971	5,46	0,980
P20	V20	9,50	1,020	7,89	1,010	7,67	1,019	8,92	1,014
P21	V21	0,50	1,010	0,47	0,999	0,52	1,006	0,52	0,999
P22	V22	2,30	1,000	2,21	0,992	2,32	0,973	2,30	0,987
P23	V23	0,50	1,000	0,63	0,993	0,81	0,993	0,70	0,985
$\Delta_{ponto}(\underline{x})$		0,00		4,1224		5,1680		4,5391	
$\Delta_{rest}(\underline{x})$		1282,52		0,1633		0,3499		0,2524	

Ao comparar os métodos pela agregação de objetivos, ou seja, pela minimização da soma das funções objetivo, como foi feito na otimização mono-objetivo em [8], obtém-se os resultados exibidos abaixo, na Tabela 12. Para os métodos multiobjetivos são informados o valor mínimo, máximo e médio da soma das funções objetivo (e as parcelas que compõem essa soma) entre os indivíduos selecionados nas Tabelas 9 e 10, ou seja, os resultados com menor distância euclidiana em relação à origem de cada uma das 10 execuções de cada método. Também é comparado o tempo de execução de cada método na Tabela 13.

Tabela 12 – Comparação de objetivos entre os vieses multi e mono-objetivo (I1)

Simulação		$\Delta_{ponto}(\underline{x}) + \Delta_{rest}(\underline{x})$	
		$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$
NSGA-II	Mínimo	4,2786	
		4,1234	0,1552
	Máximo	4,3204	
4,1250		0,1954	
	Média	4,2965	
MOEPSO	Mínimo	5,5149	
		5,1690	0,3459
	Máximo	5,5599	
5,1683		0,3915	
	Média	5,5374	
AG	Mínimo	4,7915	
		4,5391	0,2524
	Máximo	7,3049	
6,8824		0,4225	
	Média	5,7012	

Tabela 13 – Comparação de tempo entre os vieses multi e mono-objetivo (I1)

Tempo (h)	Método de Otimização		
	NSGA-II	MOEPSO	AG
Mínimo	1,1562	1,0011	1,0205
Máximo	1,1979	1,0487	1,0976
Média	1,1782	1,0297	1,0656

Analisando a Tabela 12, fica nítida a superioridade do NSGA-II, apresentando um desempenho superior nas duas funções objetivo avaliadas. Mesmo ao avaliar pela minimização da soma das funções objetivo, para o qual o AG foi especificamente projetado, o NSGA-II obteve o melhor desempenho, tanto na melhor solução quanto na média, ou seja, é a heurística de otimização que apresenta os melhores e mais consistentes resultados.

Quanto ao MOEPSO, na avaliação das melhores soluções foi dominado por todas as outras heurísticas avaliadas, entretanto na avaliação da minimização da soma das funções objetivo obteve um desempenho superior ao AG na média, o que significa que a otimização multiobjetivo é superior à otimização mono-objetivo mesmo avaliando sob uma ótica mono-objetiva.

Quanto à duração das simulações, o MOEPSO apresentou um desempenho sensivelmente melhor em comparação aos outros métodos testados, o que demonstra que se trata de um método promissor, podendo com alguns ajustes alcançar resultados melhores em um tempo menor.

Para contabilizar o número de violações de limites operativos ocorridas, somadas nas cinco contingências da lista mais o caso base, na execução de cada meta-heurística multiobjetivo foi utilizada a equação (7.1), que não foi incluída como uma função objetivo, ou seja, a otimização não se pautou na redução da quantidade de violações, mas sim na redução da severidade das violações encontradas, sendo preferíveis várias violações de severidade muito baixa a uma única violação de alta severidade. Ainda assim, a quantidade de violações ocorridas segue sendo um dado importante na avaliação do comportamento de sistema de potência. A Tabela 14 exhibe esses dados.

Tabela 14 – Contabilização do número de violações para cada meta-heurística (I1)

Simulação	NSGA-II	MOEPSO
S1	13	29
S2	13	30
S3	15	27
S4	12	29
S5	15	27
S6	13	27
S7	12	27
S8	14	28
S9	15	27
S10	12	30
Mínimo	12	27
Máximo	15	30
Média	13,400	28,100
Desv. Pad	1,2649	1,2867

Da Tabela 14 observa-se que as simulações do MOEPSO têm, em média, muito mais violações de limites operativos do que as simulações do NSGA-II, o que mostra que o MOEPSO necessitou de mais violações para “espalhar” os seus altos valores da função objetivo $\Delta_{rest}(\underline{x})$, ou seja, o seu alto valor de severidade de violações foi distribuído em várias violações de severidade muito pequena, que o sistema de potência pode suportar sem entrar em colapso, mostrando o acerto na implementação desta função objetivo.

Entretanto, a quantidade de violações de limites operativos ainda é um problema, que foi parcialmente contornado nas simulações do NSGA-II, que em média obteve menos da metade das violações retornadas pelo MOEPSO, além de um desempenho melhor na avaliação da função objetivo $\Delta_{rest}(\underline{x})$, ou seja, necessitou de menos violações de limites operativos para pulverizar seu $\Delta_{rest}(\underline{x})$, mostrando que a função objetivo para reduzir a severidade das violações também influencia no próprio número de violações ocorridas.

Por fim, será visto como a função objetivo $\Delta_{rest}(\underline{x})$ e a contabilização do número de violações se comportam a cada caso de contingência e no caso base, para cada despacho retornado pelas meta-heurísticas multiobjetivo. Trata-se de uma análise importante para verificar quais contingências têm maior impacto na avaliação da segurança do sistema de potência e assim futuramente definir estratégias para contornar eventuais problemas, assim como também verificar quais contingências acumulam o maior número de violações de limites operativos. Também serão fornecidos os valores mínimo, máximo, médio e desvio padrão para cada contingência, de modo a ter um comportamento estatístico definido para cada contingência avaliada, além do caso base (rede sem contingências). Seguem os dados nas Tabelas 15 e 16.

Tabela 15 – Número de violações por meta-heurística separados por contingência (II)

Técnica	Simulação	Número de Violações de Limites Operativos					
		Base	Cont. 1	Cont. 2	Cont. 3	Cont. 4	Cont. 5
NSGA-II	S1	0	4	3	2	2	2
	S2	0	4	3	2	2	2
	S3	1	5	3	2	2	2
	S4	0	4	2	2	2	2
	S5	1	5	3	2	2	2
	S6	0	4	3	2	2	2
	S7	0	4	2	2	2	2
	S8	0	4	3	2	3	2
	S9	1	5	3	2	2	2
	S10	0	4	2	2	2	2
Mínimo		0	4	2	2	2	2
Máximo		1	5	3	2	3	2
Média		0,3000	4,3000	2,7000	2,0000	2,1000	2,0000
Desv. Pad		0,4831	0,4831	0,4831	0,0000	0,3162	0,0000
MOEPSO	S1	1	9	6	5	4	4
	S2	0	9	6	6	5	4
	S3	0	8	5	5	4	4
	S4	0	9	6	5	5	4
	S5	0	8	5	5	4	5
	S6	1	8	5	5	4	4
	S7	1	8	5	5	4	4
	S8	0	9	6	5	4	4
	S9	1	8	5	5	4	4
	S10	0	9	6	6	4	5
Mínimo		0	8	5	5	4	4
Máximo		1	9	6	6	5	5
Média		0,4000	8,5000	5,5000	5,3000	4,2000	4,2000
Desv. Pad		0,5164	0,5270	0,5270	0,4830	0,4216	0,4216

Tabela 16 – Violação percentual por meta-heurística separados por contingência (II)

Técnica	Simulação	$\Delta_{rest}(x)$					
		Base	Cont. 1	Cont. 2	Cont. 3	Cont. 4	Cont. 5
NSGA-II	S1	0	0,0503	0,0329	0,0304	0,0251	0,0247
	S2	0	0,0539	0,0352	0,0326	0,0269	0,0265
	S3	0,0126	0,0542	0,0354	0,0328	0,0270	0,0266
	S4	0	0,0499	0,0326	0,0302	0,0249	0,0245
	S5	0,0130	0,0562	0,0367	0,0339	0,0280	0,0276
	S6	0	0,0502	0,0328	0,0303	0,0250	0,0247
	S7	0	0,0478	0,0312	0,0289	0,0238	0,0235
	S8	0	0,0547	0,0357	0,0331	0,0272	0,0269
	S9	0,0127	0,0543	0,0361	0,0330	0,0276	0,0265
	S10	0	0,0486	0,0317	0,0294	0,0242	0,0239
Mínimo		0	0,0478	0,0312	0,0289	0,0238	0,0235
Máximo		0,0130	0,0562	0,0367	0,0339	0,0280	0,0276
Média		0,0038	0,0520	0,0340	0,0315	0,0259	0,0256
Desv. Pad		0,0062	0,0030	0,0019	0,0018	0,0015	0,0015
MOEPSO	S1	0,0131	0,1133	0,0740	0,0685	0,0564	0,0556
	S2	0	0,1206	0,0788	0,0729	0,0601	0,0592
	S3	0	0,1078	0,0704	0,0651	0,0537	0,0529
	S4	0	0,1179	0,0770	0,0713	0,0588	0,0579
	S5	0	0,1065	0,0696	0,0644	0,0531	0,0523
	S6	0,0132	0,1057	0,0691	0,0639	0,0527	0,0519
	S7	0,0131	0,1049	0,0685	0,0634	0,0522	0,0515
	S8	0	0,1134	0,0741	0,0686	0,0565	0,0557
	S9	0,0131	0,1049	0,0686	0,0634	0,0523	0,0516
	S10	0	0,1200	0,0784	0,0725	0,0598	0,0589
Mínimo		0	0,1049	0,0685	0,0634	0,0522	0,0515
Máximo		0,0132	0,1206	0,0788	0,0729	0,0601	0,0592
Média		0,0053	0,1115	0,0728	0,0674	0,0556	0,0548
Desv. Pad		0,0068	0,0063	0,0041	0,0038	0,0032	0,0031

Da Tabela 15 percebe-se que a maior parte das violações, para todas as simulações de ambas as meta-heurísticas, está concentrada na contingência 1, que corresponde à linha de transmissão Segredo-Areia, que possui o maior carregamento do sistema de potência para o despacho previamente especificado e provou também ser a contingência com o maior percentual de severidade para todas as simulações de ambas as meta-heurísticas, tal como mostrado na Tabela 16. Também é possível notar a tendência das heurísticas em “distribuir” as violações de limites e a sua severidade percentual ao longo das cinco contingências de acordo com o carregamento das linhas, mostrando que quanto maior o carregamento da linha que falha mais difícil se torna evitar a ocorrência de violações em outros pontos da rede.

Mesmo assim, ainda houveram violações no caso base (rede sem contingências) em algumas simulações de ambas as heurísticas, com cada uma dessas simulações atingindo uma

violação de limite operativo na avaliação sem falhas no sistema. A ferramenta de fluxo de potência implementada para este problema está munida de controle de tensão nas barras e de geração de reativo, portanto as violações ocorridas para o caso base são de fluxo de potência nos ramos. Porém, como observado na Tabela 16, a violação de maior severidade ocorrida no caso base, dentre todas as simulações, ficou apenas 1,32% além do limite estabelecido, ou seja, uma violação de pequena magnitude. Em todas as simulações em que ocorreu essa violação de limite operativo no caso base, foi verificado que ela ocorreu na linha de transmissão S. Santiago (1060) - S. Caxias (897), que possui uma capacidade de carregamento emergencial de cerca de 13% acima do carregamento nominal, ou seja, trata-se de uma violação que não causaria problemas na rede elétrica.

O controle de tensão e de geração de reativo presente no fluxo de potência preveniu violações de tensão e reativo no caso base, entretanto a avaliação das contingências não contou com esse recurso, que não está presente no método de análise de contingências via Z_{barra} , desse modo ocorreram diversas violações dessa natureza no estudo de cada contingência. Na verdade, a imensa maioria das violações ocorridas nas contingências, em todas as simulações de ambas as meta-heurísticas, foram de tensão nas barras. Apenas na contingência 2 as simulações registraram uma violação de fluxo de potência em uma linha de transmissão, mais precisamente na linha Ibiúna (122) - Bateias (895). Entretanto, contabilizando todas as simulações essa violação atingiu uma severidade máxima de 2% de violação do limite operativo, sendo que essa linha possui um carregamento emergencial de 73% acima do carregamento nominal, não sendo assim uma violação problemática do ponto de vista da continuidade da transmissão. Quanto às violações de tensão, todas elas mantiveram-se num patamar de severidade inferior a 1,7% em todas as simulações realizadas, sendo que, de acordo com [3], uma tensão emergencial que não comprometeria o funcionamento do sistema corresponderia a uma violação de até 5% do limite operativo, tanto superior quanto inferior. Assim, as violações de tensão detectadas não causariam problemas na rede. Não foram detectadas violações de geração de reativo em nenhuma das simulações.

Quanto às meta-heurísticas, fica nítida nessa análise a superioridade do NSGA-II sobre o MOEPSO, tanto na menor quantidade de violações detectadas quanto na menor severidade acumulada dessas violações detectadas. Entretanto, tomando cada violação de cada simulação isoladamente, observou-se que ambas as técnicas tinham violações nos mesmos patamares de severidade, ou seja, o número de violações ocorridas é decisivo para um bom desempenho da meta-heurística na função objetivo $\Delta_{rest}(\underline{x})$.

8.4. SEGUNDA IMPLEMENTAÇÃO (I2)

Nas Figuras 16 e 17, estão as frentes de Pareto retornadas pelo NSGA-II e MOEPSO.

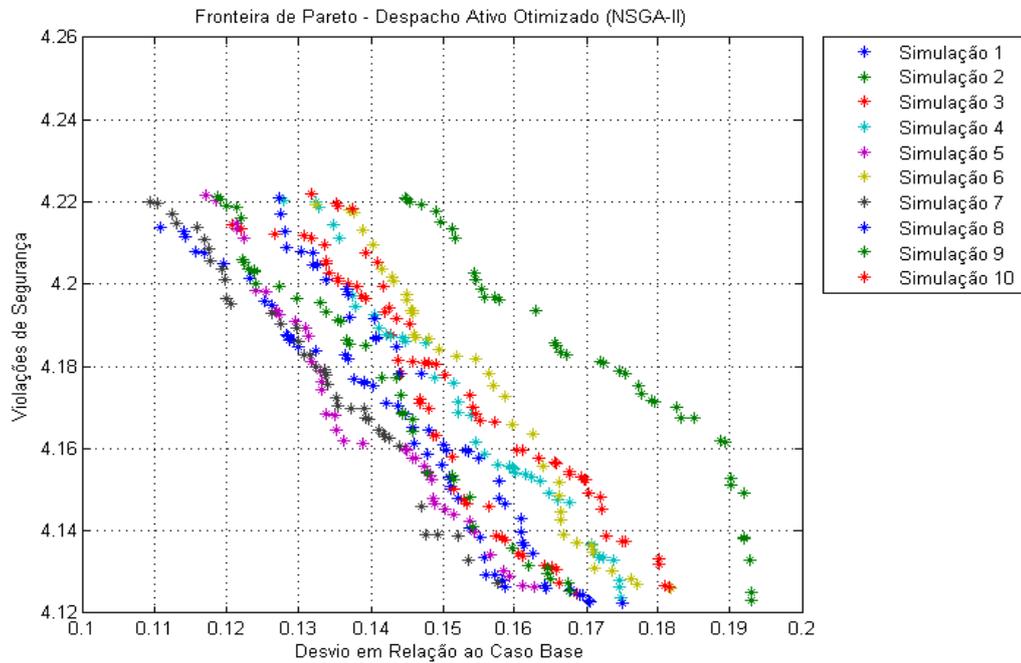


Figura 16 – Fronteiras de Pareto retornadas pela execução do NSGA-II (I2)

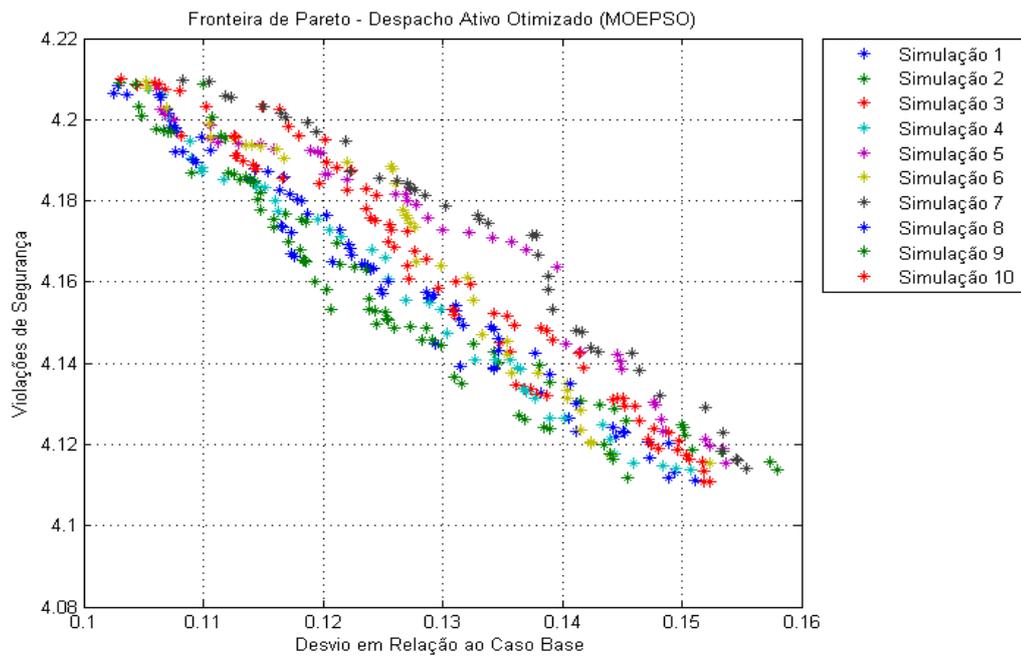


Figura 17 – Fronteiras de Pareto retornadas pela execução do MOEPSO (I2)

As 10 execuções do NSGA-II e do MOEPSO duraram, somadas, aproximadamente 9,85 horas e 8,58 horas, respectivamente. Na Figura 16, não há uma definição de qual é a melhor frente de Pareto encontrada, devido à boa convergência do algoritmo. O mesmo ocorre na Figura 17, demonstrando a eficiência do refinamento colocado no algoritmo do FPORS na segunda implementação, melhorando a convergência para ambos os métodos. A partir daí, é feita uma comparação de dominância entre os dois métodos, de modo a verificar qual deles possui o melhor desempenho. Na Figura 18, os conjuntos de soluções do NSGA-II estão em vermelho e os do MOEPSO estão em azul.

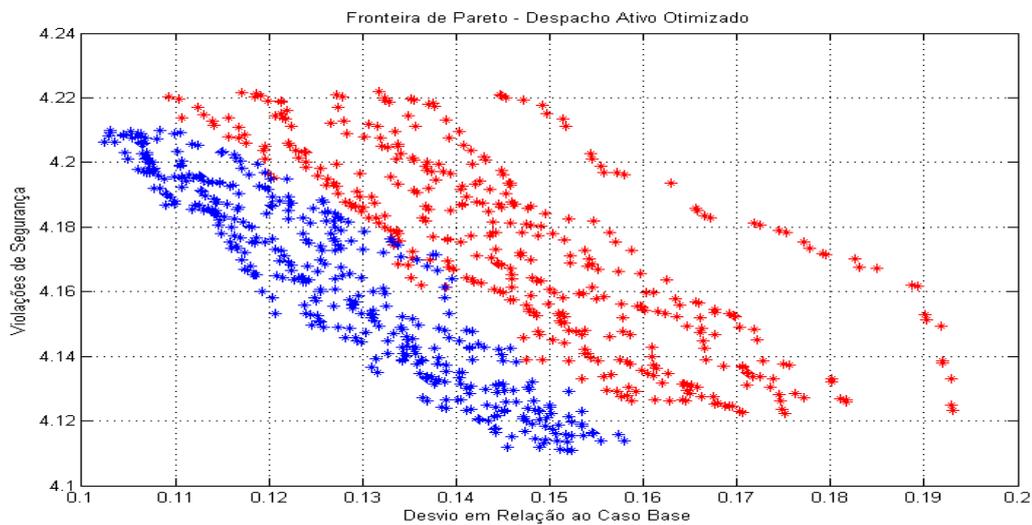


Figura 18 – Comparação entre as frentes de Pareto de cada método (I2)

Na Figura 18, nota-se que as soluções retornadas pelo MOEPSO (em azul) dominam a maioria das soluções retornadas pelo NSGA-II (em vermelho), sendo que todas as soluções MOEPSO dominam pelo menos uma solução NSGA-II, havendo inclusive soluções MOEPSO que dominam todas as soluções NSGA-II. Portanto, no que tange à otimização multiobjetivo, o método MOEPSO se mostrou bem superior ao NSGA-II nesta segunda análise.

No Apêndice A estão os indivíduos de menor distância euclidiana em relação à origem de cada frente de Pareto retornada pelas 10 simulações (S1 até S10) de cada método, e nas Tabelas 17 e 18 estão os valores da função objetivo e do tempo de simulação para cada um dos melhores despachos de cada método. As variáveis P1 até P23 representam o despacho de potência ativa das unidades geradoras e estão representadas em p.u, enquanto as variáveis de V1 até V23 são as tensões das unidades geradoras, também representadas em p.u.

Tabela 17 – Valores de função objetivo e tempo de simulação para o NSGA-II (I2)

Simulação	Tempo (h)	Dist. Eucl.	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	Agregação
S1	0,9799	4,1294	4,1263	0,1588	4,2851
S2	0,9993	4,1277	4,1232	0,1930	4,3162
S3	0,9945	4,1281	4,1246	0,1688	4,2934
S4	0,9573	4,1274	4,1237	0,1748	4,2985
S5	0,9827	4,1295	4,1263	0,1628	4,2891
S6	0,9832	4,1299	4,1259	0,1817	4,3076
S7	0,9999	4,1304	4,1274	0,1576	4,2850
S8	0,9793	4,1261	4,1223	0,1751	4,2974
S9	0,9906	4,1286	4,1252	0,1676	4,2928
S10	0,9834	4,1304	4,1264	0,1816	4,3080
Mínimo	0,9573	4,1261	4,1223	0,1576	4,2850
Máximo	0,9999	4,1304	4,1274	0,1930	4,3162
Média	0,9850	4,1287	4,1251	0,1722	4,2973
Desv. Pad	0,0124	0,0014	0,0016	0,0113	0,0104

Da análise da Tabela 17, nota-se que na função objetivo $\Delta_{ponto}(\underline{x})$, que avalia o desvio percentual do despacho em relação à referência, o menor valor foi obtido por S8, enquanto o maior valor foi obtido por S7, sendo uma variável com baixo desvio padrão avaliado para o NSGA-II, o que indica que as simulações são muito parecidas sob esse ponto de vista. Para $\Delta_{rest}(\underline{x})$, que avalia a severidade das violações, o menor valor foi obtido por S7 e o maior valor por S2, entretanto obteve um desvio padrão bem mais alto, sendo possível priorizar a segurança no momento de escolher o ponto de operação ideal, podendo optar por um custo de segurança mais baixo sabendo que o desvio para a referência será basicamente muito parecido qualquer que seja a escolha.

Em relação à agregação de objetivos, o menor valor foi retornado por S7 enquanto o maior valor foi retornado por S2, com uma forte influência de $\Delta_{rest}(\underline{x})$ demonstrada pelo alto desvio padrão, enquanto que para a distância euclidiana o menor valor foi retornado por S8 e o maior por S10, com forte influência de $\Delta_{ponto}(\underline{x})$ demonstrada pelo baixo desvio padrão. Quanto ao tempo, a menor marca foi de S4 e a maior marca de S7, também com um alto desvio padrão, o que mostra uma certa variação entre a duração de cada simulação.

Da bateria de simulações do NSGA-II para a segunda implementação, conclui-se que o melhor resultado do ponto de vista multiobjetivo (distância euclidiana) veio de S8, enquanto que do ponto de vista mono-objetivo (agregação de objetivos) o melhor resultado veio de S7, o que mostra de novo o quanto uma abordagem distinta de um mesmo problema pode influenciar no resultado final, mesmo considerando as mesmas funções objetivo.

Tabela 18 – Valores de função objetivo e tempo de simulação para o MOEPSO (I2)

Simulação	Tempo (h)	Dist. Eucl.	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	Agregação
S1	0,8800	4,1159	4,1132	0,1494	4,2626
S2	0,8329	4,1170	4,1139	0,1580	4,2719
S3	0,8704	4,1137	4,1109	0,1518	4,2627
S4	0,8405	4,1167	4,1139	0,1508	4,2647
S5	0,8357	4,1184	4,1155	0,1537	4,2692
S6	0,8538	4,1182	4,1154	0,1523	4,2678
S7	0,8615	4,1169	4,1140	0,1554	4,2694
S8	0,8675	4,1140	4,1112	0,1511	4,2623
S9	0,8647	4,1145	4,1119	0,1455	4,2574
S10	0,8761	4,1138	4,1109	0,1524	4,2633
Mínimo	0,8329	4,1137	4,1109	0,1455	4,2574
Máximo	0,8800	4,1184	4,1155	0,1580	4,2719
Média	0,8583	4,1159	4,1131	0,1520	4,2651
Desv. Pad	0,0169	0,0018	0,0017	0,0034	0,0043

Da análise da Tabela 18, nota-se que na função objetivo $\Delta_{ponto}(\underline{x})$, que avalia o desvio percentual do despacho em relação à referência, o menor valor foi obtido por S10, enquanto o maior valor foi obtido por S5, sendo uma variável com baixo desvio padrão avaliado para o MOEPSO, o que indica que as simulações são muito parecidas sob esse ponto de vista. Para $\Delta_{rest}(\underline{x})$, que avalia a severidade das violações, o menor valor foi obtido por S9 e o maior valor por S2, entretanto, ao contrário do verificado para o NSGA-II, obteve um baixo desvio padrão para a variável, característica que lhe confere, juntamente com a baixa variabilidade de $\Delta_{ponto}(\underline{x})$, um maior nível de convergência em comparação à simulação com o NSGA-II.

Em relação à agregação de objetivos, o menor valor foi retornado por S9 enquanto o maior valor foi retornado por S2, com uma forte influência de $\Delta_{rest}(\underline{x})$ demonstrada pelo desvio padrão levemente alterado, enquanto que para a distância euclidiana o menor valor foi retornado por S3 e o maior por S5, com forte influência de $\Delta_{ponto}(\underline{x})$ demonstrada pelo baixo desvio padrão. Quanto ao tempo, a menor marca foi de S2 e a maior marca de S1, também com um alto desvio padrão, o que mostra uma certa variação entre a duração de cada simulação.

Da bateria de simulações do MOEPSO para a segunda implementação, conclui-se que o melhor resultado do ponto de vista multiobjetivo (distância euclidiana) veio de S3, enquanto que do ponto de vista mono-objetivo (agregação de objetivos) o melhor resultado veio de S9, o que mostra de novo o quanto uma abordagem distinta de um mesmo problema pode influenciar no resultado final, mesmo considerando as mesmas funções objetivo.

O próximo passo é a comparação entre as abordagens mono-objetivo e multiobjetivo. Para a Tabela 19 são escolhidos, além do despacho do caso base, os despachos com a menor distância euclidiana para as simulações do NSGA-II e MOEPSO e o despacho retornado pelo AG em [8]. O despacho escolhido para representar o NSGA-II foi retornado pela simulação S8, enquanto o despacho retornado pela simulação S3 irá representar o MOEPSO.

Tabela 19 – Despachos do caso base e obtidos pelos métodos de otimização (I2)

Variável		Caso Base		NSGA-II		MOEPSO		AG	
P1	V1	3,00	1,000	3,93	0,995	4,01	1,003	5,01	1,000
P2	V2	8,00	1,000	7,22	0,996	7,23	0,995	7,78	1,022
P3	V3	9,00	1,010	8,30	1,033	8,41	1,028	9,17	1,025
P4	V4	1,40	1,000	1,47	0,995	1,60	0,974	1,40	0,986
P5	V5	1,50	1,000	1,83	0,992	2,00	0,992	1,70	1,012
P6	V6	2,00	1,000	2,81	1,036	2,76	1,017	2,11	0,995
P7	V7	0,00	1,000	0,00	0,997	0,00	1,003	0,00	1,000
P8	V8	7,00	1,020	7,67	0,987	7,05	0,983	6,17	1,007
P9	V9	3,00	1,010	2,61	1,021	2,67	1,020	3,06	1,021
P10	V10	4,00	1,020	3,74	0,997	3,65	1,037	3,68	1,017
P11	V11	2,00	1,020	3,87	1,009	3,84	1,007	5,32	0,989
P12	V12	3,00	1,000	2,56	0,992	2,75	0,983	2,92	0,990
P13	V13	8,00	1,020	8,65	0,986	8,31	0,991	7,87	1,012
P14	V14	11,00	1,020	8,95	1,003	8,99	1,001	10,02	1,001
P15	V15	11,50	1,020	9,57	0,998	9,56	1,009	7,18	0,961
P16	V16	12,00	1,020	10,06	1,006	10,46	1,000	9,90	1,005
P17	V17	7,00	1,020	6,45	0,985	6,53	0,975	6,78	1,014
P18	V18	7,00	1,020	7,45	1,012	7,53	1,013	7,04	1,006
P19	V19	7,00	1,000	6,40	0,965	6,34	0,979	5,46	0,980
P20	V20	9,50	1,020	8,52	1,013	7,88	0,994	8,92	1,014
P21	V21	0,50	1,010	0,48	0,988	0,47	0,981	0,52	0,999
P22	V22	2,30	1,000	2,26	1,002	2,25	0,999	2,30	0,987
P23	V23	0,50	1,000	0,62	0,998	0,58	0,997	0,70	0,985
$\Delta_{ponto}(\underline{x})$		0,00		4,1223		4,1109		4,5391	
$\Delta_{rest}(\underline{x})$		1282,52		0,1751		0,1518		0,2524	

Ao comparar os métodos pela agregação de objetivos, ou seja, pela minimização da soma das funções objetivo, como foi feito na otimização mono-objetivo em [8], obtém-se os resultados exibidos abaixo, na Tabela 20. Para os métodos multiobjetivos, são informados os valores mínimo, máximo e médio da soma das funções objetivos (e as parcelas que compõem essa soma) entre os indivíduos selecionados nas Tabelas 17 e 18, ou seja, os resultados com menor distância euclidiana em relação à origem de cada uma das 10 execuções de cada método. Também é comparado o tempo de execução de cada método na Tabela 21.

Tabela 20 – Comparação de objetivos entre os vieses multi e mono-objetivo (I2)

Simulação		$\Delta_{ponto}(\underline{x}) + \Delta_{rest}(\underline{x})$	
		$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$
NSGA-II	Mínimo	4,2850	
		4,1274	0,1576
	Máximo	4,3162	
		4,1232	0,1930
	Média	4,2973	
	MOEPSO	Mínimo	4,2574
4,1119			0,1455
Máximo		4,2719	
		4,1139	0,1580
Média		4,2651	
AG		Mínimo	4,7915
	4,5391		0,2524
	Máximo	7,3049	
		6,8824	0,4225
	Média	5,7012	

Tabela 21 – Comparação de tempo entre os vieses multi e mono-objetivo (I2)

Tempo (h)	Método de Otimização		
	NSGA-II	MOEPSO	AG
Mínimo	0,9573	0,8329	1,0205
Máximo	0,9999	0,8800	1,0976
Média	0,9850	0,8583	1,0656

Da análise da Tabela 20, conclui-se que a heurística de otimização com o melhor desempenho nas simulações deste trabalho foi o MOEPSO, sendo superior tanto no quesito tempo quanto nas funções objetivo, mostrando uma grande melhoria na comparação com os resultados da Tabela 12, onde o MOEPSO já se mostrava promissor no tempo de simulação comparado ao NSGA-II e ao AG, mas ainda não obtinha bons resultados na otimização em si. Essa melhora nos resultados se deve ao novo método de atribuição dos valores de g_{best} e p_{best} implementado, que agora busca os valores com as menores distâncias euclidianas em relação à origem para melhorar a movimentação das partículas em busca do melhor resultado.

O NSGA-II apresentou grande melhoria de tempo entre as simulações desta análise e da anterior, no entanto os resultados mantiveram-se muito semelhantes, o que era esperado, pois não houve modificações no algoritmo do NSGA-II. As duas técnicas multiobjetivo testadas mostraram sensível melhora no tempo de execução na comparação com a primeira implementação, graças ao refinamento CC projetado para a segunda implementação que reduziu o número de iterações necessárias para alcançar o resultado otimizado.

Para contabilizar o número de violações de limites operativos ocorridas, somadas nas cinco contingências da lista mais o caso base, na execução de cada meta-heurística multiobjetivo foi utilizada a equação (7.1), que não foi incluída como uma função objetivo, ou seja, a otimização não se pautou na redução da quantidade de violações, mas sim na redução da severidade das violações encontradas, sendo preferíveis várias violações de severidade muito baixa a uma única violação de alta severidade. Ainda assim, a quantidade de violações ocorridas segue sendo um dado importante na avaliação do comportamento de sistema de potência. A Tabela 22 exhibe esses dados.

Tabela 22 – Contabilização do número de violações para cada meta-heurística (I2)

Simulação	NSGA-II	MOEPSO
S1	12	11
S2	15	12
S3	13	12
S4	13	12
S5	13	12
S6	14	12
S7	12	12
S8	13	12
S9	13	11
S10	14	12
Mínimo	12	11
Máximo	15	12
Média	13	12
Desv. Pad	0,9190	0,4216

Da Tabela 22 observou-se um perfil parecido de número de violações de limites operativos retornados pelas duas meta-heurísticas, tendo o MOEPSO uma quantidade ligeiramente menor de violações, um desempenho muito melhor do que o obtido na primeira implementação, resultado das melhorias implementadas nessa meta-heurística nessa segunda implementação. Até mesmo o NSGA-II, que não sofreu modificações, obteve uma quantidade média de violações ligeiramente menor em comparação à primeira implementação, reflexo do refinamento CC inserido na segunda implementação do FPORS.

Assim como observado na primeira implementação, a redução das violações ocorridas nas simulações das duas técnicas é acompanhada de um melhor desempenho na função objetivo $\Delta_{rest}(\underline{x})$, ou seja, quanto menos violações acontecerem, menor será a severidade de cada violação, corroborando o fato de que a função objetivo para reduzir a severidade das violações também influencia no próprio número de violações ocorridas.

Por fim, será visto como a função objetivo $\Delta_{rest}(\underline{x})$ e a contabilização do número de violações se comportam a cada caso de contingência e no caso base, para cada despacho retornado pelas meta-heurísticas multiobjetivo. Trata-se de uma análise importante para verificar quais contingências têm maior impacto na avaliação da segurança do sistema de potência e assim futuramente definir estratégias para contornar eventuais problemas, assim como também verificar quais contingências acumulam o maior número de violações de limites operativos. Também serão fornecidos os valores mínimo, máximo, médio e desvio padrão para cada contingência, de modo a ter um comportamento estatístico definido para cada contingência avaliada, além do caso base (rede sem contingências). Seguem os dados nas Tabelas 23 e 24.

Tabela 23 – Número de violações por meta-heurística separados por contingência (I2)

Técnica	Simulação	Número de Violações de Limites Operativos					
		Base	Cont. 1	Cont. 2	Cont. 3	Cont. 4	Cont. 5
NSGA-II	S1	0	4	2	2	2	2
	S2	0	5	3	3	2	2
	S3	0	4	3	2	2	2
	S4	0	4	3	2	2	2
	S5	0	4	3	2	2	2
	S6	0	4	3	3	2	2
	S7	0	4	2	2	2	2
	S8	0	4	3	2	2	2
	S9	0	4	3	2	2	2
	S10	0	4	3	3	2	2
Mínimo		0	4	2	2	2	2
Máximo		0	5	3	3	2	2
Média		0,0000	4,1000	2,8000	2,3000	2,0000	2,0000
Desv. Pad		0,0000	0,3162	0,4216	0,4831	0,0000	0,0000
MOEPSO	S1	0	3	2	2	2	2
	S2	0	3	2	3	2	2
	S3	0	4	2	2	2	2
	S4	0	3	3	2	2	2
	S5	0	3	3	2	2	2
	S6	0	3	3	3	2	2
	S7	0	4	2	2	2	2
	S8	0	3	3	2	2	2
	S9	0	3	2	2	2	2
	S10	0	3	3	2	2	2
Mínimo		0	3	2	2	2	2
Máximo		0	4	3	3	2	2
Média		0,0000	3,2000	2,5000	2,2000	2,0000	2,0000
Desv. Pad		0,0000	0,4216	0,5271	0,4216	0,0000	0,0000

Tabela 24 – Violação percentual por meta-heurística separados por contingência (I2)

Técnica	Simulação	$\Delta_{rest}(x)$					
		Base	Cont. 1	Cont. 2	Cont. 3	Cont. 4	Cont. 5
NSGA-II	S1	0,0000	0,0489	0,0320	0,0296	0,0244	0,0240
	S2	0,0000	0,0594	0,0388	0,0359	0,0296	0,0292
	S3	0,0000	0,0520	0,0340	0,0314	0,0259	0,0255
	S4	0,0000	0,0538	0,0352	0,0325	0,0268	0,0264
	S5	0,0000	0,0501	0,0328	0,0303	0,0250	0,0246
	S6	0,0000	0,0560	0,0366	0,0338	0,0279	0,0275
	S7	0,0000	0,0485	0,0317	0,0293	0,0242	0,0238
	S8	0,0000	0,0539	0,0352	0,0326	0,0269	0,0265
	S9	0,0000	0,0516	0,0337	0,0312	0,0257	0,0254
	S10	0,0000	0,0559	0,0365	0,0338	0,0279	0,0275
Mínimo		0,0000	0,0485	0,0317	0,0293	0,0242	0,0238
Máximo		0,0000	0,0594	0,0388	0,0359	0,0296	0,0292
Média		0,0000	0,0530	0,0346	0,0320	0,0264	0,0260
Desv. Pad		0,0000	0,0035	0,0023	0,0021	0,0017	0,0017
MOEPSO	S1	0,0000	0,0460	0,0301	0,0294	0,0229	0,0226
	S2	0,0000	0,0487	0,0318	0,0283	0,0242	0,0239
	S3	0,0000	0,0467	0,0305	0,0281	0,0233	0,0230
	S4	0,0000	0,0464	0,0303	0,0286	0,0231	0,0228
	S5	0,0000	0,0473	0,0309	0,0283	0,0236	0,0233
	S6	0,0000	0,0469	0,0306	0,0289	0,0234	0,0230
	S7	0,0000	0,0479	0,0313	0,0281	0,0238	0,0235
	S8	0,0000	0,0465	0,0304	0,0271	0,0232	0,0229
	S9	0,0000	0,0448	0,0293	0,0284	0,0223	0,0220
	S10	0,0000	0,0469	0,0307	0,0283	0,0234	0,0231
Mínimo		0,0000	0,0448	0,0293	0,0271	0,0223	0,0220
Máximo		0,0000	0,0487	0,0318	0,0294	0,0242	0,0239
Média		0,0000	0,0468	0,0306	0,0284	0,0233	0,0230
Desv. Pad		0,0000	0,0010	0,0007	0,0006	0,0005	0,0005

Assim como na primeira implementação, a maior parte das violações, nas simulações de ambas as meta-heurísticas, está concentrada na contingência 1, que corresponde à linha de transmissão Segredo-Areia, que possui o maior carregamento do sistema de potência para o despacho previamente especificado e provou também ser a contingência com o maior percentual de severidade para todas as simulações de ambas as meta-heurísticas, tal como mostrado na Tabela 24. Também é possível notar a tendência das heurísticas em “distribuir” as violações de limites e a sua severidade percentual ao longo das cinco contingências de acordo com o carregamento das linhas, mostrando que quanto maior o carregamento da linha que falha mais difícil se torna evitar a ocorrência de violações em outros pontos da rede.

Entretanto, ao contrário do que ocorreu na implementação sem o refinamento CC, dessa vez não ocorreu nenhuma violação no caso base em nenhuma simulação das duas

técnicas evolutivas multiobjetivo. Um reflexo direto do efeito do refinamento dos despachos de potência ativa da solução inicial, que por ser baseado em fluxo de potência CC busca reduzir apenas violações de fluxo de potência nas linhas, permitindo que todas as simulações encontrassem soluções perfeitas do ponto de vista do caso base. Também fez diferença a melhor característica de convergência da implementação do FPORS com refinamento prévio da solução inicial, demonstrado pelo menor desvio padrão das soluções (Tabelas 17 e 18) que indica que os resultados das diversas simulações realizadas estão mais próximos entre si e convergindo em direção a uma solução ótima, além é claro do controle de tensão nas barras e de geração de reativo inserido na ferramenta de fluxo de potência, que eliminou por si só as violações de tensão e reativo do caso base.

Assim como na primeira implementação, as contingências foram analisadas através do método baseado pela matriz Z_{barra} , que não leva em conta o controle de tensão nas barras e de geração de reativo, sendo assim não foi possível evitar previamente violações dessa natureza que de fato foram a grande maioria das violações registradas para as duas meta-heurísticas. Mais uma semelhança com a implementação sem refinamento inicial foi o fato da única violação de fluxo de potência em uma linha de transmissão ter sido registrado no caso da contingência 2, na linha Ibiúna (122) - Bateias (895), o que provavelmente se deve à proximidade entre a linha defeituosa e a linha na qual foi registrada a violação, que acaba recebendo a maior parte do fluxo que escoava pela linha faltante. Mas de maneira parecida ao ocorrido na implementação anterior, em todas as simulações das duas heurísticas essa violação obteve uma severidade inferior a 1,7%, bastante inferior ao carregamento emergencial da linha (73% acima do carregamento máximo nominal). As violações de tensão registradas também mantiveram-se num patamar abaixo de 1,7%, inferior à tolerância de 5% de tensão emergencial descrita em [3], não sendo detectadas violações de geração de reativos.

Quanto às meta-heurísticas, fica nítida nessa análise a superioridade do MOEPSO sobre o NSGA-II, tanto na menor quantidade de violações detectadas quanto na menor severidade acumulada dessas violações detectadas. Percebeu-se uma grande melhora de desempenho do MOEPSO com as melhorias específicas implementadas na meta-heurística, fazendo com que a mesma superasse o NSGA-II (que não sofreu modificações) depois de ter tido um desempenho muito pior na primeira implementação. Entretanto, tomando cada violação de cada simulação isoladamente, observou-se que ambas as técnicas tinham violações nos mesmos patamares de severidade, ou seja, o número de violações ocorridas é decisivo para um bom desempenho da meta-heurística na função objetivo $\Delta_{rest}(\underline{x})$.

9. CONCLUSÕES

9.1. CONSIDERAÇÕES SOBRE OS OBJETIVOS

Este trabalho teve por objetivo o estudo de métodos de otimização natural multiobjetivo para obtenção do despacho seguro de sistemas elétricos de potência, e a sua comparação com a abordagem mono-objetivo relatada em [8]. Considerando somente restrições de segurança estática (tensões em barramentos, fluxos nas linhas, limites de potência ativa e reativa dos geradores), foram testadas duas técnicas: NSGA-II e MOEPSO.

As funções objetivo avaliadas consistiam nos somatórios do desvio percentual das restrições violadas e do desvio percentual do despacho encontrado em relação ao despacho de referência, sendo que este último representa o viés econômico da otimização, partindo-se da premissa de que o ponto de operação inicial do caso base (rede completa, sem contingências) foi previamente especificado via despacho econômico, ou seja, foi escolhido o despacho de menor custo dentre os possíveis. Em outras palavras, a metodologia visa fornecer as alterações mínimas a serem realizadas em um dado ponto de operação para torná-lo seguro à luz de uma dada lista de contingências. Para ambas as técnicas estudadas, esse objetivo foi atingido, ocorrendo apenas violações com severidades de pequena magnitude que não afetariam significativamente o sistema de potência, mas que podem ser solucionadas com a instalação de reatores shunt, no caso de violações de tensão nas barras, ou com redespacho de potência ativa, no caso de sobrecarga nas linhas.

Primeiramente, ao se analisar o somatório dos desvios das variáveis monitoradas em relação aos seus limites para o despacho do caso base, vê-se que o mesmo possui um altíssimo custo para a referida função objetivo, observando que o ponto de operação em questão foi avaliado apenas do ponto de vista da segurança operativa, pois não há desvio ativo uma vez que se trata do próprio despacho de referência, logo é necessário buscar pontos de operação melhores do ponto de vista de ambas as funções objetivo, constituindo assim motivação para o trabalho.

O próximo passo foi verificar qual das heurísticas de otimização testadas consegue fornecer a melhor solução. Para tanto, foram realizadas duas implementações distintas do programa de FPORS: a primeira consistia em uma otimização sem qualquer refinamento prévio das soluções iniciais aleatoriamente gerada, ou seja, tendo como ponto de partida um conjunto de soluções iniciais potencialmente ruim e que demandaria grande esforço das meta-heurísticas para chegar ao conjunto Pareto-ótimo. Já a segunda implementação refina

previamente a solução inicial, de modo a fornecer um ponto de partida melhorado para o programa de FPORS convergir mais rapidamente para o conjunto Pareto-ótimo. Como o refinador é baseado em fluxo de potência CC, que é bem mais rápido que o fluxo de potência completo, sua utilização não influi significativamente no tempo de execução do FPORS.

Na primeira implementação, os resultados mostraram que o algoritmo NSGA-II foi quem saiu-se melhor, uma vez que é fácil verificar que a maioria das soluções obtidas pelo mesmo domina as soluções obtidas pelo MOEPSO, além de ser superior ao AG mesmo no quesito agregação de objetivos, mostrando a eficácia superior da abordagem multiobjetivo. Entretanto, embora não obtivesse bons resultados na otimização em si, o MOEPSO se mostrava como uma alternativa promissora devido ao fato de ser o método de execução mais rápida dentre os testados, necessitando apenas de ajustes no algoritmo, o que foi feito na segunda análise.

Na segunda implementação, além da melhoria no algoritmo do MOEPSO, devido ao novo método de atribuição dos valores de g_{best} e p_{best} implementado, que agora busca os valores com as menores distâncias euclidianas em relação à origem para melhorar a movimentação das partículas em busca do melhor resultado, também foi implementado um refinamento prévio do despacho de potência ativa no próprio FPORS, o que ocasionou uma redução no tempo de execução das simulações de ambas as heurísticas multiobjetivo. Na avaliação das fronteiras de Pareto, para comparar as heurísticas multiobjetivo, o MOEPSO foi claramente superior, com a boa parte dos seus conjuntos ótimos dominando todas as fronteiras retornadas pelo NSGA-II. Quanto à comparação com a abordagem mono-objetivo, tanto MOEPSO quanto NSGA-II foram superiores ao AG, sendo que o MOEPSO foi a técnica de mais destaque, sendo superior às demais em todos os quesitos, desde a agregação de objetivos até os objetivos tomados individualmente, possuindo ainda menor tempo de simulação. O NSGA-II também obteve bom desempenho e foi superior ao AG em todos os critérios, tendo resultados bem próximos ao MOEPSO.

Portanto, demonstrou-se que a abordagem multiobjetiva via meta-heurísticas evolutivas é uma alternativa extremamente promissora para resolver o problema abordado neste trabalho, sendo plenamente superior à abordagem mono-objetiva na tarefa de conciliar objetivos conflitantes, sendo o MOEPSO (após as modificações da segunda implementação) a heurística mais indicada para desenvolver uma ferramenta computacional de análise de sistemas de potência em regime permanente capaz de definir um conjunto de ações de controle que eliminem as violações operativas de uma rede elétrica, frente a uma lista de

contingências pré-estabelecida, ao mesmo tempo em que busca não se afastar demais do despacho base previamente estabelecido para o referido sistema de potência.

O ponto negativo fica por conta do elevado custo computacional para a aplicação destes métodos em ambiente de operação, uma vez que foram necessários cerca de uma hora para cada execução das técnicas na primeira implementação e cerca de 50 minutos para a segunda implementação. Assim, são necessários métodos para aceleração do processo de busca, seja pela identificação de regiões promissoras ou pela redução do espaço de busca por meio de métodos de seleção e/ou transformação de variáveis.

9.2. PROPOSTAS PARA TRABALHOS FUTUROS

Uma sugestão imperativa é fazer esse estudo de análise de segurança também para o regime dinâmico, pois muitas das perturbações que acometem um sistema de potência têm suas consequências mais graves antes da estabilização dos estados transitórios, podendo provocar um colapso na rede elétrica antes mesmo do equilíbrio entre esses estados. O estudo desse fenômeno é essencial para mensurar o quão seguro é o sistema elétrico em questão e o mesmo não é contemplado na análise de segurança estática feita nesse trabalho.

Outra sugestão fica por conta da seleção das contingências para as quais o sistema deve estar preparado. Neste trabalho, optou-se por selecionar as linhas mais carregadas do caso base com o ponto de operação inicial utilizado originalmente em [124], porém é recomendável fazer a análise de sensibilidade da rede à queda das linhas, via critério N-1, e então selecionar aquelas que têm o maior impacto no sistema. É um estudo profundo e complexo, que exigirá grande esforço tanto do pesquisador quanto das ferramentas computacionais utilizadas.

Ainda na seleção das contingências, seria muito interessante também incluir a queda de outros equipamentos de alta tensão, principalmente geradores, cuja queda costuma ter mais impacto na operação do sistema de potência do que as linhas de transmissão. É importante também fazer um estudo sobre a confiabilidade desses equipamentos que compõem a rede elétrica, através do qual pode-se descobrir quais serão as contingências mais comuns do sistema de potência.

Uma sugestão para reduzir ainda mais o tempo de execução da simulação é implementar os algoritmos numa linguagem de programação compilada, de execução mais rápida, o que também conferiria independência para a ferramenta computacional desenvolvida, que se desprenderia da plataforma MATLAB e de sua dispendiosa licença.

Entretanto, o MATLAB ainda não seria totalmente abandonado, uma vez que poderia ser elaborada uma *toolbox* da ferramenta desenvolvida, para fins acadêmicos. Caso a ferramenta seja utilizada para o estudo de sistemas de grande porte, uma opção a ser considerada é o uso de computação paralela, para aumentar a quantidade de processamento e tornar a execução das simulações mais rápida.

O próprio refinador baseado em fluxo de potência linearizado pode se converter num programa de FPORS independente, uma vez que em diversas ocasiões o operador não está interessado em controlar as tensões dos geradores, mas tão somente em quanto de potência ativa terão que despachar caso ocorra alguma contingência. Outra medida seria considerar o número de violações ocorridas como uma função objetivo a minimizar, juntamente com a severidade das mesmas, uma vez que verificou-se haver uma relação direta entre quantidade de violações e suas severidades.

Por fim, seria interessante testar outras meta-heurísticas para a resolução do problema proposto nesse trabalho, tais como Recozimento Simulado (RS), Algoritmo de Colônia de Abelhas (ACA), Algoritmo de Evolução Diferencial (AED), Algoritmo de Busca Gravitacional (ABG), dentre muitas outras técnicas que são citadas na extensa revisão bibliográfica realizada no Capítulo 2 da presente dissertação, assim como implementar hibridizações para melhora do desempenho, que podem tanto combinar duas ou mais técnicas evolutivas quanto combinar um Algoritmo Evolutivo (AE) com alguma das técnicas tradicionais (como o Método dos Pontos Interiores, por exemplo) ou até mesmo com técnicas de *Machine Learning*, como as Redes Neurais Artificiais (RNA).

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ONS, Operador Nacional do Sistema Elétrico. “Planejamento Estratégico - Missão”. Acessado em 13/06/2016. [Online]. Disponível: http://www.ons.org.br/institucional_linguas/orientacoes_estrategicas.aspx.
- [2] BALU, N., BERTRAM, T., BOSE, A., BRANDWAIN, V., CAULEY, G., CURTICE, D., FOUAD, A., FINK, L., LAUBY, M. WOLLENBERG, B. F. & WRUBEL, J. N. “Online Power System Security Analysis”, *Proceedings of the IEEE*, vol. 80, no. 2, pp. 262-280, 1992.
- [3] ONS, Operador Nacional do Sistema Elétrico. “Diretrizes e Critérios para Estudos Elétricos”, *Procedimentos de Rede*, Submódulo 23.3, Revisão 2.0, Data de Vigência 11/11/2011.
- [4] WOOD, A. J. & WOLLENBERG, B. F. *Power Generation, Operation and Control*, 2 ed., New York, John Wiley & Sons, 1996.
- [5] ABIDO, M. A. “A novel multiobjective evolutionary algorithm for environmental/economic power dispatch”, *Electric Power Systems Research*, vol. 65, no. 1, pp. 71-81.
- [6] DEB, K. *Multi-objective optimization using evolutionary algorithms*. New York, John Wiley & Sons, 2001.
- [7] BARKITZIS, A. G., BISKAS, P. N., ZOUMAS, C. E. & PETRIDIS, V. “Optimal Power Flow by Enhanced Genetic Algorithm”, *IEEE Transactions on Power Systems*, vol. 17, no. 2, pp. 229-236, 2002.
- [8] FERREIRA, V. H., FREIRE, R. C. & DA COSTA, P. R. S. “Otimização Natural como Alternativa para Determinação do Despacho Seguro de Sistemas Elétricos de Potência”, In: *XIX Congresso Brasileiro de Automática (CBA)*, pp. 2110-2117, Campina Grande (PB), Brasil, 2012.
- [9] LIMMER, H. D., “Security Application of On-line Digital Computers”. In: *Proceedings of the Second PSCC*, 1966.
- [10] DY LIACCO, T. E. “The Adaptive Reliability Control System”, *IEEE Trans. Parallel Dist. System*, vol. 86, pp. 517-531, 1967.
- [11] CIHLAR, T. C., WEAR, J. H., EWART, D. N. & KIRCHMAYER, L. K. “Electric Utility System Security”. In: *Proceedings of the American Power Conference*, vol. 31, pp. 891-908, 1969.
- [12] MONTICELLI, A., PEREIRA, M. V. F. & GRANVILLE, S., “Security-Constrained Optimal Power Flow With Post-Contingency Corrective Rescheduling”, *IEEE Transactions on Power System*, vol. PWRS-2, no. 1, pp. 175-182, 1987.

- [13] HARSAN, H., HADJSAID, N. & PRUVOT, P. "Cyclic Security Analysis for Security Constrained Optimal Power Flow", *IEEE Trans. on Power Systems*, vol. 12, no. 2, pp. 948-953, 1997.
- [14] ALVES, A.B. & MONTICELLI, A. "Static Security Analysis Using Pipeline Decomposition", *IEEE Proc.-Gener. Transm. Distrib.*, vol. 145, no. 2, pp. 105-110, 1998.
- [15] FU, C. & BOSE, A. "Contingency Ranking Based of Severity Indices in Dinamic Security Analysis", *IEEE Trans. on Power Systems*, vol. 14, no. 3, pp. 980-986, 1999.
- [16] YURIEVICH, J. & WONG, K.P. "Evolutionary Programming Based Optimal Power Flow", *IEEE Trans. on Power Systems*, vol. 14, no. 4, pp. 1245-1250, 1999.
- [17] CARPENTIER, J. "Contribution a l'etude du dispatching economique", *Bulletin de la Societè Francaise des Electriciens*, vol. 3, pp. 431-447, 1962.
- [18] DOMMEL, H. W. & TINNEY, W. F. "Optimal Power Flow Solutions", *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-87, pp. 1866-1876, 1968.
- [19] HAPP, H. H. & WIRGAU, K. A. "A Review of the Optimal Power Flow", *Journal of The Franklin Institute*, vol. 312, no. 3/4, pp. 231-264, 1981.
- [20] STOTT, B., ALSAC, O. & MONTICELLI, J.A. "Security Analysis and Optimization", *Proceedings of the IEEE*, vol. 75, no. 12, pp. 1623-1644, 1987.
- [21] JIANG, Q., GENG, G. & CAO, Y. "An Efficient Implementation of Automatic Differentiation in Interior Point Optimal Power Flow", *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 147-155, 2010.
- [22] YAN, W., LIU, F., CHUNG, C.Y. & WONG K.P. "A Hybrid Genetic Algorithm-Interior Point Method for Optimal Reactive Power Flow", *IEEE Trans. on Power Systems*, vol. 21, no. 3, pp. 1163-1169, 2006.
- [23] DUAN, C., FANG, W., JIANG, L. & LIU, J. "Adaptative Barrier Filter-line-search Interior Point Method for Optimal Power Flow with FACTS Devices", *IET Gener., Transm. & Distrib.* vol. 9, no. 16, pp. 2792-2798, 2015.
- [24] NIE, Y., DU, Z. & LI, J. "AC-DC Optimal Reactive Power Flow Model via Predictor-Corrector Primal-dual Interior Point Method", *IET Gener., Transm. & Distrib.*, vol. 7, no. 4, pp. 382-390, 2013.
- [25] CHUNG, C. Y., YAN, W. & LIU, F. "Decomposed Predictor-Corrector Interior Point Method for Dynamic Optimal Power Flow", *IEEE Transactions on Power Systems*, vol. 26, no. 3, pp. 1030-1039, 2011.
- [26] SIVASUBRAMANI, S. & SWARUP, K. S. "Sequential Quadratic Programming Based Differential Evolution Algorithm for Optimal Power Flow Problem", *IET Gener., Transm. & Distrib.*, vol. 5, no 11, pp. 1149-1154, 2011.

- [27] BASU, M. “Hybridization of bee colony optimization and sequential quadratic programming for dynamic economic dispatch”, *Electrical Power and Energy Systems*, vol. 44, no. 1, pp. 591-596, 2012.
- [28] NEJDAWI, I. M., CLEMENTS, K. A. & DAVIS, P. W. “An Efficient Interior Point Method for Sequential Quadratic Programming Based Optimal Power Flow”, *IEEE Transactions on Power Systems*, vol. 15, no. 4, pp. 1179-1183, 2000.
- [29] MORSHED, M. J. & ASGHARPOUR, A. “Hybrid imperialist competitive-sequential quadratic programming (HIC-SQP) algorithm for solving economic load dispatch with incorporating stochastic wind power: A comparative study on heuristic optimization techniques”, *Energy Conversion and Management*, vol. 84, pp. 30-40, 2014.
- [30] SUBATHRA, M. S. P., SELVAN, S. E., VICTOIRE, T. A. A., CHRISTINAL, A. H. & AMATO, U. “A Hybrid With Cross-Entropy Method and Sequential Quadratic Programming to Solve Economic Load Dispatch Problem”, *IEEE Systems Journal*, vol. 9, no. 3, pp. 1031-1044, 2014.
- [31] NGUYEN, T. T., NGUYEN, V. L. & KARIMISHAD, A. “Transient stability-constrained optimal power flow for online dispatch and nodal price evaluation in power systems with flexible AC transmission system devices”, *IET Gener., Transm. & Distrib.*, vol. 5, no. 3, pp. 332-346, 2011.
- [32] NGUYEN, T. T. & NGUYEN, V. L. “Representation of line optimisation control in unified power-flow controller model for power-flow analysis”, *IET Gener., Transm. & Distrib.*, vol. 1, no. 5, pp. 714-723, 2007.
- [33] LIMA, F. G. M., SOARES, S., SANTOS, A., ALMEIDA, K. C., GALIANA, F. D. “Numerical experiments with an optimal power flow algorithm based on parametric techniques”, *IEEE Transactions on Power Systems*, vol. 16, no. 3, pp. 374-379, 2001.
- [34] FERREIRA, R. S., BORGES, C. L. T., PEREIRA, M. V. F. “A Flexible Mixed-Integer Linear Programming Approach to the AC Optimal Power Flow in Distribution Systems”, *IEEE Transactions on Power Systems*, vol. 29, no. 5, pp. 2447-2459, 2014.
- [35] LESIEUTRE, B. C., ROGERS, K. M., OVERBYE, T. J. & BORDEN, A. R. “A Sensitivity Approach to Detection of Local Market Power Potential”, *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 1980-1988, 2011.
- [36] MIGUELEZ, E. L., CEREZO, F. M. E. & RODRIGUEZ, L. R. “On the Assignment of Voltage Control Ancillary Service of Generators in Spain”, *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 367-375, 2007.
- [37] SHAO, W. & VITTAL, V. “LP-Based OPF for Corrective FACTS Control to Relieve Overloads and Voltage Violations”, *IEEE Transactions on Power Systems*, vol. 21, no. 4, pp. 1832-1839, 2006.
- [38] ROSENBERG, R. S. “Simulations of genetic populations with biochemical properties”, *PhD Thesis*, University of Michigan, Ann Harbor, Michigan, USA, 1967.

- [39] TODOROVSKI, M. & RAJICIC, D. "A Power Flow Method Suitable for Solving OPF Problems Using Genetic Algorithms", *IEEE EUROCON Ljubljana, Slovenia*, pp. 215-219, 2003.
- [40] AFZALAN, E. & JOORABIAN, M. "Emission, reserve and economic load dispatch problem non-smooth non-convex cost functions using epsilon-multiobjective GA variable", *Electrical Power & Energy Systems*, vol. 52, pp. 55-67, 2013.
- [41] CHEN, H., BO, M. L. & ZHU, Y. "Multi-hive bee foraging algorithm for multi-objective optimal power flow considering the cost, loss, and emission", *Electrical Power & Energy Systems*, vol. 60, pp. 203-220, 2014.
- [42] ABIDO, M. A. "Optimal power flow using particle swarm optimization", *Electrical Power & Energy Systems*, vol. 24, pp. 563-571, 2001.
- [43] ABIDO, M. A. "Multiobjective Particle Swarm Optimization for Environmental Economic Dispatch Problem", *Electrical Power & Energy Systems*, vol. 79, pp. 1105-1113, 2009.
- [44] NIKNAM, T., NARIMANI, M. R., AGHAEI, J. & AZIZIPANAH-ABARGHOOEE, R. "Improved Particle Swarm Optimisation for Multi-objective Optimal Power Flow Considering the Costs, Loss, Emission and Voltage Stability Index", *IET Gener. Transm. Distrib.*, vol. 6, no. 6, pp. 515-527, 2011.
- [45] VARADARAJAN, M. & SWARUP, K. S. "Solving Multi-objective Optimal Power Flow Using Differential Evolution", *IET Gener. Transm. Distrib.*, vol. 2, no. 5, pp. 720-730, 2008.
- [46] ROSELYN, J. P., DEVARAJ, D. & DASH, S. S. "Multi Objective Differential Evolution approach for voltage stability constrained reactive power planning problem", *Electrical Power & Energy Systems*, vol. 59, pp. 155-165, 2014.
- [47] BATTHACHARYA, A. & ROY, P. K. "Solution of Multi-objective Power Flow Using Gravitational Search Algorithm", *IET Gener. Transm. Distrib.*, vol. 6, no. 8, pp. 751-763, 2012.
- [48] BHOWMIK, A. R. & CHAKRABORTY, A. K. "Solution of optimal power flow using nondominated sorting multi objective gravitational search algorithm", *Electrical Power & Energy Systems*, vol. 62, pp. 323-334, 2014.
- [49] AMORIM, E. A., HASHIMOTO, S. H. M., LIMA, F. G. M. & MANTOVANI, J. R. S. "Multi Objective Evolutionary Algorithm Applied to the Optimal Power Flow Problem", *IEEE Latin America Trans.*, vol. 8, no. 3, pp. 236-244, 2010.
- [50] REDDY, S. S., BIJWE, P. R. & ABHYANKAR, A. R. "Faster evolutionary algorithm based optimal power flow using incremental variables", *Electrical Power & Energy Systems*, vol. 54, pp. 198-210, 2013.
- [51] ABIDO, M. A. "A niched Pareto genetic algorithm for multiobjective environmental economic dispatch", *Electrical Power & Energy Systems*, vol. 25, pp. 97-105, 2002.

- [52] DAS, D. B. & PATVARDHAN, C. “Useful Multi-objective Hybrid Evolutionary Approach to Optimal Power Flow”, *IEEE Proc.-Gener. Transm. Distrib.*, vol. 150, no. 3, pp. 275-282, 2003.
- [53] NANGIA, U., JAIN, N. K. & WADHWA, C. L. “Surrogate Worth Trade-off Technique for Multi-objective Optimal Power Flows”, *IEEE Proc.-Gener. Transm. Distrib.*, vol. 144, no. 6, pp. 1997-2013, 1997.
- [54] SRINIVASAN, D. & TETTAMANZI, A. “Heuristics-Guided Evolutionary Approach to Multiobjective Generation Scheduling”, *IEEE Proc.-Gener. Transm. Distrib.*, vol. 143, no. 6, pp. 553-559, 1996.
- [55] NANGIA, U., JAIN, N. K. & WADHWA, C. L. “Multi-objective optimal load flow based on ideal distance minimization in 3D space”, *Electrical Power & Energy Systems*, vol. 23, pp. 847-855, 2000.
- [56] ROMAN, C. & ROSEHART, W. “Evenly Distributed Pareto Points in Multi-objective Optimal Power Flow”, *IEEE Trans. on Power Systems*, vol. 21, no. 2, pp. 1011-1012, 2006.
- [57] YALCINOZ, T. & KOKSOY, O. “A Multi-objective Optimization Method to Environmental Economic Dispatch”, *Electrical Power & Energy Systems*, vol. 29, pp. 42-50, 2006.
- [58] TRIPATHY, M. & MISHRA, S. “Bacteria Foraging-Based Solution to Optimize Both Real Power Loss and Voltage Stability Limit”, *IEEE Trans. on Power Systems*, vol. 22, no. 1, pp. 240-248, Feb. 2007.
- [59] ABIDO, M. A. & BAKHASHWAIN, J. M. “Optimal VAR dispatch using a multiobjective evolutionary algorithm”, *Electrical Power & Energy Systems*, vol. 27, pp. 13-20, 2004.
- [60] SINGH, L. & DHILLON, J. S. “Secure multiobjective real and reactive power allocation of thermal power units”, *Electrical Power & Energy Systems*, vol. 30, pp. 594-602, 2008.
- [61] BASU, M. “Economic environmental dispatch of hydrothermal power system”, *Electrical Power & Energy Systems*, vol. 32, pp. 711-720, 2010.
- [62] NIKNAM, T., NARIMANI, M., JABBARI, M. & MALEKPOUR, A. R. “A modified shuffle frog leaping algorithm for multi-objective optimal power flow”, *Energy*, vol. 36, pp. 6420-6432, 2011.
- [63] SIVASUBRAMANI, S. & SWARUP, K. S. “Multi-objective harmony search algorithm for optimal power flow problem”, *Electrical Power & Energy Systems*, vol. 33, pp. 745-752, 2011.
- [64] AL-HAJRI, M. T. & ABIDO, M. A. “Multi-objective Optimal Power Flow Using Improved Strength Pareto Evolutionary Algorithm (SPEA2)”, In: *11th IEEE International Conference on Intelligent Systems Design and Applications*, vol. 11, pp. 1097-1103, 2011.

- [65] JEYADEVI, S., BASKAR, S., BABULAL, C. K. & IRUTHAYARAJAN, M. W. “Solving multi-objective optimal reactive power dispatch using modified NSGA-II”, *Electrical Power & Energy Systems*, vol. 33, pp. 219-228, 2010.
- [66] MOHAMED. F. A. & KOIVO, H. N. “Multi-objective optimization using Mesh Adaptive Direct Search for power dispatch problem of microgrid”, *Electrical Power & Energy Systems*, vol. 42, pp. 728-735, 2012.
- [67] MEDINA, M. A., DAS, S., COELLO, C. A. C. & RAMÍREZ, J. M. “Decomposition-based modern metaheuristic algorithms for multi-objective optimal power flow – A comparative study”, *Engineering Applications of Artificial Intelligence*, vol. 32, pp. 10-20, 2014.
- [68] KUMARI, M. S. & MAHESWARAPU, Y. “Enhanced Genetic Algorithm based computation technique for multi-objective Optimal Power Flow solution”, *electrical Power & Energy Systems*, vol. 23, pp. 736-742, 2010.
- [69] DEVARAJ, D. & ROSELYN, J. P. “Genetic algorithm based reactive power dispatch for voltage stability improvement”, *Electrical Power & Energy Systems*, vol. 32, pp. 1151-1156, 2010.
- [70] MALIK, I. M. & SRINIVASAN, D. “Optimum Power Flow Using Flexible Genetic Algorithm Model in Practical Power Systems”, *IEEE IPEC*, pp. 1146-1151, 2010.
- [71] KUMAR, V. S. & MOHAN, M. R. “Solution to security constrained unit commitment problem using genetic algorithm”, *Electrical Power & Energy Systems*, vol. 32, pp. 117-125, 2010.
- [72] LEE, J. C., LIN, W. M., LIAO, G. C. & TSAO, T. P. “Quantum genetic algorithm for dynamic economic dispatch with valve-point effects and including wind power system”, *Electrical Power & Energy Systems*, vol. 33, pp. 969-975, 2011.
- [73] ABOOKAZEMI, K., AHMAD, H., TAVAKOLPOUR, A. & HASSAN, M. Y. “Unit commitment solution using an optimized genetic system”, *Electrical Power & Energy Systems*, pp. 969-975, 2011.
- [74] ACHARJEE, P. “Identification of maximum loadability limit and weak buses using security constraint genetic algorithm”, *Electrical Power & Energy Systems*, vol. 36, pp. 40-50, 2012.
- [75] SZUVOVIVSKI, I., FERNANDES, T. S. P. & AOKI, A. R. “Simultaneous allocation capacitors and voltage regulators distributions networks using Genetic Algorithm Optimal Power Flow”, *Electrical Power & Energy Systems*, vol. 40, pp. 62-69, 2012.
- [76] YASAR, C. & OZYON, S. “Solution to scalarized environmental economic power dispatch problem by using genetic algorithm”, *Electrical Power & Energy Systems*, vol. 38, pp. 54-62, 2012.
- [77] LIAO, G. C. “Solve environmental economic dispatch Smart MicroGrid containing distributed generation system Using chaotic quantum GA”, *Electrical Power & Energy Systems*, vol. 43, pp. 779-787, 2012.

- [78] KAPSE, S. S. S., DIAGAVANE, M. B. & BAWANE, N. G. "A Novel Genetic Algorithm Approach to Achieve Steady State Power Flow Solution", *6th International Conference on Emerging Trends in Engineering and Technology*, pp. 189-190, 2013.
- [79] HASSAN, L. H., MOGHAVVEMI, M., ALMURIB, H. A. F. & STEINMAYER, O. "Application of GA in optimization of unified power flow controller parameters and its location in the power system network", *Electrical Power & Energy Systems*, vol. 46, pp. 89-97, 2013.
- [80] AFZALAN, E. & JOORABIAN, M. "Emission, reserve and economic load dispatch problem non-smooth non-convex cost functions using epsilon-multiobjective GA variable", *Electrical Power & Energy Systems*, vol. 52, pp. 55-67, Apr. 2013.
- [81] MAHDAD, B., SRAIRI, K. & BOUKTIR, T. "Optimal power flow for large-scale power system with shunt FACTS using efficient parallel GA", *Electrical Power & Energy Systems*, vol. 32, pp. 507-517, Sep. 2010.
- [82] MO, N., ZOU, Z. Y., CHAN, K. W. & PONG, T. Y. G. "Transient Stability Constrained Optimal Power Flow using Particle Swarm Optimization", *IET Generation, Transmission and Distribution*, vol. 1, no. 3, pp. 477-483, 2007.
- [83] YUMBLA, P. E. O., RAMIREZ, J. M. & COELLO, C. A. C. "Optimal Power Flow Subject to Security Constraints Solved with a Particle Swarm", *IEEE Trans. on Power Systems*, vol. 23, no. 1, pp. 33-40, Feb. 2008.
- [84] BASKAR, G. & MOHAN M. N. "Security constrained economic load dispatch using improved particle swarm optimization suitable for utility system", *Electrical Power & Energy Systems*, vol. 30, pp. 609-613, Sep. 2008.
- [85] ABIDO, M. A. "Multiobjective Particle Swarm Optimization for Environmental Economic Dispatch Problem", *Electrical Power & Energy Systems*, vol. 79, pp. 1105-1113, Mar. 2009.
- [86] AZADANI, E. N., HOSSEINIAN, S. H. & MORADZADEH, B. "Generation and reserve dispatch in a competitive market using constrained particle swarm optimization", *Electrical Power & Energy Systems*, vol. 32, pp. 79-86, Jun. 2009.
- [87] NIKNAM, T., NARIMANI, M. R., AGHAEI, J. & AZIZIPANAH-ABARGHOOEE, R. "Improved Particle Swarm Optimisation for Multi-objective Optimal Power Flow Considering the Costs, Loss, Emission and Voltage Stability Index", *IET Gener. Transm. Distrib.*, vol. 6, no. 6, pp. 515-527, Sep. 2011.
- [88] LEUNG, H. C. & DAH-CHUAN LU, D. "Particle Swarm Optimization for OPF with Consideration of FACTS Devices", *IEEE Trans. on Power Systems*, vol. 11, pp. 2406-2410, 2011.
- [89] MACIEL, R. S., ROSA, M., MIRANDA & V., PADILHA-FELTRIN, A. "Multi-Objective Evolutionary Particle Swarm Optimization in the Assessment of the Impact of Distributed Generation", *Electric Power Systems Research*, vol. 89, pp. 100-108, Mar. 2012.

- [90] MOHAMMADI-IVATLOO, B., RABIEE, A., SOROUDI, A. & EHSAN, M. "Iteration PSO with time varying acceleration coefficients for solving non-convex economic dispatch problems", *Electrical Power & Energy Systems*, vol. 42, pp. 508-516, Jun. 2012.
- [91] GOMEZ-GONZALEZ, M., LÓPEZ, A. & JURADO, F. "Optimization of distributed generation systems using a new discrete PSO and OPF", *Electrical Power Systems Research*, vol. 84, pp. 174-180, Dec. 2011.
- [92] DEVARAJ, D. & YEGNANARAYANA, B. "Genetic-Algorithm-Based Optimal Power Flow for Security Enhancement", *IEE Proceedings on Generation, Transmission and Distribution*, vol. 152, no. 6, pp. 899-905, 2005.
- [93] DENT, C. J., OCHOA, L. F., HARRISON, G. P. & BIALEK, J. W. "Efficient Secure AC OPF for Network Capacity Assessment", *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 575-583, 2010.
- [94] ESMIN, A. A. A., LAMBERT-TORRES, G. & ZAMBRONI DE SOUZA, A. C. "A Hybrid Particle Swarm Optimization Applied to Loss Power Minimization", *IEEE Transactions on Power Systems*, vol. 20, no. 2, pp. 859-866, 2005.
- [95] VOUMVOULAKIS, E. M. & HATZIARGYRIOU, N. D. "A Particle Swarm Optimization Method for Power System Dynamic Security Control", *IEEE Transactions on Power Systems*, vol. 25, no. 2, pp. 1032-1041, 2010.
- [96] XIN, H., GAN, D., HUANG, Z., ZHUANG, K. & CAO, L. "Applications of Stability-Constrained Optimal Power Flow in the East China System", *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1423-1433, 2010.
- [97] SHAHIDEHPOUR, M., TINNEY, W. F. & FU, Y. "Impact of Security on Power Systems Operation", *Proceedings of the IEEE*, vol. 93, no. 11, pp. 2013-2025, 2005.
- [98] MONTICELLI, A. *Fluxo de Carga em Redes de Energia Elétrica*. 1 ed. São Paulo, Edgard Blücher Ltda, 1983.
- [99] MONTICELLI, A., PEREIRA, M.V. F. & GRANVILLE, S. "Security-Constrained Optimal Power Flow With Post-Contingency Corrective Rescheduling", *IEEE Transactions on Power System*, Vol. PWR-2, No 1, pp. 175-182, 1987.
- [100] ALVES, J. M. T. "Fluxo de Potência Ótimo com Restrições de Segurança Aplicado à Operação em Tempo Real Utilizando Processamento Distribuído", *Dissertação de Mestrado*, COPPE/UFRJ, Mestrado em Sistemas de Energia, Rio de Janeiro, RJ, 2005.
- [101] AURICH, M. R. C. "Um Modelo de Fluxo de Potência Ótimo Linear com Reprogramação Corretiva via Método de Pontos Interiores", *Dissertação de Mestrado*, UNICAMP, Campinas, SP, 2004.
- [102] QUINTELA, A. S. "Estudo de Índices de Proximidade ao Limite de Estabilidade de Tensão e Aplicação na Seleção de Contingências", *Dissertação de Mestrado*, UNICAMP, Campinas, SP, 2002.

- [103] GERHARDT, R. A. “Um Sistema Computacional para Análise de Segurança em Sistemas de Energia Elétrica”, *Dissertação de Mestrado*, UNISINOS, São Leopoldo, RS, 2007.
- [104] GRAINGER, J. J. & STEVENSON, W. D. *Power System Analysis*, Singapore McGraw-Hill, 1994.
- [105] DEB, K., MOHAN, M. & MISHRA, S. “A fast multi-objective evolutionary algorithm for finding well-spread Pareto-optimal solutions”. *Relatório Técnico 2003002*, Indian Institute of Technology Kanpur, 2003.
- [106] HAIMES, Y., LASDON, L. & WISMER, D. “On a bicriterion formulation of the problems of integrated system identification and system optimization”. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 1, n. 3, p. 296–297, 1971.
- [107] COELLO, C., VELDHUIZEN, D. V. & LAMONT, G. *Evolutionary algorithm for solving multi-objective problems*. Genetic algorithms and evolutionary computation, New York, Kluiver Academic, 2002.
- [108] DE JONG, K. *Evolutionary computation: a unified approach*. Cambridge, Mass: MIT Press, 2006.
- [109] GOLDBERG, D. *Genetic algorithms in search, optimization and machine learning*. Reading, MA: Addison-Wesley Publishing Company, Inc., 1989.
- [110] SCHAFFER, J. “Multiple Objective Optimization with Vector Evaluated Genetic Algorithms”. In: *Genetic Algorithm and their Applications: Proceedings of the First International Conference on Genetic Algorithms*, Lawrence Erlbaum, pp. 93-100, 1985.
- [111] COELLO, C. “A Short Tutorial on Evolutionary Multiobjective Optimization”. In: ZITZLER, E, DEB, K., THIELE, L., COELLO, C. A. C. & CORNE, D., eds. *First International Conference on Evolutionary Multi-Criterion Optimization*, Springer-Verlag., pp. 21-40, 2001 (*Lecture Notes in Computer Science*, v.1993).
- [112] ZITZLER, E. & THIELE, L. “Improving the Strength Pareto Evolutionary Algorithm”, *Relatório Técnico 103*, Computer Engineering and Network Laboratory (TIK), Swiss Federal Institute of Technology (ETH) Zurich, Gloriastrasse 35, CH 8092 Zurich, Switzerland, 2001.
- [113] CORNE, D., KNOWLES, J. & OATES, M. “The Pareto Envelope-based Selection Algorithm for Multiobjective Optimization”. In: SCHOENAUER, M., DEB, K., RUDOLPH, G., YAO, X., LUTTON, E., MERELO, J. J. & SCHWEFEL, H.-P., eds. *Proceedings of the Parallel Problem Solving from Nature VI Conference*, Paris, France: Springer, pp. 839-848, 2000 (*Lecture Notes in Computer Science*, v.1917).
- [114] ZITZLER, E., DEB, K. & THIELE, L. “Comparison of Multiobjective Evolutionary Algorithms: Empirical Results”, *Evolutionary Computation*, vol. 8, n. 2, pp. 173-195, 2000.
- [115] HOLLAND, J. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: Univ. Michigan Press, 1975.

- [116] ZHOU, A., QU, B.-Y., LI, H., ZHAO, S.-Z., SUNGANTHAN, P. N. & ZHANG, Q. “Multiobjective Evolutionary Algorithm: A Survey of the State of the Art”, *Swarm and Evolutionary Computation*, vol. 1, no. 1, pp. 32-49, 2011.
- [117] DEB, K., AGARWAL, S., PRATAB, A. & MEYARIVAN, T. “A Fast Elitist Non-dominated Sorting Genetic Algorithm for Multiobjective Optimization: NSGA-II”, *KanGAL report 200001*, Indian Institute of Technology, Kanpur, India, 2000.
- [118] KENNEDY, J. & EBERHART, R. “Particle Swarm Optimization”, In: *Proceedings of IEEE International Conference on Neural Networks*, vol. IV, pp 1942-1948, Perth, Australia, 1995.
- [119] COELLO, C. A. C. “MOPSO: A Proposal for Multiple Objective Particle Swarm Optimization,” In: *Proc. Congr. Evolutionary Computation (CEC'2002)*, vol. 1, pp. 1051-1056, Mai 2002.
- [120] COELLO, C. A. C., PULIDO, G. T. & LECHUGA, M. S. “Handling Multiple Objectives With Particle Swarm Optimization,” *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 3, pp. 256-279, 2004.
- [121] MIRANDA, V. & FONSECA, N. “EPSO – Best-of-Two-words Meta-Heuristic Applied to Power System Problem”, *Proc. of the IEEE Congress on Evolutionary Computation 2002*, vol. 2, pp. 1080-1085, Jun 2002.
- [122] MIRANDA, V. & FONSECA, N. “EPSO – Evolutionary Particle Swarm Optimization, a New Algorithm with Applications in Power Systems”, In: *Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES*, vol. 2, pp. 745-750, 2002.
- [123] MORI, H. & OKAWA, K. “Advanced MOEPSO-based Multiobjective Environmental Economic Load Dispatching”, In: *Power and Energy Society General Meeting - 2010 IEEE*, pp. 1-7.
- [124] ALVES, W. F. “Proposição de Sistemas-Teste para Análise Computacional de Sistemas de Potência”, *Dissertação de Mestrado*, UFF, Mestrado em Computação de Potência, Niterói, RJ, 2007.

APÊNDICE A: DESVIOS DOS DESPACHOS OBTIDOS

A.1. MELHORES RESULTADOS RETORNADOS PELO NSGA-II (I1)

Nesta seção estão os indivíduos de menor distância euclidiana em relação à origem de cada fronteira de Pareto retornada pelas 10 simulações (S1 até S10) do NSGA-II da primeira implementação, com os valores em pu (P – potência ativa; V – tensão).

Variável (pu)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
P1	4,10	4,20	3,85	3,46	4,25	3,93	4,08	3,90	3,95	4,11
P2	7,11	7,15	6,89	6,86	6,66	7,17	6,74	7,15	6,90	6,84
P3	8,30	8,59	8,28	8,54	8,26	8,45	8,54	8,40	8,23	8,33
P4	1,44	1,47	1,41	1,41	1,48	1,47	1,60	1,57	1,44	1,53
P5	1,65	1,59	1,81	1,88	1,52	1,90	1,72	2,07	1,69	1,80
P6	2,79	2,66	2,61	2,70	2,63	2,65	2,67	2,56	2,73	2,60
P7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
P8	7,09	7,72	7,10	6,86	8,12	8,52	7,95	8,39	7,47	7,06
P9	2,61	2,59	2,60	2,84	2,59	2,60	2,69	2,84	2,65	2,89
P10	3,58	3,72	3,54	3,50	3,71	3,74	3,47	3,47	3,73	3,56
P11	3,75	4,30	4,38	4,37	4,14	3,76	3,79	3,71	4,21	4,28
P12	2,66	2,70	2,60	2,60	2,54	2,63	2,68	2,54	2,72	2,73
P13	8,06	8,08	7,98	8,33	8,43	8,11	8,66	8,22	8,70	8,07
P14	8,99	8,95	9,03	8,92	9,04	9,20	8,99	8,99	9,02	8,99
P15	9,56	9,73	9,54	9,80	9,57	9,51	9,55	9,55	9,58	10,58
P16	8,31	10,40	10,50	10,70	10,62	9,97	10,86	11,29	10,29	10,34
P17	6,44	6,60	6,96	6,67	6,78	6,88	6,45	6,77	6,65	6,83
P18	7,46	7,51	7,45	7,46	7,50	7,49	7,46	7,46	7,49	7,52
P19	6,21	6,32	6,36	6,25	6,09	6,22	6,36	6,22	6,12	6,16
P20	7,89	7,39	7,15	7,71	8,44	8,42	8,53	7,47	7,73	7,95
P21	0,47	0,48	0,47	0,47	0,48	0,47	0,47	0,47	0,47	0,47
P22	2,21	2,23	2,20	2,22	2,26	2,22	2,25	2,25	2,25	2,20
P23	0,63	0,59	0,58	0,62	0,57	0,63	0,60	0,58	0,57	0,63
V1	0,978	1,010	1,005	0,983	1,012	1,000	0,987	1,007	0,986	1,002
V2	1,002	1,004	0,995	0,993	0,999	1,006	0,996	1,001	0,991	1,002
V3	1,020	1,031	1,021	1,032	1,031	1,031	1,032	1,027	1,029	1,025
V4	0,982	0,993	0,988	0,971	0,966	0,971	0,965	0,986	0,978	0,972
V5	0,992	0,989	0,987	0,987	0,981	0,982	0,989	0,990	0,986	0,990
V6	1,043	1,010	1,036	1,016	1,021	1,017	1,031	1,013	1,014	1,042
V7	0,999	0,992	0,994	0,989	0,986	0,991	0,987	0,993	0,993	0,988
V8	1,000	0,987	0,989	0,977	0,993	0,978	0,978	0,985	0,993	0,986
V9	1,021	1,020	1,019	1,019	1,020	1,020	1,021	1,021	1,020	1,019
V10	1,031	1,003	1,031	1,008	1,036	1,028	1,005	0,997	1,005	0,998
V11	1,003	1,004	1,010	1,009	1,009	1,006	1,003	1,006	1,008	1,005
V12	0,996	0,999	0,989	1,003	0,994	0,988	0,991	0,987	0,988	0,982
V13	0,999	0,981	0,995	0,998	0,982	1,015	1,022	1,020	1,023	1,023
V14	0,999	1,005	1,002	0,998	0,999	0,998	1,005	1,006	1,007	1,004
V15	1,010	1,013	1,003	1,009	0,997	0,998	1,003	0,997	1,015	1,009
V16	1,004	1,004	1,008	1,007	1,000	1,006	1,000	1,002	1,000	1,005
V17	0,975	0,978	0,989	0,982	0,987	0,972	0,982	0,988	0,977	0,979
V18	1,011	1,012	1,013	1,012	1,012	1,012	1,012	1,010	1,012	1,010
V19	0,968	0,962	0,960	0,960	0,963	0,961	0,974	0,959	0,961	0,979
V20	1,010	0,996	1,011	0,995	1,001	1,000	1,003	1,003	1,000	0,993
V21	0,999	0,979	0,983	0,993	0,987	1,000	0,995	0,986	0,984	0,980
V22	0,992	1,002	0,993	0,995	0,992	1,000	0,994	0,997	0,994	0,995
V23	0,993	0,975	0,983	0,970	0,993	0,968	0,975	0,970	0,972	0,982

A.2. DESVIO DOS MELHORES RESULTADOS RETORNADOS PELO NSGA-II (I1)

Nesta seção estão os desvios percentuais dos despachos de menor distância euclidiana retornados pelas 10 simulações do NSGA-II da primeira implementação em relação ao despacho previamente especificado para o sistema-teste utilizado, especificando o quanto cada variável de controle foi modificada em comparação ao despacho pré-especificado.

Variável (%)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
$\Delta P1$	-36,7	-40,0	-28,3	-15,3	-41,7	-31,0	-36,0	-30,0	-31,7	-37,0
$\Delta P2$	11,1	10,6	13,9	14,3	16,8	10,4	15,8	10,6	13,8	14,5
$\Delta P3$	7,8	4,6	8,0	5,1	8,2	6,1	5,1	6,7	8,6	7,4
$\Delta P4$	-2,9	-5,0	-0,7	-0,7	-5,7	-5,0	-14,3	-12,1	-2,9	-9,3
$\Delta P5$	-10,0	-6,0	-20,7	-25,3	-1,3	-26,7	-14,7	-38,0	-12,7	-20,0
$\Delta P6$	-39,5	-33,0	-30,5	-35,0	-31,5	-32,5	-33,5	-28,0	-36,5	-30,0
$\Delta P7$	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
$\Delta P8$	-1,3	-10,3	-1,4	2,0	-16,0	-21,7	-13,6	-19,9	-6,7	-0,9
$\Delta P9$	13,0	13,7	13,3	5,3	13,7	13,3	10,3	5,3	11,7	3,7
$\Delta P10$	10,5	7,0	11,5	12,5	7,3	6,5	13,3	13,3	6,8	11,0
$\Delta P11$	-87,5	-115,0	-119,0	-118,5	-107,0	-88,0	-89,5	-85,5	-110,5	-114,0
$\Delta P12$	11,3	10,0	13,3	13,3	15,3	12,3	10,7	15,3	9,3	9,0
$\Delta P13$	-0,8	-1,0	0,2	-4,1	-5,4	-1,4	-8,3	-2,8	-8,7	-0,9
$\Delta P14$	18,3	18,6	17,9	18,9	17,8	16,4	18,3	18,3	18,0	18,3
$\Delta P15$	16,9	15,4	17,0	14,8	16,8	17,3	17,0	17,0	16,7	8,0
$\Delta P16$	30,8	13,3	12,5	10,8	11,5	16,9	9,5	5,9	14,3	13,8
$\Delta P17$	8,0	5,7	0,6	4,7	3,1	1,7	7,9	3,3	5,0	2,4
$\Delta P18$	-6,6	-7,3	-6,4	-6,6	-7,1	-7,0	-6,6	-6,6	-7,0	-7,4
$\Delta P19$	11,3	9,7	9,1	10,7	13,0	11,1	9,1	11,1	12,6	12,0
$\Delta P20$	16,9	22,2	24,7	18,8	11,2	11,4	10,2	21,4	18,6	16,3
$\Delta P21$	6,0	4,0	6,0	6,0	4,0	6,0	6,0	6,0	6,0	6,0
$\Delta P22$	3,9	3,0	4,3	3,5	1,7	3,5	2,2	2,2	2,2	4,3
$\Delta P23$	-26,0	-18,0	-16,0	-24,0	-14,0	-26,0	-20,0	-16,0	-14,0	-26,0
$\Delta V1$	2,20	-1,00	-0,50	1,70	-1,20	0,00	1,30	-0,70	1,40	-0,20
$\Delta V2$	-0,20	-0,40	0,50	0,70	0,10	-0,60	0,40	-0,10	0,90	-0,20
$\Delta V3$	-0,99	-2,08	-1,09	-2,18	-2,08	-2,08	-2,18	-1,68	-1,88	-1,49
$\Delta V4$	1,80	0,70	1,20	2,90	3,40	2,90	3,50	1,40	2,20	2,80
$\Delta V5$	0,80	1,10	1,30	1,30	1,90	1,80	1,10	1,03	1,40	1,00
$\Delta V6$	-4,33	-1,00	-3,60	-1,60	-2,10	-1,70	-3,10	-1,30	-1,40	-4,20
$\Delta V7$	0,10	0,80	0,60	1,10	1,40	0,90	1,30	0,70	0,70	1,20
$\Delta V8$	1,96	3,24	3,04	4,19	2,65	4,12	4,12	3,43	2,65	3,33
$\Delta V9$	-1,09	-0,99	-0,89	-0,89	-0,99	-0,99	-1,09	-1,09	-0,99	-0,89
$\Delta V10$	-1,08	1,67	-1,08	1,18	-1,57	-0,78	1,47	2,25	1,47	2,16
$\Delta V11$	1,67	1,57	0,98	1,05	1,08	1,37	1,67	1,37	1,18	1,47
$\Delta V12$	0,40	0,10	1,10	-0,30	0,60	1,20	0,90	1,30	1,20	1,80
$\Delta V13$	2,06	3,82	2,45	2,16	3,73	0,49	-0,20	0,03	-0,29	-0,33
$\Delta V14$	2,06	1,47	1,76	2,16	2,06	2,16	1,46	1,37	1,27	1,57
$\Delta V15$	0,98	0,69	1,67	1,08	2,25	2,16	1,67	2,25	0,49	1,08
$\Delta V16$	1,57	1,57	1,18	1,27	1,96	1,37	1,96	1,76	2,01	1,47
$\Delta V17$	4,41	4,12	3,04	3,71	3,22	4,71	3,73	3,14	4,22	4,02
$\Delta V18$	0,88	0,78	0,67	0,78	0,78	0,78	0,78	0,98	0,78	0,98
$\Delta V19$	3,20	3,80	4,00	4,00	3,70	3,90	2,60	4,10	3,90	2,10
$\Delta V20$	0,98	2,35	0,88	2,45	1,86	1,96	1,67	1,67	1,96	2,65
$\Delta V21$	1,09	3,07	2,67	1,68	2,28	0,99	1,49	2,38	2,57	2,97
$\Delta V22$	0,79	-0,20	0,70	0,50	0,80	0,00	0,60	0,30	0,60	0,50
$\Delta V23$	0,70	2,50	1,70	3,00	0,70	3,20	2,50	3,03	2,80	1,80

A.3. MELHORES RESULTADOS RETORNADOS PELO MOEPSO (I1)

Nesta seção estão os indivíduos de menor distância euclidiana em relação à origem de cada fronteira de Pareto retornada pelas 10 simulações (S1 até S10) do MOEPSO da primeira implementação, com os valores em pu (P – potência ativa; V – tensão).

Variável (pu)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
P1	3,84	3,83	3,80	3,92	3,96	3,98	3,96	3,97	3,91	3,92
P2	7,25	7,27	7,21	7,97	7,71	7,90	8,05	7,98	7,96	7,99
P3	8,15	8,91	8,14	8,05	8,10	8,19	8,15	7,92	7,86	7,87
P4	0,98	0,95	0,92	0,95	0,94	0,99	0,97	0,94	0,95	0,93
P5	1,42	1,46	1,46	1,47	1,42	1,44	1,40	1,48	1,42	1,46
P6	2,66	2,70	2,69	2,68	2,66	2,67	2,69	2,69	2,67	2,69
P7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
P8	6,96	6,93	6,97	6,96	6,94	6,95	6,94	6,96	6,95	6,99
P9	2,50	2,54	2,51	2,57	2,54	2,61	2,47	2,43	2,45	2,48
P10	3,85	3,62	3,23	3,57	3,91	3,34	3,86	3,61	3,29	3,85
P11	3,28	3,04	3,23	3,80	3,20	3,35	3,60	3,89	3,28	3,46
P12	2,89	2,93	2,87	2,45	2,97	3,17	3,21	2,76	3,04	2,83
P13	7,87	7,75	7,68	7,59	7,94	7,80	7,69	7,66	7,86	7,85
P14	11,58	11,85	11,52	11,45	10,37	10,59	10,44	11,18	10,52	10,44
P15	6,59	6,03	6,53	8,50	6,36	6,51	6,52	6,79	6,74	6,88
P16	9,40	9,57	9,48	9,45	9,47	9,48	9,41	9,80	9,80	9,88
P17	9,84	9,78	9,76	9,75	9,73	9,84	9,73	9,75	9,79	9,73
P18	5,43	5,52	5,53	7,70	5,15	5,70	5,17	5,99	5,98	5,79
P19	4,30	4,86	4,89	4,64	4,48	4,83	4,53	4,55	4,32	4,35
P20	7,68	7,71	7,67	7,67	7,71	7,72	7,78	7,71	7,68	7,69
P21	0,50	0,52	0,52	0,51	0,52	0,53	0,51	0,50	0,52	0,53
P22	2,35	2,35	2,32	2,32	2,36	2,34	2,30	2,31	2,37	2,37
P23	0,87	0,93	0,81	0,84	0,84	0,84	0,81	0,82	0,85	0,87
V1	0,960	0,984	0,969	0,984	0,959	0,975	0,989	1,005	1,000	0,986
V2	0,993	1,001	0,971	0,970	0,991	0,981	0,997	1,006	0,997	0,975
V3	1,030	1,019	1,031	1,024	1,035	1,026	1,019	1,028	1,040	1,021
V4	0,965	0,964	0,963	0,973	0,966	0,966	0,963	0,975	0,974	0,968
V5	1,016	1,016	1,017	1,006	1,021	1,005	1,015	1,016	1,013	1,011
V6	0,979	0,982	0,978	0,978	0,980	0,980	0,980	0,979	0,979	0,979
V7	0,992	0,998	0,999	0,998	0,997	0,999	0,999	0,999	0,997	0,999
V8	0,961	0,980	0,972	0,964	0,962	0,971	0,973	0,970	0,964	0,984
V9	1,000	0,999	1,002	0,996	0,994	1,002	0,996	0,991	0,997	0,992
V10	1,022	1,022	1,018	1,019	1,023	1,020	1,023	1,020	1,019	1,018
V11	1,022	1,040	1,024	1,032	1,039	1,039	1,029	1,031	1,024	1,027
V12	0,962	0,964	0,993	0,977	0,992	0,993	0,961	0,972	0,999	0,964
V13	1,009	0,940	0,963	0,965	0,941	0,955	0,993	1,004	0,950	0,972
V14	0,988	0,979	0,978	0,977	0,961	0,955	0,985	0,970	0,958	0,989
V15	0,981	0,987	0,992	0,997	0,998	0,991	0,993	1,009	0,992	0,988
V16	1,021	1,025	1,020	1,022	1,022	1,022	1,023	1,020	1,021	1,023
V17	1,051	1,031	1,048	1,021	1,043	1,046	1,042	1,042	1,047	1,042
V18	1,022	1,025	1,026	1,026	1,025	1,027	1,024	1,024	1,025	1,023
V19	0,961	0,959	0,971	0,970	0,965	0,959	0,986	0,985	0,959	0,965
V20	1,018	1,020	1,019	1,018	1,019	1,020	1,019	1,019	1,019	1,018
V21	1,010	1,009	1,006	1,016	1,011	1,007	1,006	1,009	1,019	1,007
V22	0,973	0,972	0,973	0,973	0,972	0,972	0,976	0,973	0,973	0,972
V23	1,010	1,032	0,993	1,023	1,029	1,022	0,990	1,004	1,030	0,999

A.4. DESVIO DOS MELHORES RESULTADOS RETORNADOS PELO MOEPSO (I1)

Nesta seção estão os desvios percentuais dos despachos de menor distância euclidiana retornados pelas 10 simulações do MOEPSO da primeira implementação em relação ao despacho previamente especificado para o sistema-teste utilizado, especificando o quanto cada variável de controle foi modificada em comparação ao despacho pré-especificado.

Variável (%)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
$\Delta P1$	-28,0	-27,7	-26,7	-30,7	-32,0	-32,7	-32,0	-32,3	-30,3	-30,7
$\Delta P2$	9,4	9,1	9,9	0,4	3,6	1,3	-0,6	0,2	0,5	0,1
$\Delta P3$	9,4	1,0	9,6	10,6	10,0	9,0	9,4	12,0	12,7	12,6
$\Delta P4$	30,0	32,1	34,3	32,1	32,9	29,3	30,7	32,9	32,1	33,6
$\Delta P5$	5,3	2,7	2,7	2,0	5,3	4,0	6,7	1,3	5,3	2,7
$\Delta P6$	-33,0	-35,0	-34,5	-34,0	-33,0	-33,5	-34,5	-34,5	-33,5	-34,5
$\Delta P7$	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
$\Delta P8$	0,6	1,0	0,4	0,6	0,9	0,7	0,9	0,6	0,7	0,1
$\Delta P9$	16,7	15,3	16,3	14,3	15,3	13,0	17,7	19,0	18,3	17,3
$\Delta P10$	3,8	9,5	19,3	10,8	2,3	16,5	3,5	9,8	17,8	3,8
$\Delta P11$	-64,0	-52,0	-61,5	-90,0	-60,0	-67,5	-80,0	-94,5	-64,0	-73,0
$\Delta P12$	3,7	2,3	4,3	18,3	1,0	-5,7	-7,0	8,0	-1,3	5,7
$\Delta P13$	1,6	3,1	4,0	5,1	0,7	2,5	3,9	4,3	1,8	1,9
$\Delta P14$	-5,3	-7,7	-4,7	-4,1	5,7	3,7	5,1	-1,6	4,4	5,1
$\Delta P15$	42,7	47,6	43,2	26,1	44,7	43,4	43,3	41,0	41,4	40,2
$\Delta P16$	21,7	20,3	21,0	21,3	21,1	21,0	21,6	18,3	18,3	17,7
$\Delta P17$	-40,6	-39,7	-39,4	-39,3	-39,0	-40,6	-39,0	-39,3	-39,9	-39,0
$\Delta P18$	22,4	21,1	21,0	-10,0	26,4	18,6	26,1	14,4	14,6	17,3
$\Delta P19$	38,6	30,6	30,1	33,7	36,0	31,0	35,3	35,0	38,3	37,9
$\Delta P20$	19,2	18,8	19,3	19,3	18,8	18,7	18,1	18,8	19,2	19,1
$\Delta P21$	0,0	-4,0	-4,0	-2,0	-4,0	-6,0	-2,0	0,0	-4,0	-6,0
$\Delta P22$	-2,2	-2,2	-0,9	-0,9	-2,6	-1,7	0,0	-0,4	-3,0	-3,0
$\Delta P23$	-74,0	-86,0	-62,0	-68,0	-68,0	-68,0	-62,0	-64,0	-70,0	-74,0
$\Delta V1$	4,00	1,60	3,10	1,60	4,10	2,50	1,10	-0,50	0,00	1,40
$\Delta V2$	0,70	-0,10	2,90	3,00	0,90	1,90	0,30	-0,60	0,30	2,50
$\Delta V3$	-1,98	-0,89	-2,08	-1,39	-2,48	-1,58	-0,89	-1,78	-2,97	-1,09
$\Delta V4$	3,50	3,60	3,70	2,70	3,40	3,40	3,70	2,50	2,60	3,20
$\Delta V5$	-1,60	-1,60	-1,70	-0,60	-2,10	-0,50	-1,50	-1,60	-1,30	-1,10
$\Delta V6$	2,10	1,80	2,20	2,20	2,00	2,00	2,00	2,10	2,10	2,13
$\Delta V7$	0,80	0,20	0,10	0,20	0,30	0,08	0,10	0,10	0,30	0,10
$\Delta V8$	5,78	3,92	4,71	5,49	5,69	4,80	4,61	4,90	5,49	3,53
$\Delta V9$	0,99	1,09	0,76	1,39	1,58	0,79	1,39	1,88	1,29	1,78
$\Delta V10$	-0,19	-0,20	0,20	0,10	-0,29	0,00	-0,29	0,00	0,10	0,20
$\Delta V11$	-0,20	-1,98	-0,39	-1,18	-1,86	-1,86	-0,88	-1,08	-0,39	-0,69
$\Delta V12$	3,80	3,60	0,70	2,30	0,80	0,68	3,90	2,80	0,10	3,60
$\Delta V13$	1,08	7,84	8,24	5,39	7,75	6,37	2,65	1,57	6,86	4,71
$\Delta V14$	3,14	4,04	4,12	4,22	5,76	6,37	3,43	4,94	6,08	3,04
$\Delta V15$	3,82	3,24	2,75	2,25	2,16	2,84	2,65	1,08	2,75	3,14
$\Delta V16$	-0,10	-0,49	0,00	-0,20	-0,20	-0,20	-0,29	0,00	-0,10	-0,29
$\Delta V17$	-3,04	-1,08	-2,75	-0,10	-2,25	-2,55	-2,16	-2,16	-2,65	-2,16
$\Delta V18$	-0,20	-0,49	-0,59	-0,59	-0,49	-0,69	-0,39	-0,39	-0,49	-0,29
$\Delta V19$	3,90	4,10	2,90	2,99	3,50	4,10	1,42	1,50	4,10	3,50
$\Delta V20$	0,20	0,00	0,10	0,20	0,10	0,00	0,10	0,10	0,10	0,20
$\Delta V21$	-0,02	0,10	0,40	-0,59	-0,10	0,30	0,40	0,10	-0,89	0,30
$\Delta V22$	2,70	2,80	2,70	2,70	2,80	2,80	2,40	2,70	2,70	2,80
$\Delta V23$	-1,00	-3,20	0,70	-2,30	-2,90	-2,20	1,00	-0,40	-3,00	0,10

A.5. MELHORES RESULTADOS RETORNADOS PELO NSGA-II (I2)

Nesta seção estão os indivíduos de menor distância euclidiana em relação à origem de cada fronteira de Pareto retornada pelas 10 simulações (S1 até S10) do NSGA-II da segunda implementação, com os valores em pu (P – potência ativa; V – tensão).

Variável (pu)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
P1	4,05	4,03	3,86	4,04	3,95	4,02	4,17	3,93	3,96	4,04
P2	7,06	7,06	7,05	7,20	7,18	6,94	6,72	7,22	6,94	7,08
P3	8,44	8,49	8,44	8,44	8,38	8,47	8,40	8,30	8,21	8,51
P4	1,51	1,50	1,54	1,49	1,56	1,49	1,55	1,47	1,47	1,50
P5	1,75	2,10	1,83	1,88	1,79	1,61	1,58	1,83	1,84	1,96
P6	2,56	2,61	2,60	2,55	2,58	2,79	2,72	2,81	2,86	2,74
P7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
P8	7,53	7,25	7,06	7,35	7,38	7,37	7,49	7,67	7,62	7,64
P9	2,79	2,70	2,85	2,59	2,72	2,73	2,72	2,61	2,70	2,79
P10	3,69	3,48	3,63	3,61	3,68	3,55	3,58	3,74	3,56	3,76
P11	4,44	3,69	4,39	3,73	4,21	4,25	4,24	3,87	3,58	3,55
P12	2,71	2,59	2,67	2,65	2,75	2,75	2,76	2,56	2,63	2,66
P13	8,75	8,67	8,75	8,87	8,32	8,13	8,10	8,65	8,34	8,64
P14	8,99	8,96	9,03	8,98	8,92	8,93	8,96	8,95	8,91	8,91
P15	9,56	9,56	9,55	9,55	9,52	9,57	9,56	9,57	9,50	9,52
P16	11,36	10,89	11,10	10,34	10,07	10,89	11,30	10,06	10,01	10,06
P17	6,90	6,97	6,93	6,69	6,79	6,97	6,80	6,45	6,43	6,87
P18	7,51	7,46	7,46	7,46	7,43	7,45	7,49	7,45	7,47	7,49
P19	6,38	6,28	6,30	6,29	6,23	6,15	6,30	6,40	6,41	6,27
P20	8,06	7,96	8,15	7,35	7,45	7,29	7,34	8,52	7,65	7,23
P21	0,47	0,48	0,47	0,48	0,47	0,47	0,48	0,48	0,48	0,47
P22	2,21	2,22	2,27	2,20	2,27	2,23	2,21	2,26	2,26	2,26
P23	0,61	0,63	0,63	0,62	0,58	0,61	0,63	0,62	0,61	0,60
V1	1,010	0,989	0,990	0,999	0,988	0,996	1,003	0,995	0,980	1,007
V2	0,997	1,006	1,001	1,008	1,002	1,000	1,002	0,996	1,003	0,992
V3	1,029	1,022	1,025	1,034	1,027	1,021	1,024	1,033	1,028	1,031
V4	0,974	0,967	0,967	0,976	0,978	0,979	0,966	0,995	0,974	0,976
V5	0,982	0,989	0,983	0,982	0,983	0,982	0,986	0,992	0,983	0,986
V6	1,016	1,043	1,045	1,011	1,040	1,018	1,011	1,036	1,017	1,045
V7	1,000	0,998	0,993	0,992	1,003	0,988	1,003	0,997	0,995	0,986
V8	0,992	0,990	0,978	0,984	0,988	0,991	0,992	0,987	0,993	0,993
V9	1,020	1,021	1,020	1,020	1,020	1,019	1,020	1,021	1,021	1,021
V10	1,039	1,021	1,017	1,007	1,037	0,999	1,023	0,997	1,029	0,998
V11	1,008	1,004	1,007	1,004	1,007	1,010	1,008	1,009	1,004	1,004
V12	0,986	1,003	0,992	0,989	0,985	1,005	0,984	0,992	1,003	0,982
V13	1,016	0,981	1,000	0,985	1,002	0,982	1,014	0,986	0,984	1,002
V14	1,007	1,002	1,005	1,002	1,006	0,998	0,998	1,003	0,998	1,000
V15	0,993	1,016	1,001	1,016	1,007	1,005	1,016	0,998	1,006	0,992
V16	1,004	1,003	1,006	1,002	1,004	1,006	1,007	1,006	1,007	1,006
V17	0,975	0,970	0,976	0,988	0,970	0,983	0,986	0,985	0,986	0,984
V18	1,011	1,013	1,011	1,012	1,012	1,011	1,012	1,012	1,010	1,010
V19	0,960	0,971	0,980	0,959	0,960	0,962	0,959	0,965	0,970	0,967
V20	1,006	1,011	0,991	0,991	1,003	0,993	1,005	1,013	0,995	0,995
V21	0,993	0,999	0,981	0,994	1,000	0,985	0,984	0,988	0,989	1,002
V22	0,999	0,994	1,004	1,005	1,000	0,998	1,002	1,002	0,994	0,999
V23	0,970	0,983	0,990	0,987	0,969	0,980	0,986	0,998	0,989	0,976

A.6. DESVIO DOS MELHORES RESULTADOS RETORNADOS PELO NSGA-II (I2)

Nesta seção estão os desvios percentuais dos despachos de menor distância euclidiana retornados pelas 10 simulações do NSGA-II da segunda implementação em relação ao despacho previamente especificado para o sistema-teste utilizado, especificando o quanto cada variável de controle foi modificada em comparação ao despacho pré-especificado.

Variável (%)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
$\Delta P1$	-35,0	-34,3	-28,7	-34,7	-31,7	-34,0	-39,0	-31,0	-32,0	-34,7
$\Delta P2$	11,8	11,8	11,9	10,0	10,3	13,3	16,0	9,8	13,3	11,5
$\Delta P3$	6,2	5,7	6,2	6,2	6,9	5,9	6,7	7,8	8,8	5,4
$\Delta P4$	-7,9	-7,1	-10,0	-6,4	-11,4	-6,4	-10,7	-5,0	-5,0	-7,1
$\Delta P5$	-16,7	-40,0	-22,0	-25,3	-19,3	-7,3	-5,3	-22,0	-22,7	-30,7
$\Delta P6$	-28,0	-30,5	-30,0	-27,5	-29,0	-39,5	-36,0	-40,5	-43,0	-37,0
$\Delta P7$	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
$\Delta P8$	-7,6	-3,6	-0,9	-5,0	-5,4	-5,3	-7,0	-9,6	-8,9	-9,1
$\Delta P9$	7,0	10,0	5,0	13,7	9,3	9,0	9,3	13,0	10,0	7,0
$\Delta P10$	7,8	13,0	9,3	9,8	8,0	11,3	10,5	6,5	11,0	6,0
$\Delta P11$	-122,0	-84,5	-119,5	-86,5	-110,5	-112,5	-112,0	-93,5	-79,0	-77,5
$\Delta P12$	9,7	13,7	11,0	11,7	8,3	8,3	8,0	14,7	12,3	11,3
$\Delta P13$	-9,4	-8,4	-9,4	-10,9	-4,0	-1,6	-1,3	-8,1	-4,3	-8,0
$\Delta P14$	18,3	18,5	17,9	18,4	18,9	18,8	18,5	18,6	19,0	19,0
$\Delta P15$	16,9	16,9	17,0	17,0	17,2	16,8	16,9	16,8	17,4	17,2
$\Delta P16$	5,3	9,3	7,5	13,8	16,1	9,3	5,8	16,2	16,6	16,2
$\Delta P17$	1,4	0,4	1,0	4,4	3,0	0,4	2,9	7,9	8,1	1,9
$\Delta P18$	-7,3	-6,6	-6,6	-6,6	-6,1	-6,4	-7,0	-6,4	-6,7	-7,0
$\Delta P19$	8,9	10,3	10,0	10,1	11,0	12,1	10,0	8,6	8,4	10,4
$\Delta P20$	15,2	16,2	14,2	22,6	21,6	23,3	22,7	10,3	19,5	23,9
$\Delta P21$	6,0	4,0	6,0	4,0	6,0	6,0	4,0	4,0	4,0	6,0
$\Delta P22$	3,9	3,5	1,3	4,3	1,3	3,0	3,9	1,7	1,7	1,7
$\Delta P23$	-22,0	-26,0	-26,0	-24,0	-16,0	-22,0	-26,0	-24,0	-22,0	-20,0
$\Delta V1$	-1,00	1,10	1,00	0,10	1,20	0,40	-0,30	0,50	2,00	-0,70
$\Delta V2$	0,30	-0,60	-0,10	-0,80	-0,20	0,00	-0,20	0,40	-0,30	0,80
$\Delta V3$	-1,88	-1,19	-1,49	-2,38	-1,68	-1,11	-1,39	-2,28	-1,78	-2,08
$\Delta V4$	2,60	3,30	3,30	2,40	2,20	2,10	3,40	0,50	2,57	2,40
$\Delta V5$	1,80	1,10	1,70	1,80	1,70	1,80	1,40	0,80	1,70	1,40
$\Delta V6$	-1,56	-4,30	-4,50	-1,14	-4,00	-1,80	-1,10	-3,60	-1,70	-4,50
$\Delta V7$	0,00	0,20	0,70	0,80	-0,26	1,20	-0,30	0,30	0,50	1,40
$\Delta V8$	2,75	2,94	4,12	3,53	3,14	2,84	2,75	3,24	2,65	2,65
$\Delta V9$	-0,99	-1,09	-1,01	-0,99	-0,99	-0,89	-0,99	-1,09	-1,09	-1,09
$\Delta V10$	-1,86	-0,10	0,29	1,27	-1,67	2,06	-0,29	2,25	-0,88	2,16
$\Delta V11$	1,18	1,57	1,27	1,57	1,27	0,98	1,18	1,08	1,57	1,57
$\Delta V12$	1,40	-0,28	0,80	1,10	1,50	-0,50	1,60	0,80	-0,30	1,80
$\Delta V13$	0,39	3,82	1,96	3,43	1,76	3,73	0,59	3,33	3,53	1,76
$\Delta V14$	1,27	1,76	1,47	1,76	1,37	2,16	2,16	1,67	2,16	1,96
$\Delta V15$	2,65	0,39	1,86	0,39	1,27	1,47	0,39	2,16	1,37	2,75
$\Delta V16$	1,57	1,67	1,37	1,76	1,57	1,37	1,27	1,37	1,27	1,37
$\Delta V17$	4,41	4,90	4,31	3,14	4,90	3,63	3,33	3,43	3,33	3,53
$\Delta V18$	0,88	0,69	0,88	0,78	0,78	0,88	0,78	0,78	0,98	0,98
$\Delta V19$	4,03	2,90	2,00	4,10	4,00	3,80	4,12	3,50	3,00	3,30
$\Delta V20$	1,34	0,88	2,84	2,84	1,67	2,65	1,47	0,69	2,45	2,45
$\Delta V21$	1,68	1,09	2,87	1,58	0,99	2,48	2,57	2,18	2,08	0,79
$\Delta V22$	0,10	0,60	-0,40	-0,50	0,00	0,20	-0,20	-0,20	0,60	0,10
$\Delta V23$	3,00	1,70	1,00	1,30	3,10	2,00	1,40	0,20	1,10	2,40

A.7. MELHORES RESULTADOS RETORNADOS PELO MOEPSO (I2)

Nesta seção estão os indivíduos de menor distância euclidiana em relação à origem de cada fronteira de Pareto retornada pelas 10 simulações (S1 até S10) do MOEPSO da segunda implementação, com os valores em pu (P – potência ativa; V – tensão).

Variável (pu)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
P1	4,00	4,04	4,01	4,05	4,01	4,02	4,08	4,09	3,93	3,89
P2	7,24	7,23	7,23	7,25	7,17	7,06	7,07	7,25	7,26	7,28
P3	8,52	8,59	8,41	8,47	8,30	8,52	8,30	8,40	8,61	8,22
P4	1,50	1,53	1,60	1,44	1,61	1,59	1,49	1,52	1,51	1,59
P5	1,62	1,91	2,00	1,79	1,51	1,47	1,82	1,58	1,68	1,71
P6	2,66	2,65	2,76	2,69	2,55	2,60	2,67	2,67	2,66	2,79
P7	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
P8	7,34	6,67	7,05	7,33	8,54	8,58	6,97	8,41	8,23	6,51
P9	2,84	2,82	2,67	2,67	2,85	2,82	2,65	2,69	2,80	2,78
P10	3,60	3,59	3,65	3,49	3,68	3,55	3,61	3,70	3,50	3,70
P11	4,39	4,44	3,84	4,21	4,07	4,15	3,82	3,71	4,23	3,98
P12	2,55	2,77	2,75	2,70	2,65	2,70	2,67	2,59	2,59	2,64
P13	8,66	8,17	8,31	8,92	8,91	8,33	8,94	8,95	7,99	8,73
P14	8,94	8,96	8,99	8,98	8,95	8,93	9,00	8,88	9,04	9,05
P15	9,52	9,50	9,56	9,51	9,56	9,52	9,56	9,51	9,57	9,58
P16	10,07	10,92	10,46	11,94	9,62	10,41	10,08	10,09	11,32	10,84
P17	6,68	6,77	6,53	6,59	6,74	6,72	6,50	6,93	6,55	6,69
P18	7,50	7,48	7,53	7,52	7,52	7,49	7,42	7,44	7,50	7,46
P19	6,28	6,16	6,34	6,35	6,26	6,14	6,11	6,19	6,40	6,42
P20	8,03	8,08	7,88	8,32	8,24	8,22	8,24	7,41	7,30	7,36
P21	0,48	0,48	0,47	0,47	0,47	0,48	0,47	0,48	0,47	0,48
P22	2,25	2,26	2,25	2,26	2,20	2,21	2,21	2,25	2,25	2,23
P23	0,59	0,58	0,58	0,61	0,61	0,61	0,62	0,62	0,59	0,61
V1	1,012	0,978	1,003	0,983	0,999	0,990	1,012	0,983	0,987	0,997
V2	0,992	1,000	0,995	0,997	0,995	1,004	0,997	1,005	1,001	0,999
V3	1,020	1,027	1,028	1,035	1,025	1,025	1,022	1,022	1,022	1,032
V4	0,996	0,993	0,974	0,986	0,983	0,970	0,977	0,978	0,972	0,978
V5	0,988	0,986	0,992	0,983	0,993	0,981	0,992	0,985	0,992	0,991
V6	1,019	1,032	1,017	1,025	1,028	1,042	1,030	1,013	1,016	1,039
V7	0,985	0,984	1,003	0,991	0,984	0,991	0,989	0,985	0,988	0,999
V8	0,976	0,995	0,983	0,986	0,993	0,991	0,981	0,978	0,989	0,984
V9	1,021	1,020	1,020	1,020	1,020	1,021	1,021	1,020	1,020	1,020
V10	1,029	1,015	1,037	1,000	1,028	1,016	1,027	1,004	1,034	1,004
V11	1,009	1,009	1,007	1,004	1,010	1,004	1,009	1,006	1,004	1,007
V12	0,983	0,977	0,983	0,974	0,986	0,995	0,985	0,997	0,981	0,982
V13	0,988	1,006	0,991	1,014	1,011	1,025	1,015	0,988	1,019	1,007
V14	0,998	1,005	1,001	0,999	1,006	0,999	1,006	1,004	1,002	0,997
V15	0,991	1,015	1,009	1,005	1,006	1,008	0,996	1,000	1,004	0,994
V16	1,008	1,005	1,000	1,006	1,002	1,002	1,005	1,006	1,005	1,005
V17	0,983	0,970	0,975	0,976	0,988	0,976	0,983	0,989	0,976	0,973
V18	1,012	1,012	1,013	1,011	1,011	1,012	1,011	1,011	1,013	1,011
V19	0,975	0,971	0,979	0,957	0,972	0,968	0,960	0,969	0,963	0,973
V20	0,993	1,007	0,994	0,999	0,999	1,003	1,014	1,005	0,998	0,991
V21	0,988	0,996	0,981	0,992	0,998	0,997	0,995	0,992	0,982	0,990
V22	0,999	1,002	0,999	0,997	0,999	0,997	0,997	1,003	0,993	1,001
V23	0,998	0,974	0,997	0,975	0,989	0,988	0,996	0,980	0,971	0,997

A.8. DESVIO DOS MELHORES RESULTADOS RETORNADOS PELO MOEPSO (I2)

Nesta seção estão os desvios percentuais dos despachos de menor distância euclidiana retornados pelas 10 simulações do MOEPSO da segunda implementação em relação ao despacho previamente especificado para o sistema-teste utilizado, especificando o quanto cada variável de controle foi modificada em comparação ao despacho pré-especificado.

Variável (%)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
$\Delta P1$	-33,3	-34,7	-33,7	-35,0	-33,7	-34,0	-36,0	-36,3	-31,0	-29,7
$\Delta P2$	9,5	9,6	9,6	9,4	10,4	11,8	11,6	9,4	9,3	9,0
$\Delta P3$	5,3	4,6	6,6	5,9	7,8	5,3	7,8	6,7	4,3	8,7
$\Delta P4$	-7,1	-9,3	-14,3	-2,9	-15,0	-13,6	-6,4	-8,6	-7,9	-13,6
$\Delta P5$	-8,0	-27,3	-33,3	-19,3	-0,7	2,0	-21,3	-5,3	-12,0	-14,0
$\Delta P6$	-33,0	-32,5	-38,0	-34,5	-27,5	-30,0	-33,5	-33,5	-33,0	-39,5
$\Delta P7$	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
$\Delta P8$	-4,9	4,7	-0,7	-4,7	-22,0	-22,6	0,4	-20,1	-17,6	7,0
$\Delta P9$	5,3	6,0	11,0	11,0	5,0	6,0	11,7	10,3	6,7	7,3
$\Delta P10$	10,0	10,3	8,8	12,8	8,0	11,3	9,8	7,5	12,5	7,5
$\Delta P11$	-119,5	-122,0	-92,0	-110,5	-103,5	-107,5	-91,0	-85,5	-111,5	-99,0
$\Delta P12$	15,0	7,7	8,3	10,0	11,7	10,0	11,0	13,7	13,7	12,0
$\Delta P13$	-8,3	-2,1	-3,9	-11,5	-11,4	-4,1	-11,8	-11,9	0,1	-9,1
$\Delta P14$	18,7	18,5	18,3	18,4	18,6	18,8	18,2	19,3	17,8	17,7
$\Delta P15$	17,2	17,4	16,9	17,3	16,9	17,2	16,9	17,3	16,8	16,7
$\Delta P16$	16,1	9,0	12,8	0,5	19,8	13,3	16,0	15,9	5,7	9,7
$\Delta P17$	4,6	3,3	6,7	5,9	3,7	4,0	7,1	1,0	6,4	4,4
$\Delta P18$	-7,1	-6,9	-7,6	-7,4	-7,4	-7,0	-6,0	-6,3	-7,1	-6,6
$\Delta P19$	10,3	12,0	9,4	9,3	10,6	12,3	12,7	11,6	8,6	8,3
$\Delta P20$	15,5	14,9	17,1	12,4	13,3	13,5	13,3	22,0	23,2	22,5
$\Delta P21$	4,0	4,0	6,0	6,0	6,0	4,0	6,0	4,0	6,0	4,0
$\Delta P22$	2,2	1,7	2,2	1,7	4,3	3,9	3,9	2,2	2,2	3,0
$\Delta P23$	-18,0	-16,0	-16,0	-22,0	-22,0	-22,0	-24,0	-24,0	-18,0	-22,0
$\Delta V1$	-1,20	2,20	-0,30	1,70	0,10	1,00	-1,20	1,70	1,30	0,30
$\Delta V2$	0,80	0,00	0,50	0,30	0,51	-0,40	0,30	-0,50	-0,10	0,10
$\Delta V3$	-0,99	-1,68	-1,78	-2,48	-1,49	-1,49	-1,19	-1,14	-1,19	-2,18
$\Delta V4$	0,40	0,70	2,60	1,40	1,70	3,00	2,30	2,20	2,80	2,20
$\Delta V5$	1,20	1,40	0,80	1,70	0,70	1,90	0,80	1,50	0,80	0,88
$\Delta V6$	-1,90	-3,20	-1,70	-2,52	-2,80	-4,20	-3,00	-1,30	-1,60	-3,90
$\Delta V7$	1,50	1,60	-0,30	0,90	1,60	0,90	1,10	1,50	1,20	0,10
$\Delta V8$	4,30	2,45	3,63	3,33	2,65	2,84	3,82	4,12	3,04	3,53
$\Delta V9$	-1,09	-0,99	-0,99	-0,99	-0,99	-1,09	-1,09	-0,99	-0,99	-0,99
$\Delta V10$	-0,88	0,49	-1,67	1,96	-0,78	0,39	-0,69	1,57	-1,36	1,57
$\Delta V11$	1,08	1,08	1,27	1,57	0,98	1,57	1,08	1,37	1,57	1,27
$\Delta V12$	1,70	2,30	1,70	2,60	1,40	0,46	1,50	0,30	1,90	1,80
$\Delta V13$	3,14	1,37	2,84	0,59	0,88	-0,49	0,49	3,14	0,10	1,27
$\Delta V14$	2,16	1,47	1,86	2,06	1,37	2,06	1,37	1,57	1,76	2,25
$\Delta V15$	2,84	0,49	1,08	1,47	1,37	1,18	2,35	1,96	1,57	2,55
$\Delta V16$	1,18	1,47	1,96	1,37	1,76	1,76	1,47	1,37	1,47	1,47
$\Delta V17$	3,63	4,90	4,41	4,31	3,14	4,31	3,63	3,04	4,31	4,61
$\Delta V18$	0,78	0,78	0,72	0,88	0,88	0,78	0,88	0,88	0,69	0,88
$\Delta V19$	2,50	2,90	2,10	4,30	2,80	3,20	4,02	3,10	3,70	2,70
$\Delta V20$	2,65	1,27	2,55	2,06	2,06	1,67	0,59	1,47	2,16	2,84
$\Delta V21$	2,18	1,39	2,87	1,78	1,19	1,29	1,49	1,78	2,77	1,98
$\Delta V22$	0,10	-0,20	0,10	0,30	0,10	0,30	0,30	-0,30	0,70	-0,10
$\Delta V23$	0,20	2,56	0,30	2,50	1,10	1,20	0,40	2,00	2,90	0,30

APÊNDICE B: VIOLAÇÕES EM CADA EQUIPAMENTO

B.1. RESULTADOS RETORNADOS PELO NSGA-II (I1)

Nesta seção são informadas as severidades percentuais das violações retornadas pelas 10 simulações (S1 até S10) do NSGA-II para a primeira implementação do FPORS, discriminados por cada caso de contingência (incluindo caso base) e exibindo os equipamentos nos quais ocorreram as violações. Tal como informado na Subseção 8.3, não houveram violações de reativo, portanto as violações de barra referem-se apenas à tensão, sendo que as sobretensões são referenciadas com sinal positivo e as subtensões com sinal negativo.

Contingência Avaliada	Equipto Avaliado	Severidade das Violações (%)									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Caso Base	Linha 1060-897	-	-	1,260	-	1,300	-	-	-	1,270	-
Contingência 1	Barra 895	+1,28	+1,32	+1,11	+1,22	+1,12	+1,28	+1,21	+1,34	+1,11	+1,20
	Barra 934	+1,25	+1,36	+1,08	+1,26	+1,14	+1,23	+1,22	+1,38	+1,09	+1,23
	Barra 938	+1,27	+1,33	+1,10	+1,24	+1,15	+1,24	+1,17	+1,35	+1,10	+1,24
	Barra 955	+1,23	+1,37	+1,07	+1,27	+1,11	+1,27	+1,18	+1,40	+1,08	+1,19
	Barra 959	-	-	+1,06	-	+1,10	-	-	-	+1,06	-
Contingência 2	Barra 895	+1,11	+1,19	+1,18	+1,65	+1,24	+1,10	+1,58	+1,20	+1,20	+1,60
	Barra 814	+1,10	+1,17	+1,19	+1,61	+1,22	+1,08	+1,54	+1,19	+1,22	+1,57
	Linha 122-895	1,086	1,162	1,168	-	1,211	1,093	-	1,178	1,191	-
Contingência 3	Barra 814	+1,54	+1,65	+1,62	+1,53	+1,71	+1,50	+1,43	+1,67	+1,67	+1,49
	Barra 895	+1,51	+1,61	+1,66	+1,50	+1,68	+1,53	+1,46	+1,64	+1,63	+1,46
Contingência 4	Barra 964	+1,27	+1,33	+1,36	+1,23	+1,41	+1,26	+1,28	-0,92	+1,39	+1,22
	Barra 965	+1,24	+1,36	+1,34	+1,26	+1,39	+1,24	+1,10	-0,91	+1,37	+1,20
	Barra 976	-	-	-	-	-	-	-	-0,90	-	-
Contingência 5	Barra 933	+1,25	+1,34	+1,32	+1,24	+1,37	+1,25	+1,19	+1,36	+1,34	+1,21
	Barra 938	+1,22	+1,31	+1,34	+1,21	+1,39	+1,22	+1,16	+1,33	+1,31	+1,18

B.2. RESULTADOS RETORNADOS PELO MOEPSO (II)

Nesta seção são informadas as severidades percentuais das violações retornadas pelas 10 simulações (S1 até S10) do MOEPSO para a primeira implementação do FPORS, discriminados por cada caso de contingência (incluindo caso base) e exibindo os equipamentos nos quais ocorreram as violações. Tal como informado na Subseção 8.3, não houveram violações de reativo, portanto as violações de barra referem-se apenas à tensão, sendo que as sobretensões são referenciadas com sinal positivo e as subtensões com sinal negativo.

Contingência Avaliada	Equipto Avaliado	Severidade das Violações (%)									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Caso Base	Linha 1060-897	1,310	-	-	-	-	1,320	1,310	-	1,310	-
Contingência 1	Barra 814	+1,31	+1,39	+1,40	+1,31	+1,39	+1,35	+1,29	+1,25	+1,29	+1,35
	Barra 895	+1,26	+1,35	+1,32	+1,34	+1,29	+1,36	+1,35	+1,30	+1,35	+1,37
	Barra 933	+1,28	+1,37	+1,36	+1,27	+1,36	+1,28	+1,26	+1,29	+1,26	+1,32
	Barra 934	+1,27	+1,38	+1,37	+1,30	+1,37	+1,33	+1,32	+1,22	+1,32	+1,39
	Barra 938	+1,30	+1,33	+1,33	+1,36	+1,31	+1,31	+1,30	+1,33	+1,30	+1,33
	Barra 939	+1,21	+1,34	+1,39	+1,35	+1,32	+1,30	+1,36	+1,31	+1,36	+1,36
	Barra 955	+1,23	+1,31	+1,31	+1,28	+1,28	+1,27	+1,27	+1,24	+1,27	+1,31
	Barra 959	+1,22	+1,30	+1,29	+1,32	+1,35	+1,37	+1,34	+1,27	+1,34	+1,29
	Barra 960	+1,25	+1,29	-	+1,26	-	-	-	+1,21	-	+1,28
Contingência 2	Barra 814	+1,22	+1,30	+1,44	+1,27	+1,39	+1,38	+1,40	+1,27	+1,40	+1,35
	Barra 895	+1,26	+1,34	+1,42	+1,31	+1,41	+1,40	+1,38	+1,22	+1,35	+1,28
	Barra 933	+1,21	+1,29	+1,38	+1,30	+1,42	+1,41	+1,34	+1,25	+1,36	+1,32
	Barra 934	+1,27	+1,35	+1,39	+1,32	+1,36	+1,35	+1,36	+1,26	+1,37	+1,29
	Barra 955	+1,25	+1,33	+1,41	+1,26	+1,38	+1,37	+1,37	+1,21	+1,39	+1,33
	Linha 122-895	1,196	1,274	-	1,245	-	-	-	1,198	-	1,267
Contingência 3	Barra 814	+1,36	+1,25	+1,33	+1,46	+1,31	+1,30	+1,27	+1,36	+1,27	+1,22
	Barra 895	+1,38	+1,23	+1,28	+1,41	+1,28	+1,27	+1,24	+1,39	+1,28	+1,18
	Barra 933	+1,34	+1,24	+1,30	+1,43	+1,26	+1,28	+1,29	+1,35	+1,29	+1,25
	Barra 934	+1,40	+1,19	+1,29	+1,44	+1,30	+1,29	+1,26	+1,40	+1,24	+1,20
	Barra 955	+1,37	+1,20	+1,32	+1,40	+1,29	+1,25	+1,28	+1,37	+1,26	+1,23
	Barra 959	-	+1,18	-	-	-	-	-	-	-	+1,17
Contingência 4	Barra 955	+1,44	+1,20	+1,33	+1,20	+1,30	+1,30	+1,33	+1,43	+1,29	+1,51
	Barra 964	+1,40	+1,21	+1,36	+1,16	+1,31	+1,29	+1,29	+1,44	+1,32	+1,53
	Barra 965	+1,42	+1,23	+1,37	+1,18	+1,34	+1,34	+1,32	+1,40	+1,33	+1,47
	Barra 976	+1,38	+1,19	+1,32	+1,19	+1,35	+1,33	+1,28	+1,38	+1,28	+1,48
	Barra 1210	-	+1,18	-	+1,15	-	-	-	-	-	-
Contingência 5	Barra 933	+1,42	+1,51	+1,31	+1,48	+1,07	+1,27	+1,30	+1,38	+1,32	+1,20
	Barra 938	+1,36	+1,50	+1,34	+1,43	+1,04	+1,31	+1,31	+1,41	+1,28	+1,17
	Barra 939	+1,38	+1,45	+1,35	+1,46	+1,05	+1,29	+1,26	+1,42	+1,30	+1,18
	Barra 964	+1,40	+1,47	+1,30	+1,42	+1,06	+1,32	+1,28	+1,37	+1,26	+1,19
	Barra 965	-	-	-	-	+1,03	-	-	-	-	+1,15

B.3. RESULTADOS RETORNADOS PELO NSGA-II (I2)

Nesta seção são informadas as severidades percentuais das violações retornadas pelas 10 simulações (S1 até S10) do NSGA-II para a segunda implementação do FPORS, discriminados por cada caso de contingência e exibindo os equipamentos nos quais ocorreram as violações. Tal como informado na Subseção 8.4, não houveram violações de reativo, portanto as violações de barra referem-se apenas à tensão, sendo que as sobretensões são referenciadas com sinal positivo e as subtensões com sinal negativo, assim como não houveram violações no caso base.

Contingência Avaliada	Equipto Avaliado	Severidade das Violações (%)									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Contingência 1	Barra 895	+1,25	+1,20	+1,33	+1,32	+1,28	+1,37	+1,20	+1,36	+1,32	+1,43
	Barra 934	+1,20	+1,21	+1,27	+1,33	+1,23	+1,41	+1,23	+1,37	+1,28	+1,41
	Barra 938	+1,21	+1,19	+1,29	+1,36	+1,24	+1,39	+1,24	+1,33	+1,30	+1,37
	Barra 955	+1,24	+1,18	+1,31	+1,37	+1,27	+1,43	+1,19	+1,32	+1,26	+1,38
	Barra 959	-	+1,16	-	-	-	-	-	-	-	-
Contingência 2	Barra 895	+1,62	+1,31	+1,12	+1,17	+1,10	+1,23	+1,60	+1,17	+1,14	+1,22
	Barra 814	+1,58	+1,28	+1,13	+1,19	+1,08	+1,21	+1,57	+1,19	+1,11	+1,23
	Linha 122-895	-	1,293	1,145	1,162	1,093	1,220	-	1,162	1,123	1,205
Contingência 3	Barra 814	+1,47	+1,21	+1,59	+1,64	+1,50	+1,12	+1,48	+1,65	+1,54	+1,14
	Barra 895	+1,50	+1,19	+1,55	+1,61	+1,53	+1,13	+1,45	+1,61	+1,58	+1,13
	Barra 933	-	+1,20	-	-	-	+1,14	-	-	-	+1,12
Contingência 4	Barra 964	+1,21	+1,50	+1,31	+1,35	+1,26	+1,38	+1,22	+1,36	+1,27	+1,41
	Barra 965	+1,23	+1,47	+1,28	+1,33	+1,24	+1,41	+1,20	+1,33	+1,30	+1,38
Contingência 5	Barra 933	+1,21	+1,48	+1,26	+1,33	+1,22	+1,39	+1,20	+1,31	+1,28	+1,36
	Barra 938	+1,19	+1,45	+1,29	+1,31	+1,24	+1,36	+1,18	+1,34	+1,26	+1,39

B.4. RESULTADOS RETORNADOS PELO MOEPSO (I2)

Nesta seção são informadas as severidades percentuais das violações retornadas pelas 10 simulações (S1 até S10) do MOEPSO para a segunda implementação do FPORS, discriminados por cada caso de contingência e exibindo os equipamentos nos quais ocorreram as violações. Tal como informado na Subseção 8.4, não houveram violações de reativo, portanto as violações de barra referem-se apenas à tensão, sendo que as sobretensões são referenciadas com sinal positivo e as subtensões com sinal negativo, assim como não houveram violações no caso base.

Contingência Avaliada	Equipto Avaliado	Severidade das Violações (%)									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Contingência 1	Barra 895	+1,55	+1,62	+1,16	+1,56	+1,56	+1,56	+1,22	+1,54	+1,51	+1,56
	Barra 934	+1,52	+1,64	+1,18	+1,53	+1,58	+1,58	+1,21	+1,55	+1,48	+1,58
	Barra 938	+1,53	+1,61	+1,19	+1,55	+1,59	+1,55	+1,19	+1,57	+1,49	+1,55
	Barra 955	-	-	+1,14	-	-	-	+1,17	-	-	-
Contingência 2	Barra 895	+1,52	+1,61	+1,51	+1,01	+1,04	+1,01	+1,55	+1,02	+1,48	+1,03
	Barra 814	+1,49	+1,57	+1,54	+1,02	+1,03	+1,02	+1,58	+1,01	+1,45	+1,02
	Linha 122-895	-	-	-	1,000	1,020	1,030	-	1,003	-	1,013
Contingência 3	Barra 814	+1,49	-0,95	+1,42	+1,42	+1,43	-0,97	+1,42	+1,37	+1,43	+1,40
	Barra 895	+1,46	-0,93	+1,39	+1,44	+1,40	-0,95	+1,39	+1,34	+1,41	+1,43
	Barra 933	-	-0,94	-	-	-	-0,96	-	-	-	-
Contingência 4	Barra 964	+1,16	+1,22	+1,15	+1,17	+1,19	+1,16	+1,20	+1,15	+1,13	+1,18
	Barra 965	+1,13	+1,20	+1,18	+1,14	+1,17	+1,18	+1,18	+1,17	+1,10	+1,16
Contingência 5	Barra 933	+1,12	+1,21	+1,16	+1,13	+1,18	+1,16	+1,19	+1,16	+1,19	+1,17
	Barra 938	+1,14	+1,18	+1,14	+1,15	+1,15	+1,14	+1,16	+1,13	+1,01	+1,14

ANEXO I: ABORDAGEM MONO-OBJETIVA DO PROBLEMA

Nesta seção será descrito o artigo “Otimização Natural como Alternativa para a Obtenção do Despacho Seguro de Sistemas Elétricos de Potência”, de autoria conjunta de Rene Cruz Freire (autor desta dissertação), Vitor Hugo Ferreira (orientador deste trabalho) e Pedro Reis Soares da Costa, que busca resolver o mesmo problema apresentado neste documento, mas de um ponto de vista da otimização mono-objetiva, e cujos resultados foram utilizados para realizar a comparação entre os vieses mono e multiobjetivo. O artigo foi publicado nos anais do XIX Congresso Brasileiro de Automática (CBA 2012) e está referenciado em [8].

I.1. RESUMO

A segurança de um sistema de potência pode ser entendida como a capacidade de um sistema manter sua estabilidade na ocorrência de algumas perturbações estabelecidas previamente, ou seja, uma lista de contingências pré-selecionadas. Sob o ponto de vista da segurança, a determinação de um ponto de operação ótimo e seguro de um dado sistema elétrico de potência reside na definição de um conjunto de controles que otimizam o critério de operação considerado e que simultaneamente garantam a manutenção da estabilidade do sistema na ocorrência de cada contingência especificada. Este problema pode ser formulado como um problema de otimização conhecido como fluxo de potência ótimo considerando restrições de segurança (FPOCRS). Este trabalho tem por objetivo o estudo de algoritmos de otimização natural como alternativa para obtenção de um ponto de operação seguro através da solução do problema de FPOCRS. Neste trabalho serão considerados somente aspectos de segurança estática. Os métodos de otimização implementados em MATLAB® são comparados utilizando dados de sistemas teste reais encontrados na literatura.

I.2. INTRODUÇÃO

A operação segura e econômica de sistemas elétricos de potência constitui um dos principais objetivos dos responsáveis pela operação de tais sistemas. No caso brasileiro, a missão do Operador Nacional do Sistema Elétrico (ONS) consiste em “operar o Sistema Interligado Nacional de forma integrada, com transparência, equidade e neutralidade, de modo a garantir a segurança, a continuidade e a economicidade do suprimento de energia elétrica no país” (ONS, 2012). Neste contexto, para obtenção de estratégias de operação que visam à operação segura e econômica da rede são necessárias ferramentas de análise, controle

e otimização de sistemas elétricos de potência e sua integração em um ambiente de auxílio à tomada de decisão.

Um sistema de potência está em um ponto de operação seguro para uma determinada lista de contingências se na ocorrência de cada possível contingência o sistema conseguir manter os fluxos nas linhas, tensões e ângulos nas barras dentro de patamares seguros definidos pelos operadores da rede (Balu et. al. 1992).

Os estudos para avaliação da segurança de sistemas de potência podem ser divididos em dois grandes grupos relacionados basicamente com a escala de tempo dos fenômenos: segurança estática e segurança dinâmica. A análise de segurança estática avalia o estado operativo do sistema desconsiderando os transitórios envolvidos na ocorrência de cada contingência. Estes estudos consideram o desempenho da rede em regime permanente após a perturbação em análise. Por outro lado, a análise de segurança dinâmica considera a evolução temporal do sistema a partir da contingência em questão, avaliando principalmente questões de estabilidade da rede. Existem na literatura diversos estudos sobre análise de segurança estática (Stott, Alsac and Monticelli, 1987), (Devaraj and Yegnanarayana, 2005), (Bakirtzis et. al, 2002) e (Dent et. al., 2010) e dinâmica (Esmín, Lambert-Torres and Zambroni de Souza, 2005), (Mo et. al., 2007), (Voumvoulakis and Hatziargyriou, 2010) e (Xin et. al., 2010). Discussões sobre as principais questões e ferramentas envolvidas na análise de segurança de sistemas de potência podem ser encontradas em (Balu et. al., 1992), (Stott, Alsac and Monticelli, 1987) e (Shahidehpour, Tinney and Fu, 2005).

A determinação de um ponto de operação ótimo e seguro consiste na definição de um conjunto de controles que minimizam um determinado critério de operação (por exemplo, custo de operação) garantindo simultaneamente a operação dos equipamentos dentro dos seus limites operativos. Este problema pode ser formulado como um problema de otimização conhecido como Fluxo de Potência Ótimo (FPO) (Stott, Alsac and Monticelli, 1987). Formulado como um problema de otimização (programação) não-linear com restrições, a literatura apresenta diversos métodos clássicos de solução de problemas desta natureza, tais como métodos de programação não-linear (Stott, Alsac and Monticelli, 1987) e programação quadrática (Burchett, Happ and Wirgau, 1982). Existem propostas que tem por objetivo identificar os pontos que atendem as condições de otimalidade de Karush-Kuhn-Tucker, utilizando, por exemplo, método de Newton para a solução do sistema não linear de equações que definem tais condições de otimalidade de problemas de otimização não linear com restrições (Sttot, Alsac e Monticelli, 1987). Método dos Pontos Interiores, que convertem as

restrições de desigualdade em restrições de igualdade por meio da inserção de variáveis de folga, também vem sendo utilizados para a solução do FPO (Wei et. al., 1998), (Lambert-Torres and Quintana, 1998), (Momoh and Zhu, 1999) e (Jiang et. al., 2010)

Os métodos clássicos de programação não-linear vêm apresentando resultados satisfatórios como solução ao problema de FPO, contudo, apresentam ainda algumas limitações, tais como estagnação em mínimos locais em problemas de otimização não-convexos (Bakirtzis, et. al., 2002). Visando superar as limitações dos métodos clássicos, técnicas de inteligência computacional inspiradas na natureza, como algoritmos genéticos (Bakirtzis, et. al., 2002), (Devaraj and Yegnanarayana, 2005) e enxame de partículas (Esmín, Lambert-Torres and Zambroni de Souza, 2005), vêm sendo aplicadas recentemente como solução para o problema de FPO. Assim, este trabalho tem por objetivo o estudo de técnicas de otimização natural como alternativa para obtenção do despacho seguro de sistemas de potência. Neste estudo inicial serão consideradas somente restrições de segurança estática relacionadas com violações de limites de fluxo de potência em linhas, tensões em barras e limites de geração.

I.3. FLUXO DE POTÊNCIA ÓTIMO CONSIDERANDO RESTRIÇÕES DE SEGURANÇA (FPORCS)

O problema de fluxo de potência ótimo (FPO) constitui uma ativa linha de pesquisa na área de sistemas de potência desde o seu surgimento na década de 1960, a partir do trabalho pioneiro de Carpentier apresentando uma formulação do problema de despacho econômico considerando restrições da rede elétrica em 1962 juntamente com a definição do FPO cunhado por Dommel e Tinney em 1968 (Dommel and Tinney, 1968). Os estudos de FPO têm por objetivo a determinação de um conjunto de controles de um sistema elétrico de potência visando otimizar um dado critério e simultaneamente satisfazer um conjunto de restrições operativas, tais como limites de geração, limites de tensão e limites de fluxo em linhas. Esta ferramenta vem sendo utilizada extensivamente em estudos de planejamento da operação e da expansão de redes elétricas, podendo ser formulado matematicamente como:

$$\min_{\underline{x}} f(\underline{x}) \quad (\text{I.1})$$

Sujeito a:

$$\begin{cases} \underline{g}(\underline{x}) = \underline{0} \\ \underline{h}(\underline{x}) \leq \underline{0} \end{cases}$$

Onde $f(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^n$ representa o critério a ser otimizado, $\underline{x} \in \mathbb{R}^n$ consiste no vetor com as n variáveis de decisão ou controles a serem especificados, $\underline{g}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^n$ representa as n_{igual} restrições de igualdade e $\underline{h}(\underline{x}): \mathbb{R}^n \rightarrow \mathbb{R}^n$ representa as n_{des} restrições de desigualdade. Este conjunto de restrições inclui as equações de fluxo de potência e os limites operativos a serem atendidos.

A inclusão de restrições de segurança ao problema de FPO dá origem ao chamado fluxo de potência ótimo considerando restrições de segurança (FPOCRS) (*security constrained optimal power flow – SCOPF*) (Wood and Wollenberg, 1996). Tendo como objetivo, por exemplo, a minimização do custo de operação e utilizando como variáveis de controle somente os despachos de potência ativa das unidades geradoras, o FPOCRS passa a ser visto como uma formulação mais geral do tradicional problema de despacho econômico, passando neste caso a considerar restrições tanto da rede elétrica quanto de segurança.

1.3.1. DETERMINAÇÃO DO DESPACHO SEGURO COMO UM PROBLEMA DE FLUXO DE POTÊNCIA ÓTIMO

Um ponto de operação é considerado seguro se tanto para a rede completa quanto para uma lista de contingências especificada o fornecimento de energia é garantido sem violação de limites de quaisquer equipamentos da rede em análise. A obtenção deste ponto de operação pode ser formulada como um problema de otimização onde o objetivo reside na especificação de um conjunto de controles que minimize o número de restrições não atendidas, com o ponto de operação seguro sendo obtido quando todas as restrições são atendidas. Matematicamente este problema pode ser formulado como segue:

$$\min_{\underline{x}} \sum_{i=1}^{N_{rest}} rest_i(\underline{x}) \quad (I.2)$$

Onde $rest_i(\underline{x}): \mathbb{R}^n \rightarrow [0,1]$ é igual a zero se a i -ésima restrição for atendida e igual a um caso contrário. Como a função objetivo dada na equação (I.2) não é continuamente diferenciável, métodos clássicos de programação não-linear não podem ser utilizados para solução deste problema.

Considerando como variáveis de controle somente as tensões em barras de geração e os despachos de potência ativa, e como restrições os limites de carregamento em linhas de

transmissão, os limites de geração de potência ativa e reativa das unidades geradoras, os limites de tensão nos barramentos e o comportamento em regime permanente da rede, a solução do problema formulado em (I.2) permite a obtenção de um ponto de operação seguro sob o ponto de vista de segurança estática. Especificações de controles onde não ocorra convergência no cálculo do fluxo de potência são consideradas como não atendendo todas as restrições de igualdade dado que não resolvem o sistema de equações que define o fluxo de potência. Exemplificando, considerando uma lista de contingências com cinco possíveis falhas (caso base mais cinco configurações) e um conjunto de controles onde não seja possível o cálculo do fluxo de potência para três configurações, o número de violações será igual a $3(2N_{barras} - 1)$ mais as violações que existam para as outras três configurações onde o fluxo de potência convergiu, com N_{barras} representando o número de barras do sistema.

A busca por um ponto de operação visando somente aspectos de segurança pode dar origem a despachos que não atendam outros critérios, por exemplo, questões econômicas. Na verdade, segurança e economicidade constituem objetivos conflitantes que devem ser balanceados. Visando melhorar a segurança de um ponto de operação previamente especificado, por exemplo, via despacho econômico, o problema de obtenção do despacho seguro por ser reformulado da maneira que segue:

$$\min_{\underline{x}} f(\underline{x}) = \Delta_{ponto}(\underline{x}) + \Delta_{rest}(\underline{x}) + \Delta_{conv}(\underline{x}) \quad (I.3)$$

Onde:

$$\Delta_{ponto}(\underline{x}) = \sum_{i=1}^{N_{cont}} \frac{|x_i - x_i^{esp}|}{x_i^{esp}} \quad (I.4)$$

$$\Delta_{rest}(\underline{x}) = \sum_{j=1}^{N_{rest}} \Omega_j(\underline{x}) \quad (I.5)$$

$$\Delta_{conv}(\underline{x}) = \sum_{k=1}^{N_{casos}} (2N - 1)c_k(\underline{x}) \quad (I.6)$$

Nas expressões acima, $\Delta_{ponto}(\underline{x})$ representa o desvio percentual do novo ponto de operação \underline{x} em relação ao ponto de operação previamente especificado \underline{x}^{esp} ; $\Delta_{rest}(\underline{x})$ representa o desvio percentual da variável monitorada em relação aos seus limites, calculado como:

$$\Omega_j(\underline{x}) = \begin{cases} 0, w_j^{min}(\underline{x}) \leq w_j(\underline{x}) \leq w_j^{max}(\underline{x}) \\ \frac{|w_j(\underline{x}) - w_j^{lim}(\underline{x})|}{w_j^{lim}(\underline{x})}, \text{ caso contrário} \end{cases} \quad (I.7)$$

Com $w_j^{lim}(\underline{x}) \in \mathbb{R}$ respondendo pelo limite violado, por exemplo, $w_j^{lim}(\underline{x}) = w_j^{max}(\underline{x})$ se $w_j(\underline{x}) \geq w_j^{max}(\underline{x})$. Por fim, $\Delta_{conv}(\underline{x})$ representa o desvio percentual devido a não-convergência do fluxo de potência para um determinado caso, com a função $c_k(\underline{x})$ dada por:

$$c(\underline{x}) = \begin{cases} 0, & \text{ caso o fluxo de potência convirja} \\ 1, & \text{ caso contrário} \end{cases} \quad (I.8)$$

Assim, despachos onde o fluxo de potência não convirja para um determinado caso são considerados como violações de 100% das restrições de igualdade do problema original.

A função objetivo dada pela equação (I.3) é uma forma de buscar um ponto de operação seguro que provoque o mínimo de alterações no ponto de operação original. O uso do desvio percentual permite a soma direta dos desvios tanto em relação ao não atendimento das restrições quanto em relação à mudança do ponto de operação previamente especificado, não requerendo assim o uso de ponderadores para conversão de unidades. A utilização de ponderadores poderia ser incluída na formulação, trazendo consigo a necessidade de especificação deste parâmetro.

I.4. OTIMIZAÇÃO NATURAL

As técnicas de otimização natural constituem uma linha de pesquisa da área de Inteligência Computacional que engloba um conjunto de metodologias inspiradas no comportamento de sistemas da natureza para solução de problemas de otimização. Como exemplos de técnicas de otimização natural podem ser citadas técnicas de busca local como recozimento simulado (Monticelli, Romero and Asada, 2006) e técnicas de busca global como algoritmos genéticos (Eiben and Smith, 2007) e enxame de partículas (Kennedy and Eberhart, 1995), dentre outros. Estas técnicas realizam uma busca estocástica pelo espaço de soluções tendo como objetivo localizar regiões com soluções promissoras evitando assim a convergência prematura em mínimos locais.

1.4.1. RECOZIMENTO SIMULADO (RS)

O RS foi proposto nos anos 50 baseado em conceitos de mecânica estatística aplicados à cristalização de materiais (Monticelli, Romero and Asada, 2006). Posteriormente por volta dos anos 80 pesquisadores (Kirkpatrick, Gellat Jr and Vecchi, 1983) sugeriram a investigação da semelhança entre o processo de recozimento e problemas de otimização combinatória, comparando o estado físico do material ao longo do recozimento e o espaço da solução de um problema de otimização.

O RS escolhe aleatoriamente para uma temperatura inicial (T_0) uma solução inicial (x_0) chamada de estado inicial. No próximo estado, uma nova solução será formada através da perturbação (ε) no valor do estado anterior. A solução mudará se a solução do próximo estado possuir um estado de energia menor, o que significa encontrar uma solução de menor custo. Em contrapartida, se a próxima solução possuir um estado de energia maior, ou seja, maior custo, uma probabilidade q será aplicada para determinar se o novo estado será aceito ou não, probabilidade esta calculada pela expressão:

$$q_k = e^{\left(\frac{E_k - E_{k-1}}{k_b T_k}\right)} \quad (I.9)$$

Assim que um número especificado de transições é alcançado, a temperatura diminui e o processo recomeça novamente. De acordo com esta metodologia, aceitar soluções com custos elevados permite que o processo de solução do RS escape de regiões com soluções ótimas locais para regiões com soluções de melhor qualidade (Wong and Wong, 1994). O processo iterativo estará terminado quando não houver uma melhora significativa na solução ou quando o número máximo de iterações for alcançado.

Existem diversos métodos para variar a temperatura T_{k+1} a partir da temperatura no estado imediatamente anterior. O mais comum é o esquema de resfriamento exponencial proposto por (Kirkpatrick, Gellat and Vecchi, 1983) dado por:

$$T_{k+1} = 0,95T_k \quad (I.10)$$

1.4.2. ALGORITMOS GENÉTICOS (AG)

Os AGs são métodos de otimização natural baseados no processo evolutivo natural das espécies e foi introduzido por John Holland em 1975 (Holland, J., 1975). Eles combinam a lei da sobrevivência do mais apto com uma estrutura de troca de informações em uma população

de criaturas artificiais, assemelhando-se a amostras do espaço de busca do problema. Durante as últimas duas décadas tem sido aplicado com sucesso na solução de diversos problemas complexos de otimização em ciência, engenharia e negócios (Zoumas et. al., 2004). Além disso, tem sido amplamente utilizados na solução de problemas através da modelagem de uma função objetivo, criada considerando todos os parâmetros envolvidos.

Uma característica que aumenta o escopo de aplicação dos AGs é a possibilidade de aplicação mesmo que não haja nenhum conhecimento prévio da função a ser otimizada, como linearidade, convexidade, continuidade ou existência de derivadas. O único requisito é que a avaliação da função adequabilidade produza um resultado para cada solução gerada. Outro aspecto importante é o conceito de população como soluções candidatas, ao invés de usar um ponto singular e informação do gradiente local, eles utilizam um grupo de soluções candidatas que representam uma população, permitindo a troca de informações entre soluções situadas em regiões distintas do espaço de busca. Cada indivíduo é chamado de cromossomo e é formado por genes que mantêm as características encontradas na solução produzida.

Para alcançar bons resultados, é necessário definir um número suficiente de gerações, e para cada geração, uma nova população é criada baseada na população criada anteriormente e assim sucessivamente. O critério de parada do algoritmo ocorre quando não há uma melhora significativa na solução para um determinado número de gerações ou quando o número máximo de gerações é alcançado.

1.4.3. ENXAME DE PARTÍCULAS (EP)

O EP é um método de otimização natural inspirado no comportamento de enxames de algumas espécies de animais, criado na década de 90 por Russ Eberhart e James Kennedy (Kennedy and Eberhart, R., 1995). Assim como o AG, o EP também trabalha com um conjunto de soluções iniciais, geradas de forma aleatória, arbitrária ou utilizando algum conhecimento sobre o problema, e não requer conhecimento prévio da função a ser otimizada, ou seja, a função objetivo é utilizada apenas como medida da qualidade da solução de uma partícula. Além das soluções iniciais, o EP requer a definição da velocidade inicial de cada partícula. A partícula é equivalente ao cromossomo no EP e representa as soluções candidatas, já o conceito de população possui o mesmo significado em ambos os métodos.

Neste método, cada partícula voa no espaço de solução, sendo modelada por vetores posição e velocidade que representam as soluções candidatas e as soluções modificadas,

respectivamente. As expressões para atualização das velocidades e da posição das partículas são dadas por:

$$v_i(k+1) = w(k)v(k) + a_1\gamma_{1i}(k)[p_i(k) - x_i(k)] + a_2\gamma_{2i}(k)[g_i(k) - x_i(k)] \quad (\text{I. 11})$$

$$x_i(k+1) = x_i(k) + v_i(k+1) \quad (\text{I. 12})$$

A modificação das soluções é orientada a partir da melhor solução encontrada pela partícula ($p_i(k)$) como também da melhor solução encontrada pelo enxame ($g_i(k)$). Assim, o EP utiliza informações individuais e coletivas para tomada da decisão na busca por soluções ótimas.

I.5. RESULTADOS

As técnicas de otimização descritas na seção anterior foram avaliadas para obtenção do despacho seguro de um sistema-teste com 107 barras, 22 geradores e um compensador síncrono. Portanto, devem ser especificados 45 controles (despachos dos 22 geradores e tensão das 23 barras de tensão controlada). Este sistema compreende segmentos do Sistema Interligado Nacional (SIN) e seus dados podem ser encontrados em (Alves, 2007), incluindo os limites dos equipamentos. As tensões em todos os barramentos devem estar entre 0,9 e 1,1 [pu]. A Figura 1 apresenta o diagrama unifilar deste sistema.

A lista de contingências é definida considerando a saída individual das cinco linhas mais carregadas para o caso base. Para o cálculo do fluxo de potência foi utilizada a toolbox PSAT (Milano, Vanfretti and Morataya, 2008). A Tabela I apresenta a lista de contingências considerada neste trabalho.

Tabela I – Lista de Contingências: Saída Individual de Cada uma das Cinco Linhas mais Carregadas para o Caso Base

Contingência	Linha	Barra DE	Barra PARA	S (MVA)
1	97	856	933	1960,336
2	105	933	895	1280,854
3	107	933	959	1184,858
4	132	995	1060	976,7270
5	134	1030	955	962,9778

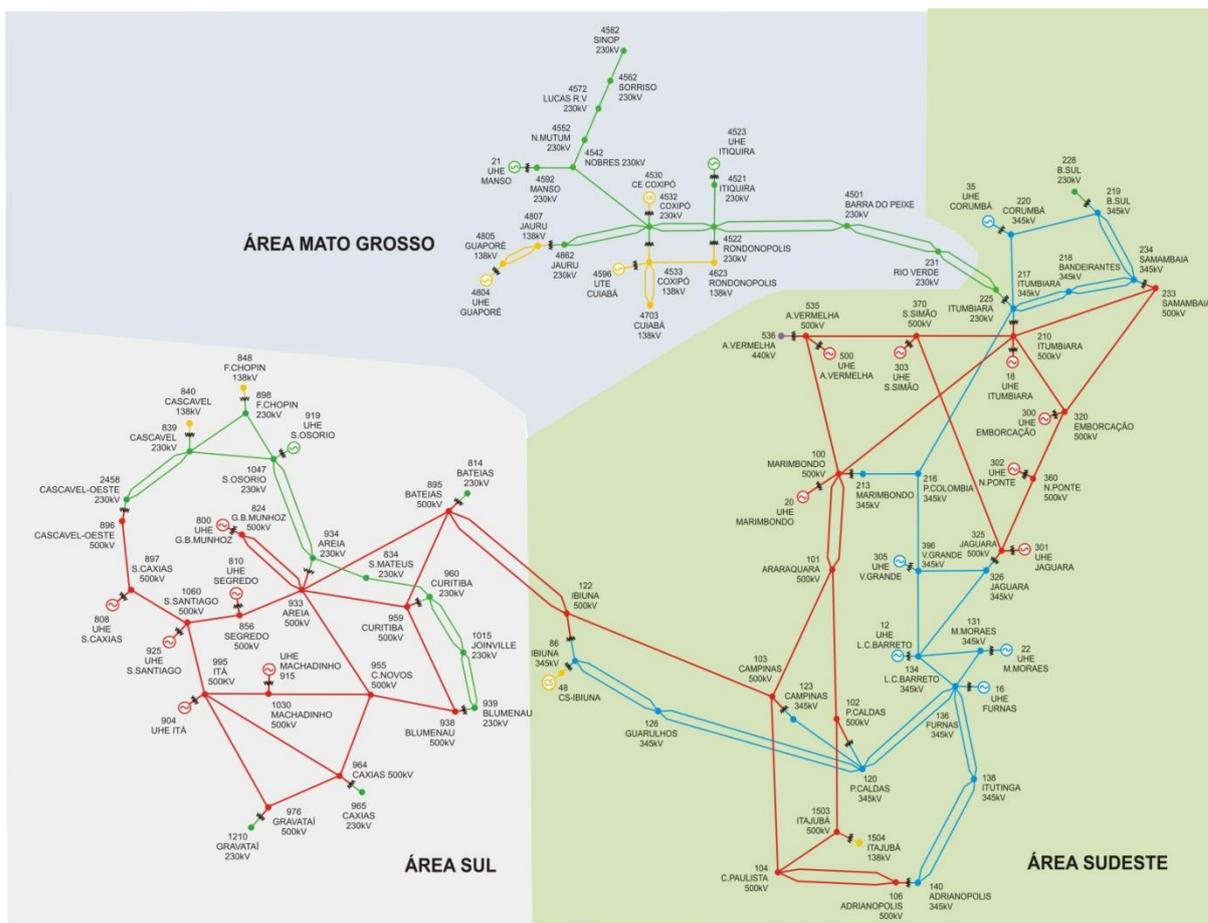


Figura I – Sistema-teste utilizado (Alves, 2007)

As técnicas de otimização natural utilizadas neste trabalho requerem a especificação de alguns parâmetros, os quais foram definidos após intensivos testes. As especificações com os melhores resultados são apresentadas na Tabela II (AG), Tabela III (RS) e Tabela IV (EP).

Tabela II – Parâmetros do Algoritmo Genético

Parâmetros	Valor
Gerações	500
Tamanho da População	15
Gerações Estagnadas	5
Tempo de Simulação	3600 s
Taxa de Crossover	90%
Tolerância da Função	0
Seleção	Roleta
Mutação	Uniforme
Cruzamento	Aritmético

Além dos parâmetros definidos para os algoritmos, foi criada uma função para gerar a população inicial dos algoritmos globais (AG e EP) a partir de uma distribuição gaussiana multivariada, com vetor média igual ao despacho para o caso base e matriz de covariância

diagonal onde cada elemento diagonal corresponde ao equivalente do vetor média. O despacho do caso base também foi utilizado com solução inicial para o RS.

Tabela III – Parâmetros do Recozimento Simulado

Parâmetros	Valor
Iterações	500
Temperatura Inicial	100
Solução Inicial	Caso Base

Tabela IV – Parâmetros do Enxame de Partículas

Parâmetros	Valor
Número de Evoluções	500
Tamanho do Enxame	15
$w_{inicial}(k)$	0,9
$w_{final}(k)$	0,4
$\gamma_{1i}(k)$	2
$\gamma_{2i}(k)$	2

Os resultados obtidos por cada um dos métodos de otimização natural utilizados neste trabalho para minimização de F01 (equação (I.2)) são apresentados na Tabela V, com as estatísticas relacionadas com esforço computacional sendo apresentadas na Tabela VI. Para cada método, foram realizadas 10 simulações sendo apresentados nestas Tabelas o melhor e o pior resultado, como também a média entre os resultados obtidos nas dez simulações. Os resultados apresentados na Tabela V mostram o desempenho superior obtido pelos métodos de busca global (AG e EP) que conseguiram obter o despacho seguro (F01 igual a zero). O RS, ainda que bem mais rápido do ponto de vista de esforço computacional, obtêm despachos com número elevado de violações (onze violações no melhor caso).

Os despachos obtidos pelos métodos, como também o despacho base (Alves, 2007) são apresentados na Tabela VII, onde também são apresentados os valores de F01 (contador de restrições não-atendidas), $\Delta_{ponto}(\underline{x})$ (distância percentual entre o despacho obtido e o despacho de referência – caso base), $\Delta_{rest}(\underline{x})$ (soma das violações percentuais de cada restrição não-atendida) e F02 para cada despacho apresentado nesta Tabela. Na ocorrência da contingência 1 o despacho definido pelo caso base não consegue atender a demanda (fluxo de potência divergente). Assim, para garantir um despacho com fluxo de potência convergente para todas as configurações (caso base e contingências) e ao mesmo tempo reduzir o esforço computacional, se para uma contingência o fluxo de potência divergir o custo F01 será igual ao custo para um despacho onde o fluxo de potência é divergente para todas as configurações

(caso base e contingências). Esta consideração também é feita para o cálculo de $\Delta_{conv}(\underline{x})$ necessário para o cálculo de F02, e como o despacho base é igual ao despacho especificado, os valores de F01 e F02 apresentados na Tabela VII são realmente próximos visto que $\Delta_{ponto}(\underline{x})$ é igual a zero neste caso.

Tabela V – Resultados da Minimização de F01

Método	RS	AG	EP
Mínimo	11	0	0
Máximo	35	13	9
Média	21,70	5,30	2,75

Tabela VI – Tempo de Simulação para a Minimização de F01 (em horas)

Método	RS	AG	EP
Mínimo	0,0816	0,9178	0,5801
Máximo	0,3395	0,9597	0,9474
Média	0,1907	0,9342	0,7652

**Tabela VII – Despacho Base e Despachos Obtidos pelos Métodos de Otimização Natural
Visando Minimizar F01**

Controles	Base	RS	AG	EP
P1	3,00	10,72	4,48	10.54
P2	8,00	9,28	6,62	6.11
P3	9,00	11,37	8,49	14.34
P4	1,40	0,54	1,06	1.06
P5	1,50	0,88	1,69	0.78
P6	2,00	3,29	2,00	3.36
P7	7,00	6,59	6,77	6.14
P8	3,00	1,79	3,21	1.74
P9	4,00	3,89	3,53	4.05
P10	2,00	6,43	10,7	5.91
P11	3,00	3,72	2,32	1.24
P12	8,00	7,00	8,84	6.7
P13	11,00	11,97	12,58	12.74
P14	11,50	5,75	6,68	7.42
P15	12,00	10,21	7,00	6.58
P16	7,00	8,64	12,16	7.33
P17	7,00	6,38	6,96	8.01
P18	7,00	1,63	6,13	5.8
P19	9,50	8,26	6,60	7.95
P20	0,50	0,40	0,49	0.61
P21	2,30	2,70	2,59	2.51
P22	0,50	0,93	0,60	0.61
V1	1,000	0,947	0,999	0.99
V2	1,000	1,001	0,980	1.09

Controles	Base	RS	AG	EP
V3	1,010	1,039	1,029	1.02
V4	1,000	1,021	1,054	1.07
V5	1,000	0,926	1,037	0.98
V6	1,000	0,992	0,976	0.93
V7	1,000	1,056	1,001	0.96
V8	1,020	1,058	0,978	1
V9	1,010	1,058	0,997	1.06
V10	1,020	0,997	0,991	1.05
V11	1,020	0,924	0,960	1.04
V12	1,000	1,020	0,964	0.99
V13	1,020	1,011	1,018	1.01
V14	1,020	1,001	0,998	1.03
V15	1,020	0,997	0,978	1
V16	1,020	0,985	1,023	0.99
V17	1,020	0,946	1,022	1.06
V18	1,020	1,081	0,965	0.94
V19	1,000	1,035	1,011	1.01
V20	1,020	1,018	0,987	0.92
V21	1,010	0,967	1,029	0.9
V22	1,000	0,992	0,973	0.94
V23	1,000	0,965	0,978	0.9
F01	1283	11	0	0
$\Delta_{ponto}(\underline{x})$	0	117,328	90,598	11,032
$\Delta_{rest}(\underline{x})$	1282,52	210,436	0	0
F02	1282,52	327,764	90,598	11,032

O resultado da aplicação dos métodos utilizados neste trabalho para minimização da função objetivo F02 (equação (I.3)) são apresentados na Tabela VIII (RS), Tabela IX (AG) e Tabela X (EP), respectivamente. Estas Tabelas apresentam o melhor e o pior desempenho juntamente com a média dos valores de F02 obtidos nas dez simulações. As colunas $\Delta_{ponto}(\underline{x})$ e $\Delta_{rest}(\underline{x})$ apresentam os desvios em relação ao ponto de operação de referência (caso base) e os desvios em relação aos limites violados, grandezas calculadas pelas expressões (I.4) e (I.5), respectivamente. Estas grandezas foram calculadas somente para o melhor e o pior resultado obtido por cada algoritmo. Os resultados destas Tabelas mostram uma melhoria do desempenho do RS quando comparado com os demais métodos globais, passando a ser inclusive mais competitivo que o EP. O aumento no tempo de simulação do RS quanto comparado com os resultados obtidos por este método para F01 está relacionado com a convergência prematura do método para a função F01, o que não foi verificado para a função F02 diante da continuidade desta função. Em outras palavras, enquanto para F01 a

melhoria da solução ocorre somente se alguma restrição é completamente atendida, para F02 melhorias incrementais na solução podem ser verificadas.

Tabela VIII – Resultados da Aplicação do RS para Minimização de F02

Simulação	Tempo (h)	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	F02
Mínimo	0,9406	4,6978	0,2718	5,3136
Máximo	1,0711	8,7626	1,9981	9,3865
Média	0,9895	-	-	7,3984

Tabela IX – Resultados da Aplicação do AG para Minimização de F02

Simulação	Tempo (h)	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	F02
Mínimo	1,0205	4,5391	0,2524	4,7915
Máximo	1,0976	6,8824	0,4225	7,4932
Média	1,0656	-	-	5,7012

Tabela IX – Resultados da Aplicação do EP para Minimização de F02

Simulação	Tempo (h)	$\Delta_{ponto}(\underline{x})$	$\Delta_{rest}(\underline{x})$	F02
Mínimo	0,9128	5,9200	0,8199	6,7398
Máximo	0,9300	7,9374	0,5959	8,5333
Média	0,9193	-	-	7,9077

Analogamente à Tabela VII, a Tabela XI apresenta os despachos obtidos pelos métodos como também o despacho base (Alves, 2007), sendo também apresentados os valores de F01, $\Delta_{ponto}(\underline{x})$, $\Delta_{rest}(\underline{x})$ e F02 para cada despacho apresentado nesta Tabela. Para a função F02 o AG apresentou os melhores resultados, obtendo um despacho com menor valor de F02 e também de $\Delta_{rest}(\underline{x})$, que para este despacho representa uma violação total de 25,24% quando somadas todas as restrições e todas as topologias (caso base e contingências). Este despacho possui um total de 14 restrições não-atendidas (F01 na Tabela XI), representando assim um despacho não-seguro do ponto de vista estrito visto que não são atendidas completamente todas as restrições. Contudo, destas 14 restrições, a que apresenta maior desvio percentual diz respeito a uma violação de fluxo em linha de 11% em relação ao fluxo máximo na ocorrência da contingência 1, com as outras 13 violações respondendo por violações de tensão inferiores a 1,3% e de fluxo inferiores a 1%. Portanto, este despacho, mais próximo do ponto de operação de referência do que o obtido pelo AG visando minimizar F01 ($\Delta_{ponto}(\underline{x})$ igual a 4,6978 para este despacho e igual a 9,0598 para o despacho via F01 – vide Tabela VII), ainda que não atenda todas as restrições, apresenta violações de pequena magnitude que podem ser desconsideradas em aplicações práticas.

Tabela XI – Despacho Base e Despachos Obtidos pelos Métodos de Otimização Natural

Visando Minimizar F02

Controle	Base	RS	AG	EP
P1	3,00	3,61	5,01	3,15
P2	8,00	7,07	7,78	9,46
P3	9,00	11,51	9,17	7,64
P4	1,40	1,60	1,4	1,92
P5	1,50	1,88	1,7	1,31
P6	2,00	1,98	2,11	3,23
P7	7,00	7,06	6,17	8,95
P8	3,00	2,87	3,06	2,45
P9	4,00	4,23	3,68	3,79
P10	2,00	3,41	5,32	2,97
P11	3,00	2,32	2,92	2,49
P12	8,00	12,05	7,87	5,38
P13	11,00	10,11	10,02	11,45
P14	11,50	10,97	7,18	9,92
P15	12,00	11,77	9,9	4,7
P16	7,00	3,75	6,78	6,48
P17	7,00	8,27	7,04	7,1
P18	7,00	6,99	5,46	4,12
P19	9,50	6,86	8,92	11,67
P20	0,50	0,48	0,52	0,52
P21	2,30	2,32	2,3	1,71
P22	0,50	0,74	0,7	0,51
V1	1,000	0,912	1,000	1,000
V2	1,000	0,997	1,022	0,960
V3	1,010	1,020	1,025	1,070
V4	1,000	0,977	0,986	0,900
V5	1,000	0,950	1,012	1,000
V6	1,000	0,933	0,995	0,910
V7	1,000	0,965	1,000	1,050
V8	1,020	1,013	1,007	1,100
V9	1,010	1,003	1,021	1,100
V10	1,020	1,006	1,017	1,090
V11	1,020	1,011	0,989	1,050
V12	1,000	1,012	0,990	1,060
V13	1,020	1,017	1,012	1,000
V14	1,020	1,040	1,001	0,910
V15	1,020	0,985	0,961	1,040
V16	1,020	1,063	1,005	1,070
V17	1,020	1,028	1,014	1,080
V18	1,020	0,986	1,006	1,090
V19	1,000	0,987	0,980	0,990
V20	1,020	1,027	1,014	1,000
V21	1,010	0,990	0,999	1,090
V22	1,000	0,957	0,987	1,010

Controle	Base	RS	AG	EP
V23	1,000	1,001	0,985	0,990
F01	1283	14	27	60
$\Delta_{\text{ponto}}(\underline{x})$	0	46,978	45,424	5,92
$\Delta_{\text{rest}}(\underline{x})$	1282,52	0,2718	0,2524	0,8199
F02	1282,52	53,136	47,915	67,398

I.6. CONCLUSÕES

Este trabalho teve por objetivo o estudo de métodos de otimização natural para obtenção do despacho seguro de sistemas elétricos de potência. Considerando somente restrições de segurança estática (tensões em barramentos, fluxos em linhas, limites de potência ativa e reativa dos geradores), foram testados três métodos de otimização natural: recozimento simulado (RS), algoritmos genéticos (AG) e enxame de partículas (EP). Foram também testadas duas funções-objetivo para obtenção do despacho seguro, uma visando minimizar o número de restrições não atendidas (F01) e outra visando minimizar o desvio percentual das restrições violadas juntamente com o desvio percentual em relação a um ponto de operação especificado (F02). O AG apresentou os melhores resultados, conseguindo obter o despacho seguro via minimização de F01 como também o despacho com menor valor de F02. O EP também conseguiu obter o despacho seguro via minimização de F01, porém não apresentou resultados equivalentes aos obtidos pelo AG para minimização de F02. O RS não apresentou desempenho satisfatório para F01 devido às descontinuidades presentes nesta função-objetivo fazendo com que o algoritmo apresentasse convergência prematura, o que não ocorreu para minimização de F02. Apesar dos resultados promissores, o elevado esforço computacional ainda constitui um empecilho para aplicação destes métodos em ambiente de operação, visto que para obtenção de cada despacho os métodos requerem cerca de uma hora de processamento. Assim, são necessários métodos para aceleração do processo de busca, seja pela identificação de regiões promissoras ou pela redução do espaço de busca por meio de métodos de seleção e/ou transformação de variáveis. Visto que a função F02 tenta unificar objetivos conflitantes (mínima alteração no ponto de operação atual versus atendimento das restrições), a aplicação de métodos de otimização mutiobjetivo também constitui uma linha de pesquisa a ser explorada.

I.7. REFERÊNCIAS BIBLIOGRÁFICAS

- Alves, W.F. (2007). “Proposição de Sistemas-teste para Análise Computacional de Sistemas de Potência”, *Dissertação de Mestrado*, Programa de Pós-graduação em Ciência da Computação, Universidade Federal Fluminense.
- Bakirtzis, A.G., Biskas, P.N., Zoumas C.E. and Petridis, V. (2002). “Optimal Power Flow by Enhanced Genetic Algorithm”, *IEEE Transactions on Power Systems*, vol. 17, no. 2, pp. 229-236.
- Balu, N., Bertram, T., Bose, A., Brandwajn, V., Cauley, G., Curtice, D., Fouad, A., Fink, L., Lauby, M., Wollenberg, B.F. and Wrubel, J.N. (1992). “On-line Power System Security Analysis”, *Proceedings of the IEEE*, vol. 80, no. 2, pp. 262-280.
- Burchett, R.C., Happ, H.H. and Wirgau, K.A. (1982). “Large-scale Optimal Power Flow”, *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, pp. 3722-3732.
- Dent, C.J., Ochoa, L.F., Harrison G.P. and Bialek, J.W. (2010). “Efficient Secure AC OPF for Network Capacity Assessment”, *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 575-583.
- Devaraj, D., Yegnanarayana, B. (2005). “Genetic-Algorithm-Based Optimal Power Flow for Security Enhancement”, *IEE Proceedings on Generation, Transmission and Distribution*, vol. 152, no. 6, pp. 899-905.
- Dommel, H.W. and Tinney, W.F. (1968). “Optimal Power Flow Solutions”, *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-87, pp. 1866-1876.
- Eiben, A.E., Smith, J.E. (2007). *Introduction to Evolutionary Computing*, New York, Springer.
- Esmin, A.A.A., Lambert-Torres, G. and Zambroni de Souza, A.C. (2005). “A Hybrid Particle Swarm Optimization Applied to Loss Power Minimization”, *IEEE Transactions on Power Systems*, vol. 20, no.2, pp. 859-866.
- Holland, J. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: Univ. Michigan Press.
- Jiang, Q., Geng, G., Gu, C. and Cao, Y. (2010). “An Efficient Implementation of Automatic Differentiation in Interior Point Optimal Power Flow”, *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 147-155.
- Kennedy, J.; Eberhart, R. (1995). “Particle Swarm Optimization”, In: *Proceedings of IEEE International Conference on Neural Networks*, vol. IV, pp 1942-1948, Perth, Australia.
- Kirkpatrick, S., Gellat Jr., C. D., Vecchi, M. (1983). “Optimization by Simulated Annealing”, *Science*, 220(4598), pp. 498-516.
- Lambert-Torres, G., Quintana, V.H. (1998). “An Interior-point Method for Nonlinear Optimal Power Flow using Voltage Rectangular Coordinates”, *IEEE Transactions on Power Systems*, vol. 13, pp. 1211-1218.

- Milano, F., Vanfretti, L. and Morataya, J. C. (2008). “An Open Source Power System Virtual Laboratory: The PSAT Case and Experience”, *IEEE Transactions on Education*, vol. 51, no. 1, pp. 17-23.
- Mo, N., Zou, Z.Y., Chan, K.W. and Pong, T.Y.G. (2007). “Transient Stability Constrained Optimal Power Flow using Particle Swarm Optimisation”, *IET Generation, Transmission and Distribution*, vol. 1, no. 3, pp. 477-483.
- Momoh, J.A. and Zhu, J.Z. (1999). “Improved Interior Point Method for OPF Problems”, *IEEE Transactions on Power Systems*, vol. 14, pp. 1114-1120.
- Monticelli, A., Romero, R. and Asada, E. (2006). “Fundamentals of Simulated Annealing”, in: *Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems*, ed. Wiley Inc.
- ONS, Operador Nacional do Sistema Elétrico, “Visão Geral do ONS – Missão”, disponível em http://www.ons.org.br/institucional/orientacoes_estrategicas_missao.aspx e acessado em 01/04/2012.
- Shahidehpour, M., Tinney, W.F. and Fu, Y. (2005). “Impact of Security on Power Systems Operation”, *Proceedings of the IEEE*, vol. 93, no. 11, pp. 2013-2025.
- Stott, B., Alsac, O. and Monticelli, A.J. (1987). “Security Analysis and Optimization”, *Proceedings of the IEEE*, vol. 75, no. 12, pp. 1623-1644.
- Voumvoulakis, E. M. and Hatziaargyriou, N.D. (2010). “A Particle Swarm Optimization Method for Power System Dynamic Security Control”, *IEEE Transactions on Power Systems*, vol. 25, no. 2, pp. 1032-1041.
- Wei, H., Sasaki, H., Kubokawa, J. and Yokoyama, R. (1998). “An Interior Point Nonlinear Programming for Optimal Power Flow Problems with a Novel Data Structure”, *IEEE Transactions on Power Systems*, vol. 13, pp. 870-877.
- Wood, A.J. and Wollenberg, B.F. (1996). *Power Generation, Operation and Control*, 2nd. Edition, New York, John Wiley & Sons.
- Xin, H., Gan, D., Huang, Z., Zhuang, K. and Cao, L. (2010). “Applications of Stability-Constrained Optimal Power Flow in the East China System”, *IEEE Transactions on Power Systems*, vol. 25, no.3, pp. 1423-1433.
- Zoumas, C. E., Bakirtzis, A.G., Theocharis, J.B., Petridis, V. (2004). “A Genetic Algorithm Solution Approach to the Hydrothermal Coordination Problem”, *IEEE Trans. Power Syst.*, vol.19, pp. 1356- 1364.