



Universidade Federal de Juiz de Fora  
Faculdade de Engenharia  
Departamento de Energia Elétrica

**Polyana Mendonça de Paiva Reis**

**OTIMIZAÇÃO MULTIOBJETIVO ASSOCIADA A TÉCNICAS  
META-HEURÍSTICAS PARA PLANEJAMENTO E OPERAÇÃO DE  
SISTEMAS DE DISTRIBUIÇÃO**

Juiz de Fora

2017

Polyana Mendonça de Paiva Reis

**OTIMIZAÇÃO MULTIOBJETIVO ASSOCIADA A TÉCNICAS  
META-HEURÍSTICAS PARA PLANEJAMENTO E OPERAÇÃO DE  
SISTEMAS DE DISTRIBUIÇÃO**

Trabalho de Conclusão de Curso apresentado ao programa de Graduação em Engenharia Elétrica, modalidade Energia, da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientador: Leonardo Willer de Oliveira

Juiz de Fora

2017

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Reis, Polyana M. P.

OTIMIZAÇÃO MULTIOBJETIVO ASSOCIADA A TÉCNICAS META-  
HEURÍSTICAS PARA PLANEJAMENTO E OPERAÇÃO DE SISTEMAS  
DE DISTRIBUIÇÃO / Polyana Mendonça de Paiva Reis. – 2017.

53 f. : il.

Orientador: Leonardo Willer de Oliveira

Trabalho de Conclusão de Curso – Universidade Federal de Juiz de Fora,  
Faculdade de Engenharia. Departamento de Energia Elétrica, 2017.

1. Otimização Multiobjetivo. 2. Meta-heurísticas. 3. Dominância de  
Pareto. I. de Oliveira, Leonardo Willer, orient. III. Título.

Polyana Mendonça de Paiva Reis

**OTIMIZAÇÃO MULTIOBJETIVO ASSOCIADA A TÉCNICAS  
META-HEURÍSTICAS PARA PLANEJAMENTO E OPERAÇÃO DE  
SISTEMAS DE DISTRIBUIÇÃO**

Trabalho de Conclusão de Curso apresentado ao programa de Graduação em Engenharia Elétrica, modalidade Energia, da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovada em 06 de dezembro de 2017.

BANCA EXAMINADORA

---

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

---

Prof. Abilio Manuel Variz, D. Sc.  
Universidade Federal de Juiz de Fora

## AGRADECIMENTOS

Ao meu Deus, o autor e consumidor da minha fé, meu alvo e porto seguro! Por me fortalecer e sustentar em todas as situações, me orientar nas mais difíceis decisões e ser a minha alegria mesmo em meio às dificuldades.

Aos meus pais Antonio e Paulina, minha base e meus grandes exemplos na vida. Obrigada pelo apoio e incentivo incondicionais na busca pelos meus sonhos e objetivos. Esta conquista também é de vocês.

Ao Tony e a Isabella, meus irmãos pelo sangue e meus amigos por escolha. Sempre presentes apesar da distância ao longo desta jornada.

Ao professor, orientador, coordenador e amigo Leonardo Willer. Agradeço pela dedicação, confiança e paciência ao longo da graduação e pesquisas.

Aos familiares, amigos, meninas da república e irmãos em Cristo que sempre me acolheram por onde passei. Obrigada pelas palavras de incentivo e por abençoarem minha vida com suas orações.

Aos amigos que a engenharia me deu, pelo companheirismo, conversas e troca de conhecimento ao longo desses anos. Este trabalho não seria realidade sem a ajuda de vocês.

Ao LABSPOT (Laboratório de Sistemas de Potência da Faculdade de Engenharia da Universidade Federal de Juiz de Fora), pela estrutura, ao CNPq pelo apoio financeiro durante as pesquisas e ao grupo "Otimização Heurística e Bio-inspirada" da UFJF.

A Universidade Federal de Juiz de Fora, pela excelência no ensino. E a todos os professores da Faculdade de Engenharia que participaram, da minha formação profissional e crescimento pessoal.

A todos que direta ou indiretamente contribuíram para a conclusão deste trabalho.

*“E Jesus disse-lhe:  
Se tu podes crer,  
Tudo é possível ao que crê”*  
Marcos 9.23

## RESUMO

A presente monografia de final de curso dedica-se ao desenvolvimento de modelos de otimização multiobjetivo como ferramentas de análise de dois problemas da área de sistemas elétricos de potência, o restabelecimento de redes radiais de distribuição de energia elétrica e a alocação ótima de geração distribuída, tratados individualmente. Os modelos consistem na associação de duas técnicas de otimização meta-heurística, enxame de partículas e sistema imunológico artificial, com os princípios de dominância de Pareto, visando a um tratamento dos objetivos através de relação de compromisso adequada entre os mesmos sem a necessidade de ponderações. Os princípios de dominância de Pareto são embutidos nos mecanismos evolutivos das meta-heurísticas de modo que o processo de otimização identifique soluções não dominadas, objetivo dos modelos multiobjetivos. Nas aplicações propostas, o problema de restabelecimento tem seis objetivos: minimização de corte de carga, maximização de atendimento a consumidores prioritários, manutenção de níveis adequados de tensão e de fluxo nos alimentadores, e minimização de número de manobras e perdas técnicas na rede elétrica. Já o problema de alocação de geração distribuída visa à redução de emissões e à minimização dos custos de investimentos. Para estes dois problemas, as técnicas de enxame de partículas binário e sistema imunológico artificial são aplicadas, respectivamente. Sistemas teste conhecidos da literatura são utilizados para validar as aplicações de otimização multi-objetivo desenvolvidas.

Palavras-chave: Otimização Multiobjetivo. Meta-heurísticas. Dominância de Pareto. Enxame de Partículas. Sistema Imunológico Artificial.

## ABSTRACT

This monograph is dedicated to the development of multiobjective optimization models as tools to analyze two problems in the area of electric power systems, the restoration of radial distribution networks and the optimal allocation of distributed generation, the work presents a model of an analytical tool of two problems, restoration and distributed generation, treated individually. The models consist of the association of two techniques of metaheuristic optimization, particle swarm and artificial immune system, with the principles of Pareto dominance, aiming at a treatment of the objectives through an adequate commitment relationship between them without the need for weights . The principles of Pareto dominance are embedded in the evolutionary mechanisms of metaheuristics so that the optimization process identifies non-dominated solutions, the goal of multiobjective models. In the proposed applications, the restoration problem has six objectives: minimization of load cut, maximization of service to priority consumers, maintenance of adequate voltage and flow levels in feeders, and minimization of manueuvers number and technical losses in the electric network. The problem of allocation of distributed generation is aimed at reducing emissions and minimizing investment costs. For these two problems, the techniques of binary particle swarm and artificial immune system are applied, respectively. Test systems known in the literature are used to validate the multi-objective optimization applications developed.

Key-words: Multi-objective Optimization. Meta-heuristics. Pareto dominance. Particle Swarm. Artificial Immune System.



## LISTA DE ILUSTRAÇÕES

Figura 1 – Evolução da carga de energia elétrica no SIN (ENERGÉTICA, 2014). . . . .	14
Figura 2 – Evolução da capacidade instalada por fonte de geração (ENERGÉTICA, 2014). . . . .	16
Figura 3 – Espaço de soluções e fronteira Pareto-ótima (DEB et al., 2002). . . . .	23
Figura 4 – Características típicas de fronteiras Pareto-ótimas no espaço de objetivos (DEB et al., 2002). . . . .	24
Figura 5 – Cálculo da distância do aglomerado (DEB et al., 2002). . . . .	25
Figura 6 – Movimento de uma partícula no enxame. . . . .	27
Figura 7 – Algoritmo EPBM. . . . .	29
Figura 8 – Algoritmo SIA Multiobjetivo. . . . .	32
Figura 9 – Etapas do SIA. . . . .	32
Figura 10 – Topologia inicial do Sistema 33 Barras pós falha. . . . .	42
Figura 11 – Topologia inicial do Sistema 16 Barras pós-falha. . . . .	45
Figura 12 – Soluções do Estudo de Caso 3 no espaço de objetivos. . . . .	49

## LISTA DE TABELAS

Tabela 1 – Análise de soluções por critério de dominância de Pareto . . . . .	23
Tabela 2 – Parâmetros do algoritmo EPBM . . . . .	42
Tabela 3 – Soluções para o Estudo de Caso 1 . . . . .	43
Tabela 4 – Parâmetros do AG . . . . .	43
Tabela 5 – Sequência de manobras para as topologias ótimas. . . . .	44
Tabela 6 – Soluções para o Estudo de Caso 2. . . . .	46
Tabela 7 – Parâmetros das unidades geradoras . . . . .	47
Tabela 8 – Parâmetros do SIA Multiobjetivo . . . . .	47
Tabela 9 – Soluções para o Estudo de Caso 3. . . . .	48

## LISTA DE ABREVIATURAS E SIGLAS

SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
SDEE	Sistema de Distribuição de Energia Elétrica
Proinfa	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
EPE	Empresa de Pesquisa Energética
GD	Geração Distribuída
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
ANEEL	Agência Nacional de Energia Elétrica
REN	Resolução Normativa
AG	Algoritmo Genético
SIA	Sistema Imunológico Artificial
EPB	Enxame de Partículas Binário
SPEA	<i>Strength Pareto Evolutionary Algorithm</i>
NSGA	<i>Non-dominated Sorting Genetic Algorithm</i>
PSO	<i>Particle Swarm Optimization</i>
MOPSO	<i>Multi-Objective Particle Swarm Optimizer</i>
EPSO	<i>Evolutionary Particle Swarm Optimization</i>
CDA	<i>Crowding Distance</i>
EPBM	Enxame de Partículas Binário Multiobjetivo
LND	Lista de Não-Dominados

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>12</b>
1.1	Considerações Iniciais . . . . .	12
1.2	O Problema de Restabelecimento . . . . .	14
1.3	O Problema de Alocação de Geração Distribuída . . . . .	15
1.4	Revisão Bibliográfica . . . . .	17
1.5	Motivação e Objetivos do Trabalho . . . . .	18
1.6	Publicações Decorrentes . . . . .	19
1.7	Estrutura do Trabalho . . . . .	19
<b>2</b>	<b>METODOLOGIAS DE OTIMIZAÇÃO DESENVOLVIDAS .</b>	<b>21</b>
2.1	Considerações Iniciais . . . . .	21
2.2	Otimização Multiobjetivo . . . . .	22
2.2.1	Dominância de Pareto . . . . .	23
2.2.2	NSGA II . . . . .	24
2.2.3	SPEA . . . . .	26
2.3	Enxame de Partículas Binário Multiobjetivo . . . . .	27
2.3.1	Enxame de Partículas . . . . .	27
2.3.2	Implementação Binária Multiobjetiva . . . . .	28
2.4	Sistema Imunológico Artificial Multiobjetivo . . . . .	30
2.4.1	Sistema Imunológico Artificial . . . . .	31
2.4.2	Implementação Multiobjetiva . . . . .	31
2.5	Considerações Finais . . . . .	33
<b>3</b>	<b>MODELAGEM DOS PROBLEMAS DE PLANEJAMENTO E OPERAÇÃO DE SEP . . . . .</b>	<b>35</b>
3.1	Considerações Iniciais . . . . .	35
3.2	Restabelecimento . . . . .	35
3.2.1	Reconfiguração . . . . .	35
3.2.2	Sequência de Manobras . . . . .	37
3.3	Alocação de GD . . . . .	38
3.3.1	Formulação do Problema . . . . .	38
3.3.2	Considerações Finais . . . . .	39
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>41</b>
4.1	Considerações Iniciais . . . . .	41
4.2	Restabelecimento de Sistemas de Distribuição . . . . .	41

4.2.1	Reconfiguração . . . . .	41
4.2.2	Sequência de manobras . . . . .	43
4.3	Restabelecimento de SDE considerando Consumidores Prioritários. . . . .	44
4.4	Alocação de Geração Distribuída . . . . .	47
4.5	Considerações Finais . . . . .	49
<b>5</b>	<b>CONCLUSÕES . . . . .</b>	<b>50</b>
5.1	Considerações Iniciais . . . . .	50
5.2	Trabalhos Futuros . . . . .	51
5.3	Considerações Finais . . . . .	51
	<b>REFERÊNCIAS . . . . .</b>	<b>52</b>

# 1 INTRODUÇÃO

## 1.1 Considerações Iniciais

Historicamente, o desenvolvimento vem acompanhado da necessidade de se otimizar. Seja em ramos industriais, sociais, econômicos ou outros, todos buscam por eficiência. E esta só é alcançada quando se consegue usar de forma ótima os recursos, o tempo e os esforços, garantindo a qualidade. Para chegar a uma decisão ótima, muitas questões devem ser levadas em conta e, normalmente, os objetivos a serem atingidos vão de encontro uns aos outros. Para se reduzir tempo, por exemplo, é necessário aumentar recursos ou esforços. Portanto, encontrar uma solução que beneficie todos os pontos nem sempre é uma tarefa simples.

A engenharia, a logística e até mesmo o mercado de investimentos são exemplos de áreas em que os problemas envolvem mais de um objetivo. Em (AZUMA et al., 2011), a logística busca otimizar custos de estoque e transporte de cargas. Para se obter menores custos com estoque, necessita-se transportar com mais frequência, o que impacta no custo dos transportes. Verifica-se que além dos múltiplos objetivos, os mesmos ainda são conflitantes entre si.

A característica notada no problema anterior também está presente em (MILOCA; FARIA & VOLPI, 2012). Organizar uma carteira de investimentos envolve, basicamente, maximizar lucros e minimizar riscos. Um bom investidor é aquele que estabelece o melhor compromisso entre retorno e risco. No entanto, existem perfis diferentes de investidores, desde os mais conservadores até os mais extremos. Nota-se então que, nem sempre, apenas uma solução ótima é suficiente, e que um conjunto de possibilidades para uma análise a posteriori se mostra como melhor alternativa.

Usualmente, para resolver problemas como os apresentados, os múltiplos objetivos são convertidos para uma base comum, gerando apenas uma função a ser otimizada. Desta forma o problema torna-se mono-objetivo, onde a qualidade das soluções é medida por um único critério. Para utilizar tal método, é necessário penalizar os diversos objetivos. Esta ponderação demanda um bom conhecimento do problema, além de muitos testes e uma enorme sensibilidade ao calcular os pesos. Tantas intervenções podem introduzir erros na modelagem do problema, acarretando soluções não confiáveis.

Um tratamento que avalie cada objetivo individualmente, sem pesos ou ponderações seria a forma mais adequada de resolver problemas do mundo real. Caso os objetivos não sejam conflitantes, a otimização de cada um deles, analisados isoladamente, irá determinar a mesma solução, neste caso o tratamento multiobjetivo teria uma única solução ótima, assim como nos métodos com apenas uma função objetivo.

No entanto, como visto anteriormente, os problemas reais frequentemente apre-

sentam objetivos conflitantes entre si. A análise isolada dos objetivos não chega a uma única solução, em vez disso apresenta um conjunto de soluções ótimas todas atendendo às restrições individuais das funções. As soluções neste conjunto são não-comparáveis, ou não-dominadas, conhecidas na literatura como soluções Pareto-ótimas (TICONA & DELBÉM, 2008). Esta característica permite ao operador a análise das condições reais na circunstância da tomada de decisão e a escolha de uma solução mediante possíveis limitações. Neste contexto, as análises de planejamento e operação de Sistemas Elétricos de Potência (SEP) apresentam-se como perfeitas candidatas a abordagens multiobjetivo, haja vista a necessidade de um tratamento adequado conforme complexidade e características deste tipo de problema.

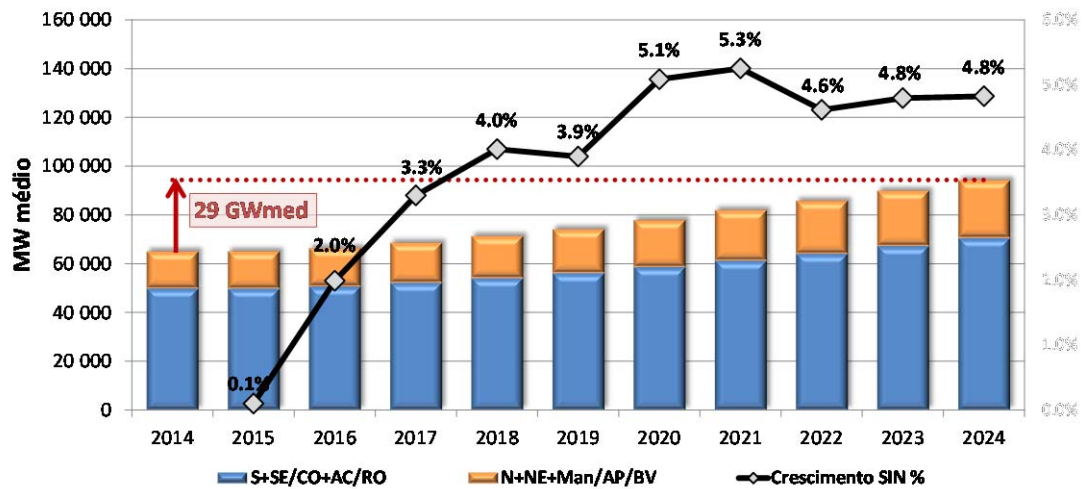
As demandas do mercado consumidor de energia elétrica tornam-se cada vez maiores e mais exigentes quanto à qualidade e confiabilidade da energia fornecida, portanto os desafios do SEP, no que se refere à operação e planejamento, também são cada vez maiores. O Sistema Elétrico de Potência pode ser dividido basicamente em quatro segmentos: geração, transmissão, distribuição e consumo. Inicialmente formado por pequenas estruturas isoladas, este sistema evoluiu para uma rede extensa, complexa e robusta. O SEP interliga os geradores aos pontos de consumo de praticamente todo o país através do Sistema Interligado Nacional (SIN).

As análises propostas na presente monografia de conclusão de curso estão direcionadas ao segmento de distribuição, ou nos Sistemas de Distribuição de Energia Elétrica (SDEE), cujo objetivo principal é garantir um suprimento deste insumo cada vez mais confiável e de qualidade. Isto implica em respeitar os limites de frequência e tensão que chegam aos consumidores finais, além de garantir o mínimo tempo e quantidade de interrupções no fornecimento. Tais características mostram a necessidade de um elaborado método para auxiliar na operação deste sistema, de forma que o restabelecimento de energia após uma inevitável falha seja rápido e eficiente.

Além da complexidade na operação, o consumo de energia elétrica está em constante crescimento no país em proporções tais que os grandes empreendimentos de geração hidráulica não conseguem acompanhar. O Plano Decenal de Expansão de Energia 2024 diz que num horizonte de 10 anos o SIN apresentará uma taxa média de crescimento anual de 3,8%, que representa 29 GW médios, como mostra a Figura 1. Por esse motivo, começaram a surgir incentivos à diversidade da matriz energética com a inserção de novas tecnologias de geração e conseqüente aumento na capacidade instalada do SIN.

Em 2002, a Lei nº 10.438/2002 instituiu o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa) que tem o objetivo de desenvolver fontes alternativas e renováveis de energia para a produção de eletricidade. Após a criação do programa, os empreendimentos com base em geração eólica, fotovoltaica, biomassa e Pequenas Centrais Hidrelétricas (PCH), por exemplo, vêm conquistando cada vez mais

espaço no cenário energético brasileiro, como mostram os balanços anuais publicados pela Empresa de Pesquisa Energética (EPE).



FORNTE: EPE.

Figura 1 – Evolução da carga de energia elétrica no SIN (ENERGÉTICA, 2014).

Muitos destes empreendimentos são concebidos próximos ao consumidor, muitas das vezes ligados diretamente às redes de distribuição. Empreendimentos deste tipo são chamados de Geração Distribuída (GD). Esta crescente inserção de GD no sistema aumenta não apenas os desafios da operação como também do planejamento da expansão, que precisa alocar a geração em tal ponto do sistema que não prejudique a qualidade da energia fornecida.

## 1.2 O Problema de Restabelecimento

Tanto interrupções quanto violações nos níveis de tensão são indesejadas pelas concessionárias, que seguem um padrão de fornecimento de energia cada vez mais rigoroso e são fiscalizadas quanto ao seu cumprimento (PRODIST, 2012). Além deste fato, a crescente complexidade do sistema e a contingências da rede requerem que a operação nessas empresas tome decisões cada vez mais rápidas e adequadas

Muitas podem ser as causas de uma interrupção, e os planos de restabelecimento devem ser compostos por ações que otimizem a operação durante a reparação da mesma, de forma a mitigar seus efeitos. Devem ser levados em conta diversos objetivos e restrições, como já dito, muitas vezes conflitantes entre si.

O SDEE é interligado por chaves de manobra que permitem a transferência de cargas afetadas para outros alimentadores não interrompidos. O plano de restabelecimento ótimo deve definir, a partir da configuração pós-falta, uma nova topologia para o sistema e determinar a sequência das manobras que irão formá-la, de forma a maximizar o fornecimento. Essas ações de restabelecimento são feitas, em sua grande maioria, baseadas



na experiência do operador, que nem sempre consegue definir a melhor estratégia, dado o tamanho o sistema real. Em vista desse desafio tem-se buscado métodos computacionais de otimização que auxiliem as concessionárias na definição de planos mais adequados para restauração do sistema após um falta.

Mesmo com a utilização de métodos computacionais, em um sistema real nem sempre é possível encontrar uma nova topologia que mantenha o atendimento total das cargas enquanto se executa as manutenções e correções necessárias após uma falha na rede de distribuição de energia elétrica. Muitas das vezes é necessário escolher quem fica sem fornecimento por mais tempo. Por esse motivo, a ANEEL define alguns consumidores como prioridade.

Estes consumidores prioritários são chamados no Módulo 1 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) como “Serviço essencial” e definidos como “Serviço ou atividade de fundamental importância para a sociedade”. Alguns exemplos são:

- Unidade operacional de segurança pública e institucional (Polícia Militar, Polícia Civil, Corpo de Bombeiros, Exército, Marinha e Aeronáutica);
- Unidades hospitalares, armazenamento e distribuição de vacinas e soros antídotos;
- Unidades de tratamento de água e esgotos, uso e controle de substâncias radioativas;
- Centro de controle público de tráfego aéreo, marítimo e terrestre.

Os estados de manobra da chave, aberto ou fechado, configuram variável discreta, “0” ou “1”, enquanto o fluxo de potência é modelado com variáveis contínuas, ainda, existem inúmeras combinações possíveis de soluções. Essas características apresentam o problema como um bom candidato à resolução via técnicas meta-heurísticas, visto que é de natureza inteira mista e combinatória.

### 1.3 O Problema de Alocação de Geração Distribuída

Como dito, nos últimos anos, a geração centralizada das grandes hidrelétricas não tem sido suficiente para atender a crescente demanda de consumo de energia elétrica. Com isso foram surgindo novas tecnologias de geração que vêm ganhando cada vez mais competitividade no mercado de energia, com o aumento de incentivos e normalização.

São gerações mais próximas ao centro de carga, reduzindo custos com expansão no sistema de transmissão e distribuição, redução de perdas, melhoria da tensão da rede, além dos benefícios de diversificação da matriz energética e baixo impacto ambiental. O Módulo 1 do PRODIST define Geração Distribuída como “Centrais geradoras de energia

elétrica, de qualquer potência, com instalações conectadas diretamente no sistema elétrico de distribuição ou através de instalações de consumidores, podendo operar em paralelo ou de forma isolada e despachadas – ou não – pelo ONS” (ALBERICO, 2016).

A definição do PRODIST inclui a cogeração (muito frequente no segmento industrial) e as gerações de pequeno porte instaladas diretamente pelo consumidor. Esta última vem ganhando cada vez mais espaço devido às iniciativas regulatórias que definem, por exemplo, a compensação de energia quando da existência de excedentes de exportáveis à rede. A Resolução Normativa REN n° 482/2012 (NORMATIVA, 2012) definiu as condições de acesso ao sistema de distribuição, cujos critérios técnicos e operacionais são descritos no Módulo 3 do PRODIST; ambos foram revisados pela REN n° 687/2015 (ANEEL, 2015).

Geradores distribuídos podem ser inseridos tanto ao longo das redes de transmissão quanto diretamente nas linhas de distribuição de média e até baixa tensão. No entanto o sistema aéreo de distribuição de energia elétrica é projetado de forma radial, e pensado para acomodar cargas e não geradores. Essa inversão no fluxo de potencia pode tornar o planejamento da expansão um enorme desafio.

A geração eólica e a biomassa são as fontes alternativas renováveis com maior expressão no país segundo a EPE, como mostra a Figura 2. Neste trabalho considera-se inserir geração eólica, biomassa ou não inserir nenhuma geração. Observa-se uma característica discreta no problema, que aliada às variáveis contínuas do fluxo de potência e ao enorme espaço de busca, considerando as inúmeras barras do sistema, faz da alocação de GD um bom candidato à otimização via técnicas meta-heurísticas.

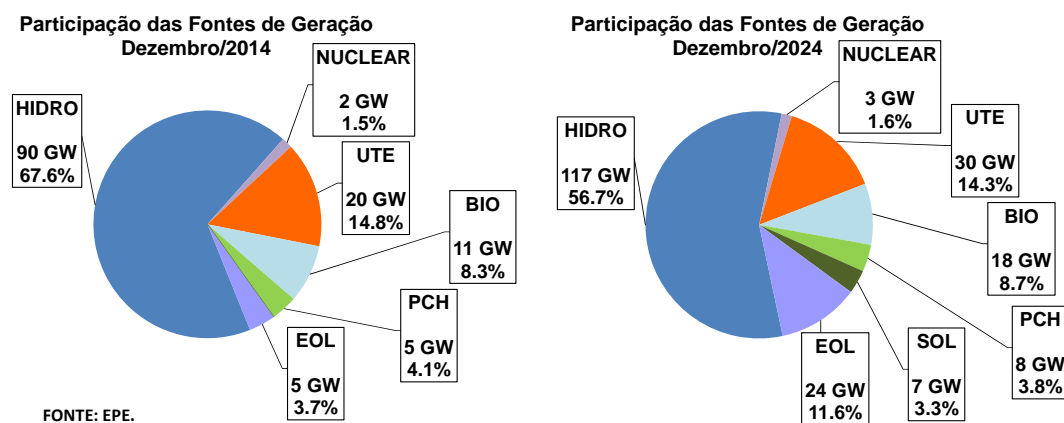


Figura 2 – Evolução da capacidade instalada por fonte de geração (ENERGÉTICA, 2014).

A implantação de GDs pode trazer tanto benefício quanto prejuízo, dependendo do lugar onde for instalada, tecnologia utilizada e quantidade gerada (MACIEL, 2012). Algumas questões que precisam ser analisadas são perdas, níveis de tensão, ilhamento, custos de investimento, entre outros. Observa-se que se trata de um bom problema para ser tratado por um método de otimização multiobjetivo.

## 1.4 Revisão Bibliográfica

Para a construção deste trabalho foi feita uma revisão bibliográfica dos métodos aplicados aos problemas analisados. Dada a importância tanto do restabelecimento de energia quanto da alocação de GD, a literatura apresenta muitas abordagens para a solução dos mesmos.

Métodos como os algoritmos genéticos, algoritmos evolutivos, sistemas inteligentes, colônia de formigas, sistemas imunológicos artificiais, busca tabu, lógicas fuzzy, redes neurais artificiais, modelos híbridos e a técnica bioinspirada por enxame de partículas tem sido aplicados a problemas desse tipo. Em (LAMBERT-TORRES et al., 2009) é feita uma comparação entre Algoritmo Genético (AG) e Sistema Imunológico Artificial (SIA), aplicando as ferramentas ao problema de restabelecimento de energia elétrica.

A utilização de Sistemas Imunológicos artificiais para o planejamento da alocação de GD é proposta em (OLIVEIRA et al., 2015). O método determina o ponto do sistema em que será inserida a geração bem como o tipo de fonte, além da capacidade e fator de potência dos geradores. O problema apresenta quatro objetivos que são os custos totais de investimento e operação, as perdas de energia e as emissões de gases poluentes. Os objetivos são multiplicados por fatores de custo para possibilitar a análise em uma só função objetivo.

O problema de restabelecimento de energia é tratado em (ARCANJO et al., 2014), que utiliza Algoritmos Genéticos, Método Baseado na Ecolocalização de Morcegos e Método Baseado na Reprodução dos Pássaros Cuco para encontrar a topologia ótima pós falha. Os objetivos do problema são minimizar a energia não suprida, considerando a existência de cargas prioritárias, as perdas do sistema, o número de chaveamentos e os limites operativos do sistema. Para se gerar uma equação matemática que englobasse todos os objetivos foram usados “fatores de inclusão” que definem o impacto de cada parcela na equação. Tais fatores foram encontrados mediante simulação exaustiva e são parte decisiva na convergência.

Em (KENNEDY & EBERHART, 1997) é apresentada uma versão denominada de enxame de partículas binário (EPB). O método de enxame de partículas foi desenvolvido para otimizar no espaço contínuo, enquanto a proposta da referência é reformular o algoritmo para operar com variáveis binárias, onde as trajetórias são mudanças na probabilidade de uma coordenada assumir o valor zero ou um. A técnica foi aplicada ao restabelecimento em (OLIVEIRA et al., 2016), que conseguiu bons resultados com um método de duas etapas: a primeira utilizando o EPB para encontrar a topologia reconfigurada de rede após a ocorrência de falta, e a segunda etapa faz uso de algoritmo genético para propor a sequência de manobras de chaveamento. O método considera ponderação dos objetivos através de uma única função matemática e de fatores de compromisso ou pesos.

Adaptações de algumas técnicas meta-heurísticas vêm sendo exploradas na literatura para aliar os métodos à otimização multiobjetiva. Em (MILOCA; FARIA & VOLPI, 2012) é feita uma apresentação dos conceitos envolvidos no desenvolvimento de algoritmos evolutivos (AEs) para algoritmos multiobjetivo, bem uma descrição dos principais modelos existentes. Os modelos referenciados são o *Strength Pareto Evolutionary Algorithm* (SPEA), proposto em (ZITZLER & THIELE, 1999) que recebeu uma versão melhorada chamada SPEA2 em (ZITZLER; LAUMANN & THIELE, 2001), e o *Non-dominated Sorting Genetic Algorithm* (NSGA), proposto (DEB, 2001).

A literatura vem aliando os modelos multiobjetivo às técnicas meta-heurísticas. Destacamos a abordagem multiobjetivo para SIA apresentado em (COELLO & CORTÉS, 2002) que utiliza a técnica de criar uma memória secundária onde são separadas as soluções não dominadas para evolução pelo sistema imunológico artificial. Analogamente, em (COELLO, 2002) é proposto um algoritmo que amplia o PSO para solução de problemas multiobjetivo resultando em um método denominado MOPSO (*Multi-Objective Particle Swarm Optimizer*). Uma versão multiobjetiva do método EPSO (*Evolutionary Particle Swarm Optimization*), que consiste numa combinação de estratégias dos AEs ao método PSO é proposto em (MACIEL, 2012).

## 1.5 Motivação e Objetivos do Trabalho

A crescente tendência de inserção de GD no SDEE leva à necessidade de se investigar métodos que facilitem o planejamento dessas alocações de forma a beneficiar o sistema. Da mesma forma, a importância dos problemas de restabelecimento e reconfiguração faz com que os mesmos estejam sempre nos temas de estudos voltados a otimização, com o intuito de constante melhoria da eficiência e qualidade da distribuição de energia elétrica.

O elevado espaço de busca e as muitas variáveis são características em ambos os problemas que tornam os métodos não computacionais inviáveis de ser utilizados, dados os enormes esforços demandados. Os problemas descritos são de natureza inteira mista, pois apresentam variáveis contínuas e discretas. Além disso, o porte das redes de distribuição possibilita inúmeras opções de manobra para reconfiguração e barras para alocação de geração distribuída, o que atribui natureza combinatória aos problemas.

Estas características apontam para a aplicação de técnicas heurísticas e meta-heurísticas como alternativas de resolução, como já vem sendo explorado na literatura. No entanto, a aplicação destas técnicas aliadas a uma abordagem multiobjetivo é ainda pouco explorada para os problemas em estudo neste trabalho.

O objetivo deste trabalho de conclusão de curso é tratar de forma adequada os diferentes objetivos dos problemas mencionados, estabelecendo um compromisso entre os mesmos sem a necessidade de ponderações. O propósito final é apresentar ao operador e

planejador do sistema um conjunto de soluções ótimas que facilitarão sua tomada de decisão, sem limitar suas possibilidades. Ao problema de alocação de GD é proposto um algoritmo meta-heurístico SIA multiobjetivo para minimizar perdas e custo de investimento.

O problema de restabelecimento é tratado em dois estágios. A proposta para o primeiro estágio é um algoritmo multiobjetivo por enxame de partículas que utiliza configuração binária para reconfigurar o sistema de forma a definir uma topologia radial ótima. No segundo estágio, um algoritmo genético deve indicar a sequência de manobras de chaveamento a serem seguidas para que se tenha a topologia definida no primeiro estágio.

A determinação dessa sequência deve considerar os consumidores prioritários e o tempo de restabelecimento, procurando restaurar o fornecimento a começar por esses clientes. Com isso, o AG consegue estabelecer as melhores estratégias de corte quando não é possível garantir a realocação total das cargas.

## 1.6 Publicações Decorrentes

Os estudos e desenvolvimentos realizados no âmbito desta monografia de conclusão de curso resultaram em duas publicações em congressos técnico-científicos, listados a seguir:

- REIS, Polyana M. P. ; Oliveira, Leonardo W. ; PEREIRA, J. L. R. ; OLIVEIRA, EDIMAR J. . *Restabelecimento Multiobjetivo de Sistemas de Distribuição via Enxame de Partículas*. In: VI Simpósio Brasileiro de Sistemas Elétricos (SBSE), 2016, Natal, RN.
- REIS, Polyana M. P. ; Oliveira, Leonardo W. ; PEREIRA, JOSÉ LUIZ R. ; OLIVEIRA, EDIMAR J. ; FERREIRA, Saulo C. A. . *Restabelecimento Multiobjetivo de Sistemas de Distribuição Considerando Consumidores Prioritários*. In: XLVIII Simpósio Brasileiro de Pesquisa Operacional (SBPO), 2016, Vitória, ES.

## 1.7 Estrutura do Trabalho

Este trabalho é organizado em 5 capítulos.

No Capítulo 1 são apresentadas as considerações iniciais, a contextualização dos problemas, uma revisão bibliográfica dos temas em estudo além da motivação e objetivos do trabalho.

O Capítulo 2 mostra os métodos de otimização bem como as principais teorias e técnicas que permitiram o desenvolvimento da ferramenta multiobjetivo.

No Capítulo 3 é feita a formulação dos problemas evidenciando a aplicação da metodologia proposta.

No Capítulo 4 são realizados os estudos de casos aplicando as metodologias propostas a sistemas conhecidos da literatura. Ainda, são apresentadas e discutidas as soluções encontradas.

O Capítulo 5 apresenta as conclusões obtidas com o desenvolvimento do trabalho, as considerações finais e propostas de trabalhos futuros.

## 2 METODOLOGIAS DE OTIMIZAÇÃO DESENVOLVIDAS

### 2.1 Considerações Iniciais

Como visto, a grande maioria dos problemas reais apresentam diversos objetivos que precisam ser otimizados simultaneamente. Muitas vezes essas metas são conflitantes entre si, ou seja, não existe uma única solução que consiga otimizar todas ao mesmo tempo. O que se costuma fazer é um somatório das funções objetivo de modo que haja apenas uma equação, e então se valoriza ou penaliza termos pontuais, criando ponderações. Outro meio visto na literatura é transformar todos os termos para uma mesma unidade, o que pode ser feito levando em conta os custos de cada um e, assim, minimizando o valor final. Tais alternativas podem comprometer a legitimidade da solução dita ótima.

Na otimização multiobjetivo é possível tratar os objetivos de modo adequado gerando um conjunto de soluções ótimas, ou soluções onde um objetivo não pode mais ser melhorado sem que prejudique os demais (TICONA & DELBÉM, 2008). Esse conjunto de soluções é apresentado ao operador, que passa a ter alternativas que o auxiliam no processo de decisão. Nesse caso, o próprio operador faz as ponderações necessárias de acordo com as condições da situação em tempo real.

Muitas vezes, os problemas a serem otimizados possuem soluções complexas, com funções não lineares e descontínuas, variáveis aleatórias e grandes espaços de busca com diversas dimensões, definindo uma natureza combinatória. Tal característica inviabiliza a enumeração exaustiva, que é o método que compara todas as soluções possíveis, já que demandaria enorme, e ainda não suficiente esforço. Nesse contexto, surgem as técnicas heurísticas, as quais buscam soluções aproximadas, ou seja, procura alcançar uma solução satisfatória sem ter que percorrer todo o espaço de soluções, de proporções exponenciais.

Os métodos heurísticos são normalmente implementados de forma muito específica ao problema que se busca solucionar. As meta-heurísticas aproveitam conceitos e princípios de uma heurística de modo a constituir uma estrutura mais genérica. Diversas técnicas vêm sendo propostas pela literatura (LUZIA & RODRIGUES, ), sendo alguns listados:

- Colônia de Formigas (*Ant Colony Optimization*);
- Procedimento Aleatório Adaptativo Guloso (*Greedy Randomized Adaptive Procedure* – GRASP);
- Algoritmos Genéticos (*Genetic Algorithms*);
- Busca Tabu (*Taboo Search*);
- Busca por Dimensão (*Scatter Search*);

- Enxame de Partículas (*Particle Swarm*);
- Sistema Imunológico Artificial (*Artificial Immune Systems*).

Alguns desses métodos foram inspirados na natureza e, por isso, são chamados de bioinspirados. É o caso dos Algoritmos Genéticos, que apresentam computação evolucionária, o Enxame de Partículas, baseado na inteligência coletiva, e os Sistemas Imunológicos Artificiais.

## 2.2 Otimização Multiobjetivo

Um problema de otimização no qual há dois ou mais objetivos é caracterizado como problema de otimização vetorial, onde se trabalha com o espaço de variáveis e o espaço de objetivos. O espaço de variáveis é onde se faz a busca pelas soluções do problema, ou seja, é o domínio das variáveis do problema. Já o espaço de objetivos é o espaço formado pelas funções-objetivo do problema.

Assim, um problema de otimização multiobjetivo é composto por um conjunto de funções-objetivo, como modelado na Equação 2.1, a serem otimizadas (maximizadas ou minimizadas) e um conjunto de restrições, Equações de 2.2a a 2.2c, que devem ser satisfeitas para que a solução seja factível. Tendo um número de objetivos  $N_{Obj}$  a ser otimizado, o problema se formula da seguinte maneira:

$$f(x) = [f_1(x); f_2(x); \dots; f_{N_{Obj}}(x)] \quad (2.1)$$

$$g_j(x) \geq 0, j = 1, \dots, J \quad (2.2a)$$

$$h_k(x) = 0, k = 1, \dots, K \quad (2.2b)$$

$$x_i^{(inf)} \leq x_i \leq x_i^{(sup)} \quad (2.2c)$$

onde  $x$  é um vetor de variáveis de decisão tal que  $x = [x_1; x_2; \dots; x_{N_{Var}}]$ , representando a solução do problema e  $J$  e  $K$  são, respectivamente, o número de restrições de desigualdade e de igualdade. As desigualdades ( $g_j$ ) e as igualdades ( $h_k$ ) são chamadas de funções de restrição e os valores  $x_i^{(inf)}$  e  $x_i^{(sup)}$  representam os limites inferior e superior para a variável  $x_i$ . Esses limites definem o espaço das variáveis. O conjunto de todas as soluções factíveis forma a região factível ou espaço de busca. O vetor de funções-objetivo  $f(x) = [f_1(x); f_2(x); \dots; f_{N_{Obj}}(x)]$  pertence ao espaço dos objetivos. Para cada solução  $x$  no espaço de decisão, existe um ponto  $f(x)$  no espaço dos objetivos.



### 2.2.1 Dominância de Pareto

O método utilizado para se comparar soluções com múltiplos e conflitantes objetivos é a dominância de Pareto. Se  $x$  e  $y$  são duas possíveis soluções, diz-se que  $x$  domina  $y$  se as seguintes condições forem satisfeitas:

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

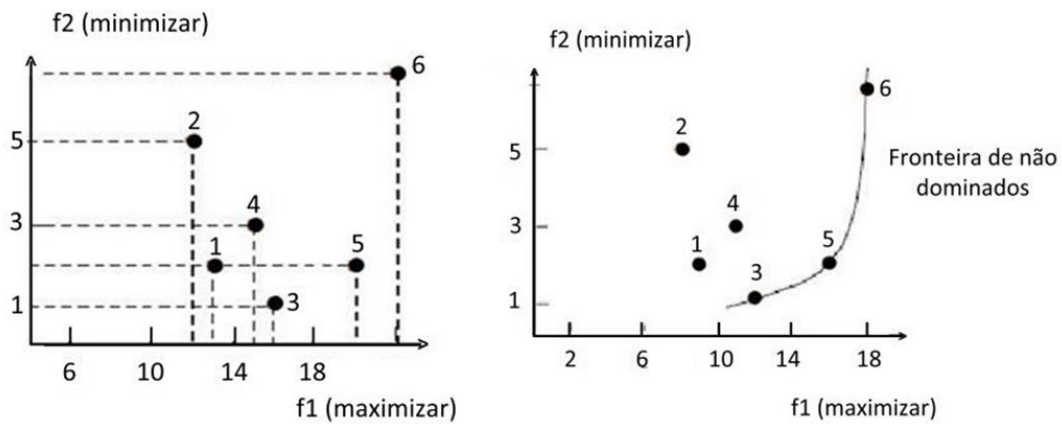


Figura 3 – Espaço de soluções e fronteira Pareto-ótima (DEB et al., 2002).

Fazendo a análise pelo método de dominância é possível encontrar as soluções não dominadas, que compõem o chamado conjunto Pareto-ótimo. A Figura 3 mostra um exemplo de espaço de objetivos, onde se deseja minimizar a função  $f_2$  e maximizar  $f_1$ . No gráfico são plotados seis pontos, que representa possíveis soluções para o problema. Cada solução está associada á variáveis distintas no espaço de busca.

Tabela 1 – Análise de soluções por critério de dominância de Pareto

Combinação	Relação de dominância	Combinação	Relação de dominância
1 e 2	1 domina 2	2 e 6	Não comparáveis
1 e 3	3 domina 1	3 e 4	3 domina 4
1 e 4	Não comparáveis	3 e 5	Não comparáveis
1 e 5	5 domina 1	3 e 6	Não comparáveis
1 e 6	Não comparáveis	4 e 5	5 domina 4
2 e 3	3 domina 2	4 e 6	Não comparáveis
2 e 4	4 domina 2	5 e 6	Não comparáveis
2 e 5	5 domina 2		

Comparando todas as soluções pelas condições de não dominância descritas anteriormente, temos a relação apresentada na Tabela 1. Pode ser verificado que os pontos

3, 5 e 6 não são dominados por nenhuma outra solução, compondo, assim, o conjunto Pareto-ótimo.

Considerando duas funções objetivo  $f_1(x)$  e  $f_2(x)$ , a Figura 4 mostra exemplos de conjuntos Pareto-ótimos para algumas combinações de maximização e minimização. A curva indica onde o conjunto está localizado. Essa figura também ilustra que é possível ter conjuntos Pareto-ótimos formando por uma região contínua ou pela união de regiões descontínuas.

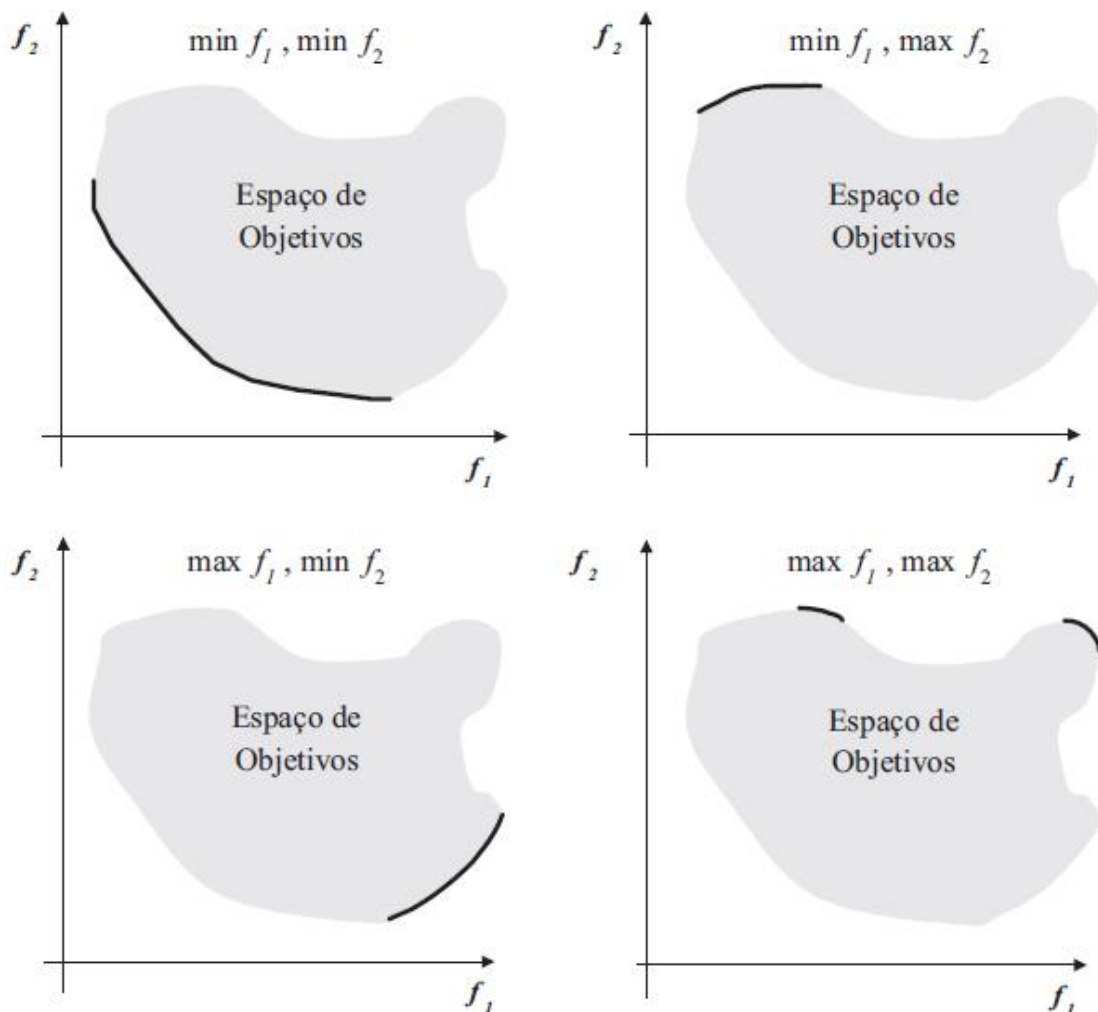


Figura 4 – Características típicas de fronteiras Pareto-ótimas no espaço de objetivos (DEB et al., 2002).

### 2.2.2 NSGA II

Deb em (DEB, 2001) propôs um método baseado em vários níveis de classificação dos indivíduos de acordo com sua dominância, conhecido como *fast non dominated sorting*. Se as soluções não forem dominadas por nenhuma outra, são classificadas na primeira fronteira de Pareto. Assim se faz até a última fronteira, onde estão classificadas

as soluções que são dominadas por todas as outras das fronteiras precedentes. No exemplo da Figura 3 as soluções são classificadas da seguinte forma:

- Fronteira 1: 3, 5 e 6;
- Fronteira 2: 1 e 4;
- Fronteira 3: 2.

Em (DEB, 2001) Deb apresenta o operador *crowding distance* (CDA) como uma melhoria do NSGA. Uma vez que a ordenação em fronteiras está completa, é calculada a “distância do aglomerado”. Este parâmetro fornece uma estimativa da densidade de soluções em torno de determinado ponto. O valor de CDA de um ponto é dado pela distância média de suas soluções vizinhas.

Para exemplificar, considera-se que os pontos destacados na Figura 5 estejam na mesma fronteira não dominada. Neste caso, o CDA do ponto ‘i’ é dado pela média das distâncias entre ‘i e i-1’ e ‘i e i+1’. Os pontos extremos (‘0’ e ‘1’) estão mais distantes do aglomerado e, portanto, recebem prioridade para seleção, através de um valor elevado de CDA.




Figura 5 – Cálculo da distância do aglomerado (DEB et al., 2002).

O processo descrito é efetuado para cada função objetivo e o CDA de uma solução é obtido somando-se os CDAs determinados para esta solução segundo cada objetivo. A priorização por pontos distantes do aglomerado visa a introduzir e manter a diversidade de soluções durante o processo evolutivo de uma meta-heurística, por exemplo.

A seleção empregada é por torneio e a aptidão de cada indivíduo depende de qual fronteira ele pertence e da distancia do aglomerado. Serão selecionados os indivíduos da primeira ou das primeiras fronteiras, em ordem crescente. Caso estejam no mesmo nível, são escolhidos indivíduos com maior distancia de aglomerado.

O resultado desta classificação é um conjunto de alternativas não dominadas entre si (pertencentes à primeira fronteira) e melhores que as demais opções (nas demais fronteiras) de acordo com os objetivos estabelecidos. As soluções da primeira fronteira compõem o conjunto Pareto-ótimo, de onde a solução vencedora pode ser escolhida segundo critérios de tomada de decisão de um agente humano, como dito anteriormente.

### 2.2.3 SPEA

No algoritmo proposto por Zitzlerem (ZITZLER; LAUMANNNS & THIELE, 2001) é utilizada a seleção baseada na relação de dominância para avaliar e selecionar as soluções. A aptidão calculada para cada solução é chamada de *strenght fitness*. O algoritmo introduz a ideia de uma memória externa que recebe as soluções não dominadas ou com melhor aptidão a cada iteração.

O cálculo da função de fitness usa conceitos de dominância e de densidade para calcular a aptidão de um conjunto que une a população inicial aleatória à memória externa. Inicialmente é calculada a força de cada indivíduo (solução), ou *strenght<sub>i</sub>*, que é o numero de soluções que o individuo i domina. O fitness bruto, ou *raw<sub>i</sub>*, é a soma das forças de todos os indivíduos que o dominam. Assim, os indivíduos não-dominados têm strenght máximo e raw igual a zero, enquanto o oposto acontece aos dominados, que vão apresentar strenght zero e raw máximo.

Quando existem muitas soluções não-dominadas, raw se aproxima de zero para todas elas, neste caso o cálculo se torna insuficiente e se faz necessário um mecanismo para privilegiar soluções dentre as não-dominadas. O SPEA calcula a densidade do indivíduo, que é uma função decrescente em relação ao k-ésimo vizinho mais próximo. A densidade calculada na Equação 2.3 é inversamente proporcional a distancia *dist* (no espaço de objetivos) entre cada individuo i e todos os indivíduos j do conjunto U composto pela população inicial aleatória e a memória externa .

$$D(i) = \frac{1}{dist_{ij}(k) + 2} \quad (2.3)$$

Os valores da densidade para cada solução candidata são calculados e armazenados em uma lista, que posteriormente é colocada em ordem crescente. O valor de k sugerido na literatura é a raiz quadrada do número de elementos de U. Finalmente, a função de fitness adotada pelo algoritmo SPEA2 é dada pela soma do fitness bruto e da densidade, Equação 2.4.

$$F(i) = raw(i) + D(i) \quad (2.4)$$

## 2.3 Enxame de Partículas Binário Multiobjetivo

O EPBM proposto é uma versão multiobjetivo do Enxame de Partículas Binário. O método alia as técnicas de dominância de Pareto, *fast non dominated sorting* e *crowding distance* ao EPB.

### 2.3.1 Enxame de Partículas

A inteligência de enxame é baseada no comportamento coletivo dos indivíduos em uma população, que resulta em soluções coerentes ou padrões a surgir. Mais especificamente, baseia-se no comportamento coletivo de indivíduos interagindo entre si e com o ambiente. Exemplos clássicos são os enxames de abelhas, colônias de formigas, cardumes de peixes e bandos de pássaros (KENNEDY & EBERHART, 1992).

O Enxame de Partículas, mais conhecido por sua sigla do inglês PSO, é um tipo de inteligência de enxame e se baseia na revoada dos pássaros. Nessa técnica, o conjunto das soluções candidatas seria o enxame (ou bando), formada por partículas (como são chamados os pássaros) e a modelagem usa a experiência individual e coletiva das partículas para percorrer o espaço de busca (área sobrevoada pelo bando) e encontrar as soluções ótimas.

Considerando que o bando percorre o espaço de busca, a evolução do algoritmo está associada à trajetória deste bando e ao tempo gasto para encontrar a solução ótima. Cada partícula possui uma posição e uma velocidade que são atualizados a cada iteração. A velocidade é responsável por guiar as mudanças da posição das partículas. O deslocamento das partículas se dá por três termos: (i) termo de inércia, (ii) termo cognitivo e (iii) termo social, como mostra a Figura 6. O somatório dos vetores resulta no movimento da partícula para a nova posição.

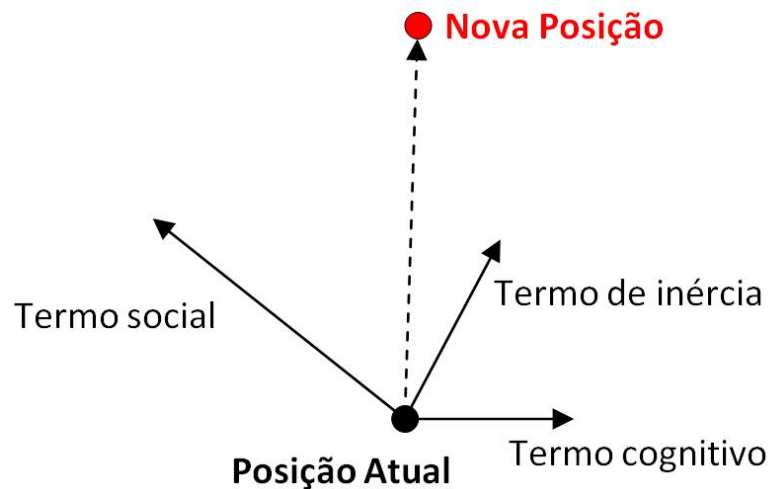


Figura 6 – Movimento de uma partícula no enxame.

Este movimento é modelado nas Equações 2.5 e refpos, pelas quais são atualizadas a posição e a velocidade a cada iteração  $k$ . Atualizando a posição  $x_i^{(k+1)}$  e a velocidade  $V_i^{(k+1)}$ , respectivamente.

$$V_i^{(k+1)} = w \cdot V_i^k + c_1 \cdot r_1 \cdot (pbest_i^k - x_i^k) + c_2 \cdot r_2 \cdot (gbest_i^k - x_i^k) \quad (2.5)$$

$$x_i^{(k+1)} = x_i^k + V_i^{(k+1)}, i = 1, \dots, n_P, \quad (2.6)$$

Em que:

$V_i^{(k+1)}$ : velocidade da partícula  $i$  na iteração  $k$ ;

$w$ : fator inércia;

$c_1, c_2$ : fatores de aceleração cognitivo e social, respectivamente;

$r_1, r_2$ : números aleatórios distribuídos uniformemente entre 0 e 1;

$pbest_i^k$ : melhor posição da  $i$ -ésima partícula na iteração  $k$ ;

$gbest_i^k$ : melhor posição global na iteração  $k$ ;

$x_i^k$ : posição da partícula  $i$  na iteração  $k$ ;

$n_P$ : Número de partículas ou soluções candidatas.

A solução ótima nesta analogia seria o local onde o bando encontrou o ninho ou o alimento. É chamado de Pbest o termo que carrega a experiência ou conhecimento individual de cada partícula, ou seja, a melhor posição em que aquela partícula já esteve. Enquanto o Gbest representa o conhecimento do enxame como um todo, ou a melhor posição que a população já encontrou. Esses termos são encontrados a partir do cálculo da função objetivo para cada partícula.

### 2.3.2 Implementação Binária Multiobjetiva

Para implementar o Enxame de Partículas Multiobjetivo, foi utilizado o algoritmo apresentado em (OLIVEIRA et al., 2016). O EPB utiliza operadores binários de deslocamento para realizar as operações das equações e 2.5 e 2.6 sem a necessidade de estratégias de arredondamento ou similares, que poderiam afetar a eficiência do algoritmo de otimização.

O Enxame de Partículas Binário Multiobjetivo (EPBM) alia os mecanismos de busca do enxame de partículas binário com a técnica de classificação de soluções por dominância de Pareto. A Figura 7 apresenta as etapas do algoritmo, definidas com base em (COELLO, 2002). A princípio devem ser predefinidos os parâmetros do método, como tamanho do bando  $P$  (número de soluções candidatas) e número máximo de iterações (ou número máximo de gerações  $g_{max}$ ).

Etapa 1: Inicializa-se o “enxame de partículas”  $P^*$  com as soluções candidatas. O conjunto é uma matriz [Nº de soluções candidatas x Nº de chaves do sistema], que é

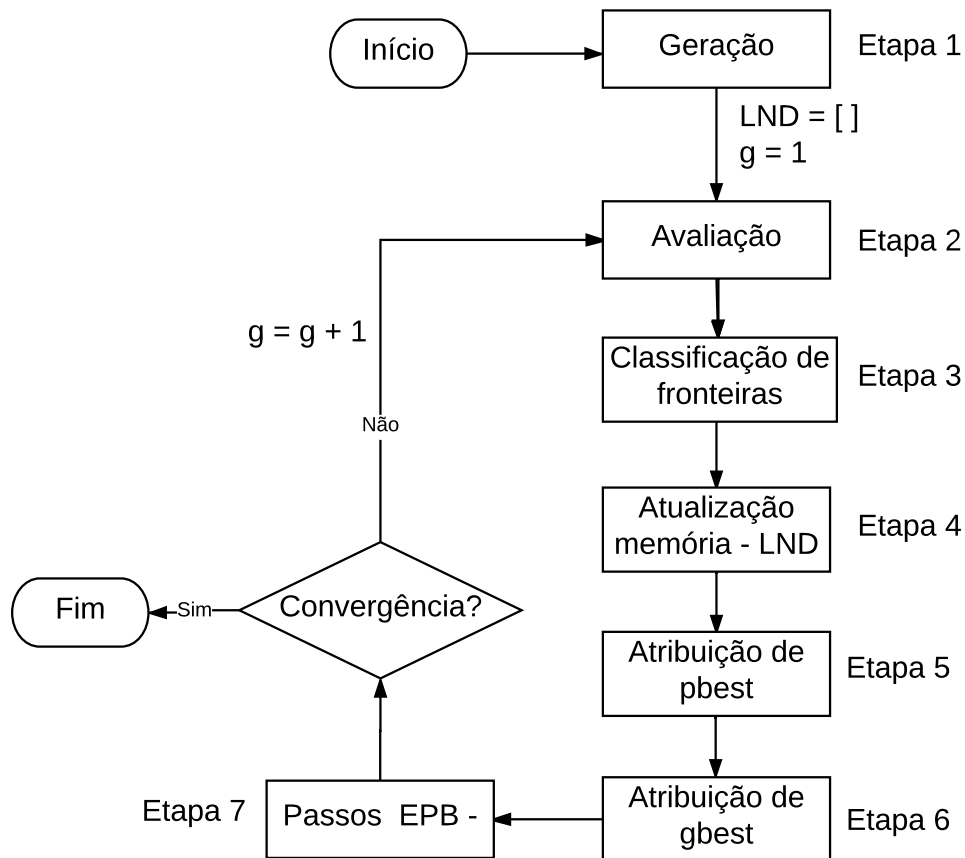


Figura 7 – Algoritmo EPBM.

gerada aleatoriamente através da troca dos estados aberto (0) e fechado (1) das chaves manobráveis. A matriz gerada é composta apenas por topologias radiais e conexas. Nesta etapa também é inicializada a Lista de Não-Dominado LND, uma memória externa a princípio vazia cujo tamanho é um parâmetro do algoritmo.

Etapa 2: Cada partícula é avaliada para cada função objetivo. A matriz das soluções candidatas passa a carregar consigo mais M colunas, que é a quantidade de objetivos do problema, cada uma guardando os valores calculados pela respectiva função objetivo (FOB) de cada partícula.

Etapa 3: Carregando os valores das FOBs, é criada uma matriz que une P e LND (inicialmente vazia). A este conjunto união U são aplicados os operadores , *fast non dominated sorting* e *crowding distance*. Nesta etapa mais duas colunas são acrescentadas à partícula, a primeira com o número da fronteira à qual pertence e a segunda com a respectiva distância de aglomerado. As partículas são colocadas em ordem crescente de fronteira e, dentro de cada fronteira, em ordem decrescente de distância.

Etapa 4: Com P já toda classificada e ordenada, transfere-se para LND todos os

indivíduos da fronteira 1. Nesta etapa, três hipóteses devem ser consideradas:

- a) Número de partículas na primeira fronteira menor que  $n_{LND}$ . Neste caso, LND é completada com as próximas partículas de P em ordem crescente de fronteira;
- b) Número de partículas na primeira fronteira maior que  $n_{LND}$ . Neste caso, as partículas da primeira fronteira com as menores “distâncias de aglomeração” não são incluídas em LND, de modo que apenas  $n_{LND}$  partículas sejam incluídas;
- c) Número de partículas na primeira fronteira igual a  $n_{LND}$ . Neste caso, todas as partículas não dominadas da primeira fronteira são incluídas em LND.

Desta forma o enxame é dividido em dois: LND, com os melhores candidatos, e P, que será descartado.

Etapa 5: O vetor pbest inicial recebe todo o P. Durante o processo iterativo, é atribuída ao Pbest a última solução não dominada encontrada pela partícula.

Etapa 6: Diferentemente do método por enxame de partículas tradicional, o enxame de partículas multiobjetivo atribui um gbest para cada partícula. Nesta etapa, uma lista Gb é preenchida com  $n_{Gb}$  soluções de LND, que apresentam as maiores distâncias de acordo com o parâmetro CDA. Para as partículas ‘i’ da fronteira ‘if’, com ‘if’ variando da segunda até a última fronteira,  $Gbest_i$  é definido como a partícula da fronteira ‘if - 1’ mais distante de ‘i’. Esta distância (d) é calculada como na Equação 2.7.

$$d(i^{if-1}, i^{if}) = max_i \cdot \left( \left| \frac{FOB_i^{if} - FOB_i^{if-1}}{max_{FOB_i} - min_{FOB_i}} \right| \right) \quad (2.7)$$

Em que:

$d(i^{if-1}, i^{if})$ : é a distância entre duas partículas nas fronteiras ‘if - 1’ e ‘if’;

$FOB_i^{if}$ : é o valor da i-ésima função objetivo para a partícula da fronteira ‘if’;

$FOB_i^{if-1}$ : é o valor da i-ésima função objetivo para a partícula da fronteira ‘if - 1’;

$max_{FOB_i}$  e  $min_{FOB_i}$ : são os valores máximo e mínimo da i-ésima função.

Para cada partícula ‘i’ da primeira fronteira,  $Gbest_i$  é definida como uma partícula aleatoriamente escolhida de Gb [9].

Etapa 7: O enxame de partículas binário (EPB) é aplicado à população reduzida de LND. O critério de convergência aplicado é pelo número de gerações, se o valor parametrizado de gmaxfor atingido, LND final é o conjunto Pareto-ótimo. Caso contrário, volta-se a Etapa 2.

## 2.4 Sistema Imunológico Artificial Multiobjetivo

Os Sistemas Imunológicos Artificiais são meta-heurísticas bioinspiradas na natureza. Baseiam-se no comportamento das células de defesa do organismo dos animais, quando



em contato com um agente estranho ao organismo.

#### 2.4.1 Sistema Imunológico Artificial

O sistema imunológico natural tem a capacidade de evoluir fornecendo proteção ao organismo contra uma infinidade de agentes patogênicos. Algumas características deste sistema que justificam o interesse computacional tais como a unicidade, ou seja, o sistema de cada indivíduo é único; os detectores estão bem distribuídos, excluindo o risco de um controle centralizado, além de que não há necessidade de uma detecção completa do patógeno para que o sistema seja ativado; a capacidade de reconhecer padrões, anomalias aprender a estruturas dos patógenos de forma a reconhecê-las depois.

Existem dois tipos de respostas ao ataque de patógenos, o sistema imunológico inato e o sistema imunológico adquirido ou adaptativo. O sistema imunológico artificial é baseado no segundo tipo de resposta, que é mais lenta que a primeira, no entanto específica a cada tipo de patógeno.

As células que detectam reconhecem os agentes patogênicos são chamadas de linfócitos. Existem dois tipos principais de linfócitos, os linfócitos B (ou células B) e os linfócitos T (ou células T), que possuem em sua superfície receptores de antígenos com alta especificidade. Estas células atuam no reconhecimento e eliminação de patógenos, além de serem responsáveis pela constituição da chamada memória imunológica. Esta memória corresponde basicamente à capacidade que as células do sistema adaptativo têm de reconhecer um mesmo antígeno (ou um antígeno semelhante) quando houver uma infecção recorrente, o que leva a uma resposta imunológica mais rápida e pode até mesmo evitar o restabelecimento da doença no organismo. Graças a estes mecanismos, a resposta adaptativa dá ao sistema imunológico a capacidade de aprender e se aprimorar a cada infecção sofrida.

As soluções candidatas no SIA são chamadas anticorpos e o conjunto  $P$  destas soluções recebe o nome de repertório, que evolui ao longo das iterações do algoritmo. Nesse projeto foi utilizado o algoritmo (CASTRO & ZUBEN, 2002), que é baseado no princípio da seleção clonal do sistema imunológico artificial.

#### 2.4.2 Implementação Multiobjetiva

Assim como no EPBM, no SIA multiobjetivo foi implementada a memória externa. Na Figura 8, o fluxograma mostra estrutura do algoritmo do método. Devem ser definidos como parâmetros o número máximo de gerações, o tamanho do repertório, o número de anticorpos a serem selecionados para processo de clonagem, o número de anticorpos que serão mutados e o número de anticorpos gerados no processo de edição de receptores, bem como as constantes que controlam os processos de clonagem e mutação.

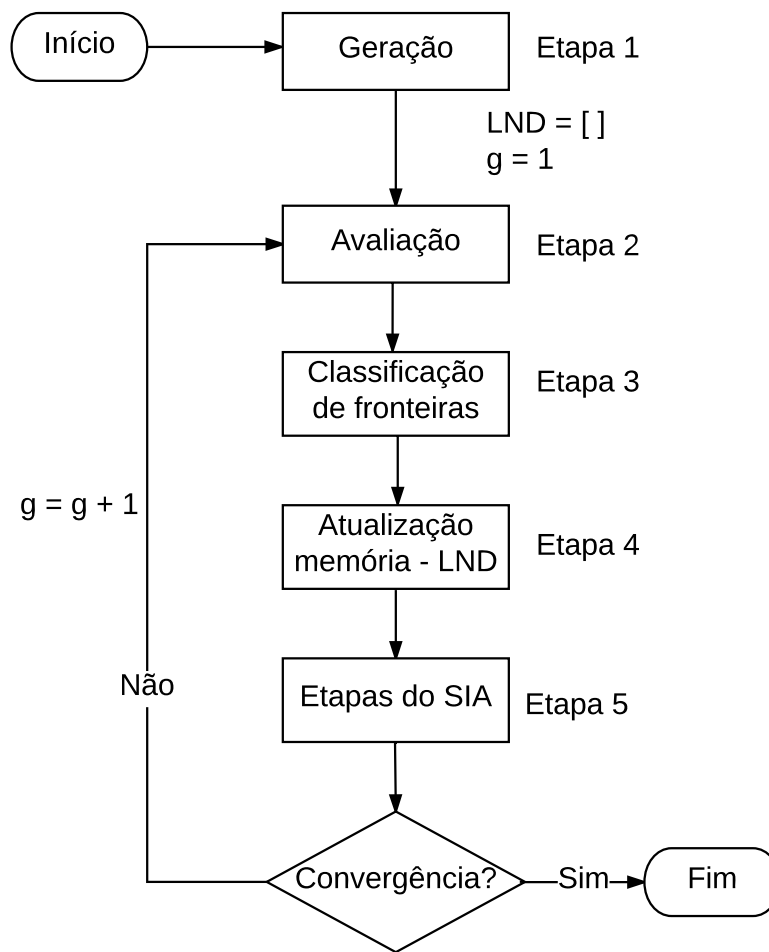


Figura 8 – Algoritmo SIA Multiobjetivo.

As etapas 1, 2 e 3 são idênticas às do EPBM. Na Etapa 4, a única diferença está no fato de que P (soluções dominadas) não será descartado. Para implementar a abordagem multiobjetiva no SIA foi empregada a técnica *strength fitness* do SPEA, portanto havendo modificações em algumas etapas do algoritmo SIA da Figura 9.

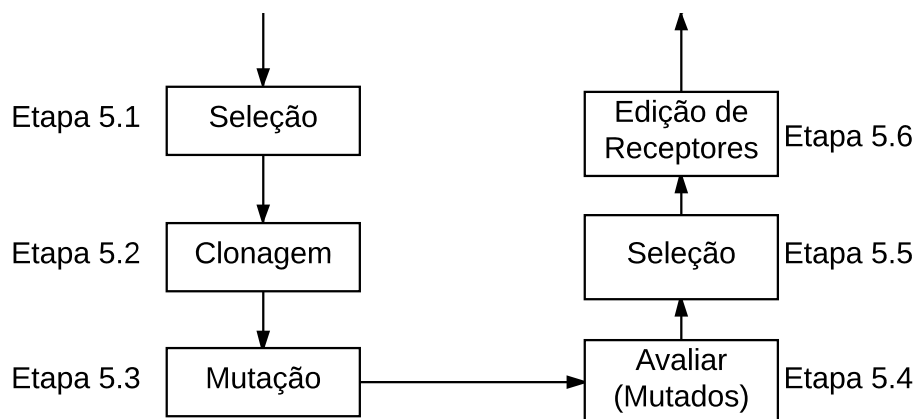


Figura 9 – Etapas do SIA.

Etapa 5.1: O operador *strenght fitness* é aplicado à LND. Os  $n$  anticorpos com melhor fitness são selecionados para o processo de clonagem.

Etapa 5.2: Cada anticorpo selecionado é clonado, gerando um conjunto  $C$  de cópias idênticas. O número de clones para cada anticorpo depende do seu fitness. Quando melhor, mais clones esse anticorpo irá gerar.

Etapa 5.3: O repertório de clones  $C$  passa por um processo de hipermutação somática, que é responsável pela modificação de  $b$  dos clones gerados. Esse processo de mutação, como já dito, previne ótimos locais e o número de mutantes também depende do fitness das soluções.

Etapa 5.4: O repertório  $M$  de clones mutados são avaliados e classificados através dos operadores *fast non dominated sorting* e *crowding distance*.

Etapa 5.5: Os melhores  $n$  anticorpos de  $M$  são selecionados. Nesse ponto os piores anticorpos do repertorio  $P$  são substituídos pelos melhores da seleção.

Etapa 5.6: A edição de receptores consiste na geração aleatória de novos anticorpos que, assim como na etapa anterior, substituirão os piores de  $P$ . Essa técnica tem o propósito de inserir diversidade no repertório.

Após o passo 5, o contador de geração  $g$  é incrementado e o critério de convergência é avaliado. Este critério é satisfeito quando pelo menos uma das seguintes condições é verdadeira: (i) o número de gerações atinge um valor limite dado por  $g_{max}$ ; (ii) a melhor solução do repertório  $P$  permanece inalterada durante um número de gerações dado por  $g_{stop}$ . Caso não ocorra convergência o algoritmo, Esse novo  $P$  volta a Etapa 2 como repertório da próxima iteração, até a convergência.

## 2.5 Considerações Finais

Neste capítulo foi reforçado que os problemas reais em engenharia normalmente apresentam objetivos múltiplos e conflitantes entre si. A forma mais adequada de se encontrar soluções ótimas para problemas deste tipo é por meio de metodologias que consigam tratar os objetivos de forma individual mantendo o compromisso entre eles.

Além dos diversos objetivos, estes problemas são modelados por funções não lineares e descontínuas, variáveis aleatórias e grandes espaços de busca com diversas dimensões, além de natureza combinatória. Apresentam-se desta forma como candidatos perfeitos à métodos meta-heurísticos.

Foram apresentadas ferramentas que tornam possível a avaliação dos objetivos de forma independente. Ainda, métodos tomados como referência na literatura para aplicação aos problemas apresentados na introdução foram descritos nesta seção. A implementação dos métodos com a utilização das ferramentas adequadas norteou os estudos que resultaram

no desenvolvimento das metodologias propostas no findo capítulo.

Duas metodologias meta-heurísticas bioinspiradas foram implementadas para múltiplos objetivos e serão aplicadas a estudos de caso neste trabalho: EPBM e SIA Multiobjetivo.

### 3 MODELAGEM DOS PROBLEMAS DE PLANEJAMENTO E OPERAÇÃO DE SEP

#### 3.1 Considerações Iniciais

Tanto a operação para o restabelecimento quanto o planejamento para a alocação de GD tratados neste trabalho consistem na resolução de um problema de otimização. Portanto devem ser formulados a partir de uma ou mais funções objetivo e um conjunto de equações e inequações que correspondem às restrições associadas ao problema. Neste capítulo os problemas em estudo no trabalho são modelados matematicamente.

#### 3.2 Restabelecimento

O problema de restabelecimento é solucionado neste trabalho em dois estágios: (i) é feita a reconfiguração do sistema via Enxame de Partículas Binário Multiobjetivo e (ii) determinada a sequência de chaveamento utilizando Algoritmo Genético. Em (i) a topologia ótima é encontrada fazendo-se a análise de 6 funções objetivas separadamente e otimizadas em conjunto, além disso são levadas em conta outras quatro restrições do sistema. Em (ii) os objetivos estão modelados em uma única função com as mesmas restrições do primeiro estágio.

##### 3.2.1 Reconfiguração

A reconfiguração do SDEE deve abranger diversos objetivos e restrições, que são muitas vezes conflitantes entre si, justificando a utilização de método multiobjetivo. Os objetivos do problema foram modelados pelas Equações de 3.1 a 3.6.

$$\text{Min}[ENS] \quad (3.1)$$

$$\text{Min} \left[ \sum_{k=1}^{NB_V} (V_{min} - V_k) \right] \quad (3.2)$$

$$\text{Min}[Pe/PL_T] \quad (3.3)$$

$$\text{Min}[nch] \quad (3.4)$$

$$\text{Min}[CPSA] \quad (3.5)$$

$$Min \left[ \sum_{km=1}^{TRV} (P_{km} - P_{km}^{max}) \right] \quad (3.6)$$

Além das funções objetivo (FOBs), o problema de restabelecimento apresenta restrições que precisam ser consideradas como a operação radial da rede de distribuição, o balanço de potência em cada barra e os estados discretos das chaves (aberto ou fechado). As restrições são modeladas matematicamente nas Equações de 3.7 a 3.11.

$$PG_k - PL_k - \sum_{m \in \Omega_k} [x_{km} \cdot P_{km}] = 0 \quad (3.7)$$

$$QG_k - QL_k - \sum_{m \in \Omega_k} [x_{km} \cdot Q_{km}] = 0 \quad (3.8)$$

$$x_{km} = 0 \text{ ou } 1 \quad (3.9)$$

$$V_k, V_m \geq V_{kmin} \quad (3.10)$$

$$\textit{Radialidade e Conectividade} \quad (3.11)$$

Onde:

*ENS*: Energia não suprida;

$V_{min}$ : Limite mínimo de tensão;

$V_k$ : Tensão da barra k;

$NB_V$ : Número de barras com tensões abaixo do limite  $V_{min}$ ;

$Pe$ : Perda de potência ativa;

$PL_T$ : Carga total do sistema;

$nch$ : Número de manobras de chaveamento;

$PG_k$ : Gerações de potência ativa na barra k;

$QG_k$ : Gerações de potência reativa na barra k;

$PL_k$ : Demandas de potência ativa em k;

$QL_k$ : Demandas de potência reativa em k;

$x_{km}$ : Estado da chave acoplada ao trecho km (0: aberto, 1: fechado);

$P_{km}$ : Fluxos de potência ativa no trecho km;

$Q_{km}$ : Fluxos de potência reativa no trecho km.

Ao utilizar a técnica de Pareto é possível avaliar os quatro objetivos separadamente, sem necessidade de pesos e ponderações, e ainda manter um compromisso entre eles. O objetivo da Equação 3.1 é minimizar a energia não suprida, que é dada pelo produto da

demanda de potência interrompida (kW) pelo tempo necessário para o restabelecimento. Está ligado à confiabilidade do SDEE, buscando garantir o máximo de fornecimento durante a restauração do sistema.

A Equação 3.2 está voltada à qualidade da energia entregue, cujo objetivo é minimizar a violação de tensão na barra  $k$ . O terceiro e o quarto objetivo buscam minimizar as perdas de potência do sistema e o número de chaveamento, respectivamente. Tanto a Equação 3.3 quanto a Equação 3.4, cuja última se preocupa em reduzir os desgastes dos dispositivos de manobra, dizem respeito à eficiência do processo de restabelecimento. A Equação 3.5 faz com que o algoritmo evite o corte de barras onde estão alocadas consumidores classificados como prioritários. O fluxo nos alimentadores é modelado pela Equação 3.6 e minimiza a violação, buscando distribuir as cargas sem sobrecarregar os alimentadores.

A estrutura radial da rede de distribuição é uma das restrições do problema, Equação 3.11. O algoritmo de enxame de partículas binário parte de um chamado caso base, que é uma topologia inicial pós-falha radial, com os trechos afetados desconectados do sistema e, a partir dele, é gerado um conjunto de topologias radiais candidatas. À medida que se aplica os passos do algoritmo para a obtenção das novas configurações, a radialidade é mantida pela aplicação da técnica de troca de posições, que é baseada na teoria de grafos (OLIVEIRA et al., 2014). A natureza discreta do problema, Equação 3.9, também já é automaticamente tratada pelo EPB.

Utilizando o método iterativo de Newton-Raphson é calculado um fluxo de potência para cada uma das topologias candidatas, de onde se obtém o balanço de potência das restrições modeladas pela Equação 3.7 e Equação 3.8. A restrição que trata o limite de tensão na rede, Equação 3.10, é atendida pelo objetivo modelado na Equação 3.2.

### 3.2.2 Sequência de Manobras

Esta etapa do problema determina a sequência em que as chaves manobráveis serão abertas ou fechadas. Ou seja, define o a ordem das manobras para que o sistema deixe a topologia pós falta até que se tenha a topologia ótima escolhida pelo operador na primeira etapa do problema.

A escolha dessa sequência leva em conta o tempo necessário para realizar cada manobra, considerando localização da chave e tempo de deslocamento de equipes de manutenção, e a potência que deixou de ser fornecida até que o sistema fosse restaurado. Dessa forma tem como objetivo maximizar a energia fornecida. Ainda, espera-se que a violação de tensão, enquanto as chaves são manobradas, seja mínima.

Cada possível sequência é avaliada pelo cálculo de fluxo de potência e analisada pela Equação 3.12, que modela os objetivos apresentadas nesse segundo estágio. O problema

da Etapa 2 também é sujeito às restrições de rede e natureza discreta das opções de chaveamento formuladas nas equações de 3.7 a 3.11.

$$Min \left[ \rho_{en} \cdot ENS + \rho_v \cdot \sum_{k=1}^{NB_V} (V_{min} - V_k) \right] \quad (3.12)$$

Neste estágio a função é tratada como único objetivo. Portanto para modelar o problema é necessária a utilização dos fatores  $\rho_{en}$  e  $\rho_v$  de penalidade ou compromisso entre os objetivos.

O AG vai determina o corte discreto de carga para cada sequencia proposta ao algoritmo. Cada indivíduo do algoritmo genético codifica uma solução candidata para o corte discreto de carga, se necessário, através de um vetor que tem o número de posições igual ao número de barras candidatas a corte. Cada posição deste vetor pode receber um valor binário, que, caso tenha valor “0” significa corte de carga na barra candidata correspondente[14].

### 3.3 Alocação de GD

O problema busca a alocação ótima de uma geração distribuída no sistema de distribuição de energia. Foram apresentadas ao método utilizado três opções: (i) não alocar GD, (ii) alocar geração termelétrica e (iii) alocar geração eólica.

#### 3.3.1 Formulação do Problema

São modelados dois objetivos para otimizar o problema: minimizar as emissões de  $CO_2$  para atmosfera, Equação (20) e minimizar o custo de investimento, Equação (21). As equações de (22) a (28) correspondem às restrições associadas a problema.

$$Min[Emissões] \quad (3.13)$$

$$Min \left[ (C_{inv}^{te} \cdot S_{inst}^{te}) + (C_{inv}^e \cdot S_{inst}^e) \right] \quad (3.14)$$

$$(x_k^{te} \cdot P_k^{te}) + (x_k^e \cdot P_k^e) - P_k^{carga} - \sum_{m \in \Omega_k} P_{km} = 0 \quad (3.15)$$

$$(x_k^{te} \cdot Q_k^{te}) + (x_k^e \cdot Q_k^e) - Q_k^{carga} - \sum_{m \in \Omega_k} Q_{km} = 0 \quad (3.16)$$

$$V_k, \geq V_k^{min} \quad (3.17)$$



$$x_k^{te}, x_k^e = 0 \text{ ou } 1 \quad (3.18)$$

$$x_k^{te} + x_k^e < 2 \quad (3.19)$$

$$\sum_{k \in NBC_k} x_k^{te} + \sum_{k \in NBC_k} x_k^e \leq NGD^{max} \quad (3.20)$$

Onde:

$C_{inv}^{te}$ : Custo de investimento em uma unidade de geração termelétrica a biomassa;

$C_{inv}^e$ : Custo de investimento em uma unidade de geração eólica;

$S_{inst}^{te}$ : Potência instalada da unidade de geração termelétrica a biomassa;

$S_{inst}^e$ : Potência instalada da unidade de geração eólica;

$P_k^{te}$ : Potência ativa gerada pela unidade de geração termelétrica a biomassa;

$P_k^e$ : Potência ativa gerada pela unidade de geração eólica;

$x_k^{te}$ : Variável de decisão de alocação de unidade de geração termelétrica a biomassa;

$x_k^e$ : Variável de decisão de alocação de unidade de geração eólica;

$P_k^{carga}$ : Potência ativa demandada pela carga;

$Q_k^{carga}$ : Potência reativa demandada pela carga;

$P_{km}$ : Potência ativa que flui da barra k para a barra m;

$Q_{km}$ : Potência reativa que flui da barra k para a barra m;

$NGD^{max}$ : Número máximo de geração distribuída;

$\Omega_k$ : Conjunto de todas as barras ligadas à barra k,

NBC: Número de barras candidatas à alocação.

As equações 3.15 e 3.16 representam o balanço de potência ativa e reativa, respectivamente, em cada barra do sistema. Na inequação 3.17 é modelada a restrição de limite mínimo de tensão nodal. A equação 3.18 retrata a característica discreta das variáveis de investimento em geração distribuída, alocar ou não alocar GD naquela barra. A condição de que uma mesma barra candidata pode receber a alocação exclusiva de geração eólica ou termelétrica é modelada pela inequação 3.19. Por fim, a inequação 3.20 limita a inserção de geração distribuída no sistema. As equações e inequações foram modeladas em (OLIVEIRA et al., 2015) e (NEVES, 2014).

### 3.3.2 Considerações Finais

O Sistema Elétrico de Potência é complexo e apresenta naturalmente inúmeras restrições. Modelar matematicamente tais condições de operação e de planejamento envolve variáveis contínuas de fluxo de potência bem como variáveis discretas de comutação de chaves e decisão de alocar ou não uma unidade geradora. Se fez necessário formular muitas

equações para representar todos os objetivos que se fizeram interessantes ao estudos e suas decorrentes restrições.

O trabalho apresentou a modelagem de dois problemas importantes no cenário da operação e do planejamento. Considerando a ocorrência de falta no sistema, a primeira formulação matemática viabiliza a obtenção de topologias pós-falha ótimas que estarão à disposição do operador. As equações também permitem a análise das topologias escolhidas buscando a sequência em que as chaves serão manobradas, sempre mantendo radialidade e conectividade do sistema, bem como buscando manter os níveis de tensão e fluxo nas barras e alimentadores de forma a garantir o máximo fornecimento. A segunda modelagem garante que sejam escolhidas as melhores barras para alocação de geradores distribuídos, levado em conta balanço de potência, qualidade da energia e eficiência do sistema, além de buscar por menores custos e redução da emissão de poluentes.

## 4 RESULTADOS

### 4.1 Considerações Iniciais

Neste capítulo são descritos três estudos de casos com dois sistemas muito conhecidos da literatura. O objetivo é analisar e avaliar a aplicação dos métodos propostos na solução dos problemas de energia elétrica modelados na sessão anterior. Os algoritmos foram implementados em MATLAB® versão 7.10.0 (R2010a).

O primeiro estudo de caso consiste no restabelecimento de energia após uma falha. A solução é obtida por dois estágios onde a topologia ótima pós falta é encontrada no primeiro e a sequencia de manobras é determinada no segundo estágio. O segundo estudo se dedica a encontrar a topologia ótima considerando a presença de barras que alimentam consumidores prioritários, além de avaliar o limite de fluxo nos alimentadores. No terceiro estudo é feita a alocação ótima de geração distribuída considerando a modelagem do problema na sessão 3.3.

### 4.2 Restabelecimento de Sistemas de Distribuição

Para este caso é utilizado o Sistema 33 Barras, apresentado em (BARAN & WU, 1989), que tem nível de tensão de 12,66 kV, carga total de 3715 kW, 1 subestação cuja tensão é mantida em 1,0 pu e cinco chaves NA.

Assim como em (OLIVEIRA et al., 2016) e (OLIVEIRA et al., 2015), o caso base consiste na topologia da Figura 10 otimizada para perdas mínimas cujas chaves abertas são S7, S9, S14, S32 e S37. Dois trechos são afetados pela falha S5 e S35, (OLIVEIRA et al., 2010), e a tensão mínima é 0,9 pu. Considera-se que todos os trechos de rede têm chaves manobráveis, implicando que todo trecho pode ser chaveado durante o restabelecimento.

#### 4.2.1 Reconfiguração

Para encontrar a topologia ótima após as falhas, as soluções candidatas são avaliadas por quatro dos objetivos modelados na sessão 3.2 deste trabalho. As equações de 3.1 a 3.4 consistem respectivamente em minimizar a energia não suprida, minimizar a violação de tensão e as perdas técnicas e minimizar o número de manobras de chaveamento, considerando que todas as barras tem o mesmo grau de prioridade.

A Tabela 2 apresenta os parâmetros do EPBM utilizados para o caso em estudo, que foram determinados empiricamente através de análises de sensibilidade envolvendo diversos estudos. Destaca-se que o algoritmo proposto apresenta poucos parâmetros, pois  $n_{Gb}$  e  $n_{LND}$  são definidos em função de  $n_{P*}$ .

O critério de convergência consiste apenas no número máximo de iterações, ou seja,




Figura 10 – Topologia inicial do Sistema 33 Barras pós falha.

Tabela 2 – Parâmetros do algoritmo EPBM

Fator	$it_{max}$	$n_{P^*}$	$n_{Gb}$	$n_{LND}$
Valor	100	100	$0,4 \cdot n_{P^*}$	$0,5 \cdot n_{P^*}$

a convergência prematura para um ponto suficientemente ótimo não é utilizada. Isto se deve ao fato de que o objetivo do modelo de otimização é determinar planos alternativos de restabelecimento e, neste caso, mesmo que um ponto suficientemente bom sob a ótica dos objetivos considerados seja obtido, permitir ao método evoluir até a iteração  $it_{max}$  viabiliza potencialmente a obtenção de soluções alternativas.

A Tabela 6 mostra algumas soluções extraídas do conjunto Pareto-ótimo (LND) obtido na convergência do algoritmo EPBM proposto. Neste caso, estas soluções foram selecionadas na LND por não implicar em corte carga, admitindo-se este critério como uma premissa do operador do sistema para a melhoria dos índices de confiabilidade, e que não há restrições impeditivas para a operação sob quaisquer destas soluções.

As Soluções 1 e 2 podem ser mais indicadas por apresentar menor número de manobras, embora impliquem em maiores perdas do que a Solução-3. A Solução-1 também

Tabela 3 – Soluções para o Estudo de Caso 1

Solução	Manobras	Tensão Mínima (pu)	Perdas (kW)	Nº de manobras
1	Fechar S9 Fechar S37	0,93 (Barra 6)	188,67	2
2	Fechar S14 Fechar S37	0,93 (Barra 6)	195,00	2
3	Fechar S7 Fechar S9 Fechar S37 Abrir S6	0,93 (Barra 32)	180,97	4
4	Fechar S14 Fechar S32 Fechar S37 Abrir S17	0,92 (Barra 17)	199,70	4

foi determinada em (OLIVEIRA et al., 2016), (OLIVEIRA et al., 2015) e (OLIVEIRA et al., 2010) e a Solução-2 em (BORGES et al., 2011). A partir destas análises, conclui-se que a oferta de alternativas para o operador de um SDEE constitui-se como principal vantagem do método proposto, haja vista que os trabalhos usados na comparação (OLIVEIRA et al., 2016) e (OLIVEIRA et al., 2015) oferecem apenas uma opção, que pode não ser a mais indicada para um dado caso.

#### 4.2.2 Sequência de manobras

A determinação da sequência de manobras é feita a partir das soluções encontradas pelo primeiro estágio do restabelecimento. Ou seja, encontradas as topologias ótimas, foram testadas através de algoritmo genético qual a sequência de chaveamento em que menos carga é cortada no processo. Os mesmos parâmetros do AG de (OLIVEIRA et al., 2016) foram utilizados nesta implementação e são mostrados na Tabela 4.

Tabela 4 – Parâmetros do AG

Fator	$it_{max}$	$n_{P^*}$	$n_C$	$n_m$	Elitismo
Valor	200	50	90%	20%	1 cromossomo

A convergência se dá pelo número máximo de iterações ou número de gerações consecutivas sem melhoria da solução corrente, neste caso parametrizado em 15 iterações. A Tabela 5 mostra a sequência de chaveamento ótima para cada solução apresentada pelo primeiro estágio do problema.

Para a Solução-1 fechando primeiro S37, ocorre o corte da barra 10 (45 kW) e fechando primeiro S9, o corte é feito na barra 16 (60 kW). Destaca-se que essa sequência

Tabela 5 – Sequência de manobras para as topologias ótimas.

Solução	Manobras	Sequência
1	Fechar S9 Fechar S37	1º Fechar S37 2º Fechar S9
2	Fechar S14 Fechar S37	Não relevante
3	Fechar S7 Fechar S9 Fechar S37 Abrir S6	1º Abrir S6 2º Fechar S37 3º Fechar S9 4º Fechar S7
4	Fechar S14 Fechar S32 Fechar S37 Abrir S17	1º Fechar S32 2º Fechar S14 3º Fechar S37 4º Abrir S17

também foi encontrada em (OLIVEIRA et al., 2016). A Solução-2 corta a barra 10 para qualquer sequência de chaveamento, deixando a escolha a cargo do operador. Na análise da Solução-3 observou-se que abrir S6 não cortou nenhuma carga. Fechando S37 e S9, também não ocorreu corte de carga, enquanto fechando S7 na sequência de S37 cortou a barra 10. Para a Solução-4, fechar S32 acarretava em perda da barra 10, bem como se fosse fechada primeiro S37, porém se o fechamento de uma fosse sequência da outra haveria queda da barra 10, enquanto fechar primeiro S32 e S14 em seguida não acarretou em corte de carga. Se S37 for fechada antes da abertura de S17 não ocorre queda de nenhuma barra, enquanto se S17 for aberta para depois fechamento de S37 podem cair a barra 14 ou a barra 32 (ambas com 60 kW).

#### 4.3 Restabelecimento de SDE considerando Consumidores Prioritários.

Como já dito, nem sempre é possível encontrar ou optar por uma topologia em que nenhuma carga seja cortada. Desta forma, muitas vezes o operador tem a missão de escolher qual barra será atendida e qual ficará sem fornecimento. No entanto, alguns consumidores já são previamente classificados como prioritários.

Neste caso, a topologia ótima é escolhida com o objetivo de minimizar, além do corte de carga geral do sistema modelado na Equação 3.1, o número de consumidores prioritários sem atendimento, Equação 3.5. Diferente no primeiro estudo de caso, este também analisa a violação de fluxo em cada alimentador, modelado pela Equação 3.6.

A otimização do problema foi feita novamente pelo algoritmo EPBM respeitando os mesmos parâmetros da Tabela 2, bem como o critério de parada descrito para a reconfiguração do estudo de caso anterior.

As análises foram feitas no Sistema 16 Barras da literatura, apresentado em (CIVANLAR et al., 1988). Este sistema apresenta 1 subestação com nível de tensão de 23 kV, carga total de 28,70 MW e 17,30 Mvar, três chaves seccionadoras ou normalmente abertas (NA), representadas na Figura 11 pelas linhas pontilhadas, e 13 chaves de interconexão ou normalmente fechadas (NF). Considera-se como caso base a topologia para perdas mínimas otimizada em (OLIVEIRA et al., 2015), cujas chaves abertas são S7, S8 e S16.

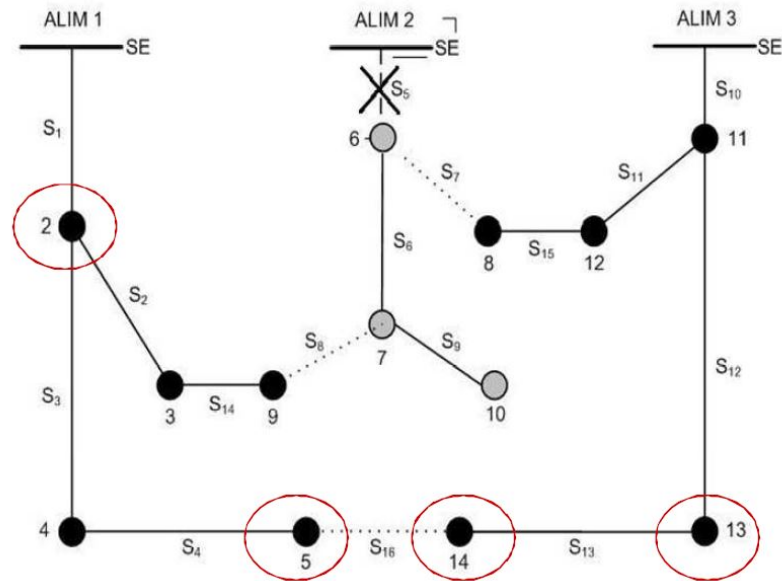


Figura 11 – Topologia inicial do Sistema 16 Barras pós-falha.

Uma falha é considerada no trecho S5, afetando o fornecimento das barras 6, 7 e 10, representadas pelas barras em cinza na configuração pós-falha da Figura 11. Ainda, as barras circuladas apontam para onde estão ligados os consumidores prioritários no sistema. A Tabela 6 apresenta as soluções encontradas pelo algoritmo.

Pode-se notar que o operador tem um leque de opções à sua disposição e pode escolher a topologia que pretende implantar no sistema atendendo a praticamente todas as possíveis restrições e operação. A Solução-1 se apresenta como uma boa candidata ao operador, não deixa nenhum consumidor sem fornecimento, no entanto apresenta altas perdas técnicas e violação de fluxo. Observa-se que na Solução-2 a violação de fluxo e perdas são bem menores que na primeira solução, além de melhorar o nível de tensão e ainda não cortar nenhum consumidor prioritário, no entanto apresenta corte de carga no sistema. Este é um caso em que talvez o operador julgue válido deixar algumas cargas de menor importância sem atendimento pensando na qualidade do sistema.

Algumas curiosidades são notadas nas soluções. A Solução-5, por exemplo, apresenta os piores níveis de tensão, valores de perda e violação de fluxo, no entanto não corta nenhuma carga e altera a topologia com apenas uma manobra. Caso as chaves manobráveis sejam manuais apresentando necessidade de envio de equipe de campo, está

Tabela 6 – Soluções para o Estudo de Caso 2.

Solução	Manobras	Tensão Mínima (pu)	Perdas (kW)	Carga Isol. (kW)	Viol. de Fluxo (A)	Nº de CPSA
1	Fechar S7 Fechar S8 Abrir S6	0,95 (Barra 10)	849,39	0	543,95	0
2	Fechar S7 Fechar S8 Abrir S9	0,96 (Barra 7)	522,87	450,0	398,17	0
3	Fechar S7 Fechar S8 Fechar S16 Abrir S11 Abrir S6	0,95 (Barra 10)	786,46	100,0	606,82	1
4	Fechar S7 Fechar S8 Fechar S16 Abrir S6 Abrir S15	0,96 (Barra 8)	642,67	500,0	252,38	0
5	Fechar S18	0,92 (Barra 6)	1.180,74	0	769,43	0
6	Fechar S7 Fechar S8 Abrir S4	0,96 (Barra 9)	743,08	150,0	594,82	1
7	Fechar S7 Fechar S8 Fechar S16 Abrir S2 Abrir S11	0,99 (Barra 4)	70,79	1.910,0	7,7	0
8	Fechar S7 Fechar S8 Abrir S13	0,96 (Barra 10)	738,73	210,0	580,65	1
9	Fechar S7 Fechar S8 Abrir S3	0,96 (Barra 8)	695,36	350,0	586,83	1

seria a opção provavelmente mais rápida de restabelecimento mantendo o atendimento a todos os consumidores.

Outro caso que pode acontecer no sistema é o da Solução-7 que apresenta excelente nível de tensão, quase 1,0pu, baixíssimas perdas e quase nenhuma violação de fluxo além de não cortar nenhum consumidor prioritário. No entanto as demais cargas do sistema são altamente prejudicadas. Dependendo dos critérios de qualidade da energia estabelecidos pela distribuidora e do grau de importância desses consumidores, a solução também pode



ser viável caso as chaves manobráveis sejam automáticas, por exemplo.

Vale salientar que, como dito na seção 2.1, os métodos implementados são do tipo a-posteriori onde os objetivos tem o mesmo grau de relevância. Portanto, o algoritmo julga que, por exemplo, minimizar número de manobras seja tão importante quanto minimizar a energia não suprida. Justificando assim a diversidade das soluções encontradas.

#### 4.4 Alocação de Geração Distribuída

O estudo de caso foi realizado novamente no Sistema 33 Barras da Figura 10. O cromossomo no SIA terá tantas posições quantas forem as barras candidatas a receber a alocação de GD. Nesse trabalho as barras 26, 27 e 28 serão consideradas aptas a receberem uma fonte de geração. As posições desse indivíduo podem ser admitir as seguintes variáveis de estado:

- 1: alocação de geração termelétrica baseada em biomassa na barra;
- 2: alocação de geração eólica;
- 0: não há alocação de GD

A Tabela 7 apresenta os parâmetros das unidades geradoras que foram considerados na simulação deste trabalho para a avaliação das soluções. Os dados nominais das unidades bem como os custos de investimento das mesmas são obtidos de (NEVES, 2014), que considera um horizonte de planejamento de 30 anos.

Tabela 7 – Parâmetros das unidades geradoras

Parâmetro	Valor
Capacidade dos Geradores Térmicos	250 kW
Fator de Potência dos Geradores Térmicos	0,8 adiantado
Fator de Capacidade dos Geradores Térmicos	100%
Capacidade dos Geradores Eólicos	700 kW
Fator de Potência dos Geradores Eólicos	0,9 adiantado
Fator de Capacidade dos Geradores Eólicos	18,8%
Custo de investimento em unidade de GD a Biomassa	2.293,00 \$/kVA
Custo de investimento em unidade de geração eólica	1.882,00 \$/kVA

Tabela 8 – Parâmetros do SIA Multiobjetivo

Fator	$it_{max}$	$n_{P^*}$	n	d	c	h	b
Valor	200	50	2%	1%	0,3%	0,3	1%

Onde:

$n_{P^*}$ : Tamanho do Repertório;

- n: Taxa de Seleção para clonagem;
- d: Taxa de Edição de Receptores;
- c: Constante que controla o processo de Clonagem;
- h: Constante que controla o processo de Hipermutação Somática;
- b: Taxa de Mutação.

O método aplicado para a resolução do problema neste estudo de caso foi apresentado na Figura 8. O algoritmo SIA Multiobjetivo foi implementado com os parâmetros da Tabela 8. As soluções da LND são mostradas na Tabela 9.

Tabela 9 – Soluções para o Estudo de Caso 3.

Barras Candidatas			Funções Objetivo	
Barra 26	Barra 27	Barra 28	Custo de Investimento (\$)	Emissões (Ton $CO_2$ )
0	0	0	0	926.610
1	1	1	2.150.000	727.340
0	1	1	1.430.000,00	791.740
0	2	1	790.000	848.810
0	2	2	150.000,00	907.660
0	0	1	720.000,00	858.030
0	0	2	70.000,00	917.060
2	1	1	1.510.000,00	782.770
2	2	1	860.000,00	839.720
2	2	2	220.000,00	848.460

Observa-se que uma das soluções apresentadas não aloca nenhuma GD em nenhuma barra. Como já dito, no método a-posteriori, os objetivos são tratados com mesmo grau de relevância, portanto custo de investimento zero é um bom resultado, porém as emissões tem o maior valor dentre as possibilidades apresentadas.

Pode-se notar também uma preferencia por alocação de geração eólica, presente em 6 das 9 soluções em que houve alocação, dados os custos de investimentos mais baixos em relação à geração térmica.

O conjunto também apresentou uma solução com alocação de térmica em todas as barras candidatas envolvendo altos custos de investimento, porém com o menor valor de emissão de poluentes das opções. Visto que geradores eólicos demandam grandes espaços para construção e boas características de vento, esta solução se torna viável caso o sistema esteja em alguma área de controle mais rígido de emissões. Neste caso custear a alocação de térmica seria melhor escolha do que não investir nada.

Como se trata de um problema de dois objetivos, é possível plotar o espaço de soluções, ou de objetivos como mostrado na Figura 12. Comparando à Figura 4, pode-se reforçar a característica de mínimo/mínimo com dois objetivos conflitantes como modelado para o problema.

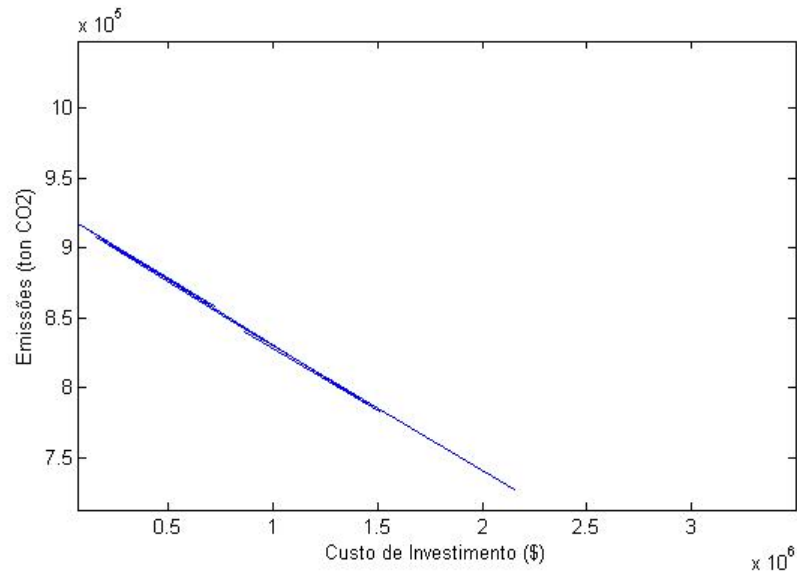


Figura 12 – Soluções do Estudo de Caso 3 no espaço de objetivos.

#### 4.5 Considerações Finais

Neste capítulo foram utilizados dois sistemas da literatura para avaliar a aplicação dos métodos propostos aos problemas modelados no presente trabalho. Três estudos de casos baseados nas modelagens apresentadas foram realizados.

O primeiro estudo aplicou o EPBM para encontrar as topologias ótimas na etapa de reconfiguração do sistema no problema do restabelecimento. Numa segunda etapa aplicou um algoritmo genético de corte para encontrar a sequência de manobras. No segundo estudo o EPBM avaliou as soluções considerando a presença de consumidores prioritários. A alocação de GD foi otimizada via SIA Multiobjetivo.

Os resultados obtidos foram os conjuntos ótimos das soluções. Estes resultados foram analisados e comparados à outros trabalhos da literatura e observou-se que muitos deles também foram encontrados pelos métodos mono-objetivo, mostrando a viabilidade dos métodos propostos. Constatou-se que a principal contribuição do tratamento multiobjetivo é a possibilidade do operador ou planejador escolher dentre um conjunto de soluções ótimas aquela que melhor atende às suas necessidades mesmo em situação de contingências e limitações.

## 5 CONCLUSÕES

### 5.1 Considerações Iniciais

A presente monografia apresentou duas metodologias de otimização multiobjetivo para aplicação em problemas de operação e de planejamento do Sistema Elétrico de Potência. O restabelecimento é solucionado via Enxame de Partículas Binário Multiobjetivo e encontra a topologia radial e conexa ótima do sistema de distribuição mediante a modelagem de seis objetivos individuais. A minimização do corte de carga, maximização de atendimento a consumidores prioritários, manutenção de níveis adequados de tensão e de fluxo nos alimentadores, e minimização do número de manobras e perdas técnicas na rede elétrica são tratados adequadamente sem a necessidade de ponderações e com o mesmo grau de relevância entre si. A determinação da sequência de chaveamento desde a falha até a configuração ótima é encontrada via Algoritmo Genético. O método minimiza energia não suprida e violação de tensão modeladas em apenas uma função objetivo e, neste caso, se fez necessário o uso de pesos que direcionaram a reconfiguração otimizando os objetivos a cada manobra. O Sistema Imunológico Artificial Multiobjetivo foi aplicado ao planejamento da rede de distribuição visando a alocação ótima de geradores distribuídos nas barras candidatas. A modelagem levou em conta os custos de investimento e emissões de poluentes na atmosfera, além das restrições intrínsecas ao sistema.

O Enxame de Partículas Binário Multiobjetivo foi implementado combinando técnicas de dominância de Pareto e operadores apresentados em referências da literatura à versão binária do Enxame de partículas (PSO). O PSO consiste em um tipo de inteligência de enxame e se baseia na revoada dos pássaros. Nessa técnica, o conjunto das soluções candidatas seria o bando, formada por partículas (como são chamados os pássaros) e a modelagem usa a experiência individual e coletiva das partículas para percorrer o espaço de busca (área sobrevoada pelo bando) e encontrar as soluções ótimas. Portanto, O permite a exploração eficiente do espaço de busca e a representação das variáveis binárias de chaveamento sem a necessidade de estratégias de discretização, enquanto que os critérios de Pareto permitem obter um conjunto de soluções “ótimas” segundo os diferentes objetivos do problema.

A implementação de técnicas de dominância e de fitness apresentados pela literatura para classificação das soluções candidatas ao princípio da seleção clonal do Sistema Imunológico Artificial originou no SIA Multiobjetivo proposto neste trabalho. Os SIAs são meta-heurísticas bioinspiradas na natureza e baseiam-se no comportamento das células de defesa do organismo dos animais (anticorpos), quando em contato com um agente estranho ao organismo (antígeno). Assim como no EPBM, a aplicação da meta-heurística se mostra eficiente na exploração do espaço de busca enquanto os critérios de Pareto e os operadores garantem a avaliação adequadas das soluções pelos diversos objetivos.

## 5.2 Trabalhos Futuros

Seguindo a linha de pesquisa desenvolvida na elaboração desta monografia e tendo em vista os resultados obtidos, algumas sugestões se tornam promissoras para trabalhos futuros:

- Implementar uma técnica meta-heurística Multiobjetivo para determinação da sequência de chaveamento no problema de restabelecimento, avaliando o algoritmo *spanning tree* e a teoria de grafos.
- Estender a busca de soluções na alocação de GD para sistemas de maior porte e redes reais de distribuição. Avaliar o impacto da alocação de GD no requisito qualidade de energia do sistema através de modelagem de novos objetivos.
- Estender a aplicação de otimização meta-heurística multi-objetivo para outros problemas de planejamento e operação de sistemas elétricos de potência.
- Desenvolver os conceitos de dominância de Pareto em outras técnicas meta-heurísticas, como os algoritmos por colônia de formigas, ecolocalização de morcegos e *monkey search*.

## 5.3 Considerações Finais

A avaliação dos métodos aplicados aos problemas pelos sistemas apresentaram resultados satisfatórios, muitos deles também encontrados por outros trabalhos da literatura. Os algoritmos propostos demonstraram eficácia e eficiência na busca por soluções ótimas. Destaca-se que a principal contribuição foi aliar mecanismos meta-heurísticos a técnicas que permitem oferecer alternativas para os operadores e planejadores dum sistema de energia, de modo a auxiliar no processo decisório, utilizando-se dos conceitos de dominância de Pareto.

## REFERÊNCIAS

- ALBERICO, C. E. A. Eficiência energética aplicada em instalações elétricas residenciais. Sardinha, Leonardo Carneiro, 2016.
- ANEEL, R. N. N. 687, de 24 de novembro de 2015. *AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, Brasil*, 2015.
- ARCANJO, D. N. et al. Metodologia multi-estágio para restabelecimento de sistemas elétricos de distribuição utilizando algoritmos bio-inspirados. Universidade Federal de Juiz de Fora, 2014.
- AZUMA, R. M. et al. Otimização multiobjetivo em problema de estoque e roteamento gerenciados pelo fornecedor. 2011.
- BARAN, M. E.; WU, F. F. Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power delivery*, IEEE, v. 4, n. 2, p. 1401–1407, 1989.
- BORGES, T. et al. Distribution systems restoration using the interior point method and sensibility analysis. In: IEEE. *Power and Energy Society General Meeting, 2011 IEEE*. 2011. p. 1–4.
- CASTRO, L. N. D.; ZUBEN, F. J. V. Learning and optimization using the clonal selection principle. *IEEE transactions on evolutionary computation*, IEEE, v. 6, n. 3, p. 239–251, 2002.
- CIVANLAR, S. et al. Distribution feeder reconfiguration for loss reduction. *IEEE Transactions on Power Delivery*, IEEE, v. 3, n. 3, p. 1217–1223, 1988.
- COELLO, C. A. C. Mopso: A proposal for multiple objective particle swarm optimization. In: *Proceedings of the 2002 Congress on Evolutionary Computation (CEC 2002)*. 2002. v. 2, p. 1051–1056.
- COELLO, C. C.; CORTÉS, N. C. An approach to solve multiobjective optimization problems based on an artificial immune system. In: *first international Conference on artificial immune systems (ICARIS'2002)*. 2002. p. 212–221.
- DEB, K. *Multi-objective optimization using evolutionary algorithms*. : John Wiley & Sons, 2001.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE transactions on evolutionary computation*, IEEE, v. 6, n. 2, p. 182–197, 2002.
- ENERGÉTICA, E. de P. *Plano Decenal de Energia*. : Brasília, 2014.
- KENNEDY, J.; EBERHART, R. (1995). particle swarm optimization. In: *IEEE International Conference on Neural Networks (Perth, Australia), IEEE Service Center, Piscataway, NJ*. 1995. p. 1942–1948.
- KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. In: IEEE. *Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference on*. 1997. v. 5, p. 4104–4108.

- LAMBERT-TORRES, G. et al. Comparison between pso and ga in system restoration solution. In: IEEE. *Intelligent System Applications to Power Systems, 2009. ISAP'09. 15th International Conference on.* 2009. p. 1–6.
- LUZIA, L. F.; RODRIGUES, M. C. Estudo sobre as metaheurísticas.
- MACIEL, R. S. Otimização multiobjetivo na análise da integração de geração distribuída às redes de distribuição. Universidade Estadual Paulista (UNESP), 2012.
- MILOCA, S. A.; FARIA, T. M. B.; VOLPI, N. M. P. Aplicação de algoritmo genético multiobjetivo em otimização de portfólios. 2012.
- NEVES, P. S. Planejamento de sistemas de distribuição de energia elétrica com geração distribuída através de algoritmos genéticos. Universidade Federal de Juiz de Fora, 2014.
- NORMATIVA, N. R. *482, 17 de Abril de 2012.* : Agência Nacional de Energia Elétrica, 2012.
- OLIVEIRA, L. et al. Planejamento de geração distribuída através de sistemas imunológicos artificiais. In: *Proc. 2015 XI Latin-American Congress on Electricity Generation and Transmission (CLAGTEE)*. 2015. p. 1–7.
- OLIVEIRA, L. W. et al. Restabelecimento de sistemas de distribuição de energia através da técnica enxame de partículas. *LINKSCIENCEPLACE-Interdisciplinary Scientific Journal*, v. 3, n. 1, 2016.
- OLIVEIRA, L. W. et al. Optimal restoration of power distribution system through particle swarm optimization. In: IEEE. *PowerTech, 2015 IEEE Eindhoven*. 2015. p. 1–5.
- OLIVEIRA, L. W. D. et al. Artificial immune systems applied to the reconfiguration of electrical power distribution networks for energy loss minimization. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 56, p. 64–74, 2014.
- OLIVEIRA, L. W. de et al. Optimal reconfiguration and capacitor allocation in radial distribution systems for energy losses minimization. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 32, n. 8, p. 840–848, 2010.
- PRODIST, A.-A. *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Módulo 8–Qualidade da Energia Elétrica.[Sl]:[sn]*, v. : Revisão, 2012.
- TICONA, W. G. C.; DELBÉM, A. C. B. Algoritmos evolutivos para otimização multi-objetivo. *Nova Didática*, v. 76, 2008.
- ZITZLER, E.; LAUMANN, M.; THIELE, L. Spea2: Improving the strength pareto evolutionary algorithm. 2001.
- ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. *IEEE transactions on Evolutionary Computation*, IEEE, v. 3, n. 4, p. 257–271, 1999.