



**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**UMA NOVA SOLUÇÃO PARA A OTIMIZAÇÃO DO DESPACHO ECONÔMICO E  
AMBIENTAL UTILIZANDO METAHEURÍSTICAS DA COMPUTAÇÃO BIO-  
INSPIRADA**

**TESE DE DOUTORADO**

**MANOEL HENRIQUE REIS NASCIMENTO**

**UFPA / ITEC / PPGE  
Campus Universitário do Guamá  
Belém-Pará-Brasil**

**2016**

**UMA NOVA SOLUÇÃO UMA NOVA SOLUÇÃO PARA A OTIMIZAÇÃO DO  
DESPACHO ECONÔMICO E AMBIENTAL UTILIZANDO METAHEURÍSTICAS  
DA COMPUTAÇÃO BIO-INSPIRADA**

**MANOEL HENRIQUE REIS NASCIMENTO**

Tese de Doutorado submetida à coordenação do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) do Instituto de Tecnologia da Universidade Federal do Pará (UFPA) como parte dos requisitos finais para obtenção do grau de Doutor em Engenharia Elétrica na área de Sistemas de Potência.

**PROF. Dr. MARCUS VINICIUS ALVES NUNES**  
**(Orientador – PPGEE – UFPA)**

**UFPA / ITEC / PPGEE**  
**Campus Universitário do Guamá**  
**Belém-Pará-Brasil**  
**2016**

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de  
Bibliotecas da UFPA

---

Nascimento, Manoel Henrique Reis, 1975-

Uma nova solução para a otimização do despacho econômico e ambiental utilizando metaheurísticas da computação bio-inspirada / Manoel Henrique Reis Nascimento.-2016.

Orientador : Marcus Vinicius Alves Nunes

Tese (Doutorado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2016.

1. Usinas termelétricas – modelos matemáticos. Usinas termelétricas – aspectos econômicos. Otimização matemática. Usinas elétricas – testes. I. Título.

CDD 23. ed. 621.31243

---

## AGRADECIMENTOS

A **Deus**, pois sem ele nada eu teria conseguido.

Aos meus pais, Manoel Nascimento Nonato e Lucinda Forasteiro Reis, por nunca terem medido esforços para propiciar uma boa educação com valores éticos e morais ensinados para toda a minha vida.

Aos meus irmãos e sobrinhos.

Ao Professor, Dr. Marcus Vinícius Alves Nunes pela orientação, competência e dedicação à realização desta tese.

Aos Professores Doutores Jandecy Cabral Leite e Jorge Laureano Moya Rodríguez pela capacidade e ensinamentos, sem os quais esse trabalho não teria sido possível de ser realizado.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica do ITEC-UFPA, em especial Prof<sup>o</sup>. Dr. José Augusto Lima Barreiros pelo apoio e convênio entre o ITEGAM e UFPA que trouxe para Manaus maiores oportunidades para alavancar o conhecimento da sociedade.

Aos colaboradores da secretaria do PPGEE-UFPA.

Aos colaboradores do ITEGAM que sempre apoiaram nesta jornada, em especial a Prof<sup>a</sup>. M.Sc. Tereza Felipe.

Aos coordenadores de Cursos do Centro Universitário do Norte - Uninorte que compreenderam, por diversas vezes, minhas viagens a Universidade Federal do Pará – UFPA, para as aulas e pesquisas, em especial a Prof<sup>a</sup>.

M.Sc. Helen Oliveira e Prof<sup>a</sup>. M.Sc. Viviane Costa Novo.

Aos meus colegas do Uninorte, em especial a Prof<sup>a</sup>. Laura Egas, Sílvia Brandão e Viviane Costa Novo que por vezes me incentivaram, motivando-me a permanecer firme nos estudos e nos objetivos traçados.

Aos colegas do curso de doutorado, em especial a Prof<sup>a</sup> M.Sc. Vanise dos Santos Rodrigues.

A Aline Santos pela compreensão e apoio imensuráveis para conclusão deste trabalho.

E a todas as pessoas que me acompanharam na conclusão desta jornada.

***Epígrafe***

*“O sábio é aquele que aceita que o conhecimento continuo é o último nível da aprendizagem.”*

*Henrique Reis*

***Dedicatória***

*Aos meus pais, Manoel Nascimento Nonato e Lucinda Forasteiro Reis*

## SUMÁRIO

<b>1</b>	<b>LISTA DE FIGURAS .....</b>	<b>11</b>
<b>1</b>	<b>LISTA DE TABELAS.....</b>	<b>14</b>
<b>2</b>	<b>GLOSSÁRIO .....</b>	<b>16</b>
<b>3</b>	<b>RESUMO .....</b>	<b>18</b>
<b>4</b>	<b>ABSTRACT .....</b>	<b>19</b>
<b>1</b>	<b>CAPÍTULO I.....</b>	<b>20</b>
	<b>INTRODUÇÃO.....</b>	<b>20</b>
1.1	Motivação .....	20
1.2	A Tese em Duas Etapas .....	22
1.3	Objetivos:.....	22
1.3.1.	Objetivo Geral .....	22
1.3.2.	Objetivos Específicos.....	23
1.4	Contribuição e Relevância do Estudo.....	23
1.5	Estrutura da Tese .....	24
<b>2</b>	<b>CAPÍTULO II.....</b>	<b>26</b>
	<b>PESQUISAS RELACIONADAS COM O DE E O DEA .....</b>	<b>26</b>
2.1	Introdução .....	26
2.1.1.	Despacho Econômico (DE).....	26
2.1.2.	Despacho Econômico e Ambiental (DEA) .....	29
2.2	Regulamentação Ambiental.....	34
<b>3</b>	<b>CAPÍTULO III.....</b>	<b>37</b>
	<b>USINAS TÉRMICAS .....</b>	<b>37</b>
3.1	Introdução .....	37
3.2	O motor diesel.....	37
3.3	Motores de Combustão Interna.....	37
3.3.1	Tipos Básicos de Motores Alternativos .....	38
3.3.2	Processo de Geração de Energia com Motores de Combustão .....	38
3.4	Recursos Energéticos .....	39
3.4.1	Turbina a gás .....	39
3.4.2	Caldeira de Recuperação de Calor (HRSG).....	41
3.5	Cogeração .....	42
3.6	Termoeconomia .....	42

3.7	Conclusões do capítulo .....	43
<b>4</b>	<b>CAPÍTULO IV .....</b>	<b>44</b>
	<b>TÉCNICAS DE OTIMIZAÇÃO .....</b>	<b>44</b>
4.1	Introdução .....	44
4.1.1.	Otimização multiobjetivo.....	44
4.2	Como Gerenciar Múltiplos Objetivos.....	47
4.3	Otimização Multiobjetivo e Soluções Ótimas de Pareto .....	47
4.4	Técnicas de Resolução de Problemas de Otimização Multiobjetivo .....	49
4.4.1	A Técnica de Transformação Escalar.....	50
<b>5</b>	<b>CAPÍTULO V.....</b>	<b>54</b>
	<b>MÉTODOS PARA OTIMIZAÇÃO DO DE/DEA.....</b>	<b>54</b>
5.1	Introdução .....	54
5.2	Métodos Determinísticos .....	54
5.2.1	Método de Iteração Lambda (MIL).....	54
5.2.2	Programação Quadrática Sequencial (SQP).....	56
5.2.3	Método de Newton (MN).....	59
5.3	Métodos Heurísticos .....	62
5.3.1	Algoritmo Evolução Diferencial (ED) .....	62
5.3.2	Algoritmos Genéticos (AGs).....	64
5.3.3	Algoritmo Genético de Classificação Não-Dominado (NSGA) .....	68
5.3.4	O Elitista Algoritmo Genético de Classificação Não-Dominado II (NSGA II).....	70
5.3.5	Otimização por enxame de partículas (PSO) .....	74
5.3.6	Algoritmo Colônia de Abelhas Artificial (ABC) .....	77
5.3.7	Recozimento Simulado (RS).....	80
5.3.8	Grey Wolf Optimizer (GWO) .....	81
5.3.9	Multiobjetivo NSGA-III (NSGA-III).....	87
5.4	Conclusões do capítulo .....	91
<b>6</b>	<b>CAPÍTULO VI .....</b>	<b>92</b>
	<b>METODOLOGIA PARA NOVA SOLUÇÃO DE OTIMIZAÇÃO DO DE/DEA .....</b>	<b>92</b>
6.1	Introdução .....	92
6.2	Características da Usina Termoeletrica (UTE) para o Estudo de Caso .....	92
6.2.1	Parâmetros de funcionamento da UTE – Estudo de Caso.....	94
6.2.2	Parâmetros de funcionamento da UTE – Sistema de Teste DE .....	97
6.2.3	Parâmetros de funcionamento da UTE Sistema de Teste – NSGA II.....	98
6.2.4	Parâmetros de funcionamento da UTE Sistema de Teste – NSGA III.....	99

6.2.5	Formulação Matemática para o Problema do DE .....	100
6.2.6	Formulação Matemática para o Problema do DEA – Estudo de Caso.....	104
6.2.7	Formulação Matemática para o DEA – Sistema de Teste – NSGA II.....	105
6.2.8	Formulação Matemática para o DEA – Sistema de Teste – NSGA III.....	105
6.3	Implementação dos Métodos Determinísticos .....	106
6.3.1	Aplicação do MIL – Estudo de Caso .....	106
6.3.2	Aplicação do MIL – Sistema de Teste .....	106
6.3.3	Aplicação do MN – Estudo de Caso .....	107
6.3.4	Aplicação do MN – Sistema de Teste .....	107
6.3.5	Aplicação do Método da PQ – Estudo de Caso .....	107
6.3.6	Aplicação do Método da PQ – Sistema de Teste .....	107
6.4	Implementação dos Métodos Heurísticos Mono-objetivo .....	108
6.4.1	Otimização do DE por Algoritmo Genético (AG) – Estudo de caso .....	108
6.4.2	GA comparativo com o Sistema de Teste. ....	111
6.4.3	Otimização do DE por Enxame de Partículas (PSO) – Estudo de caso. ....	112
6.4.4	PSO comparativo com o Sistema de Teste.....	115
6.4.5	Otimização do DE por Evolução Diferencial (ED) – Estudo de caso.....	116
6.4.6	ED comparativo com o Sistema de Teste.....	118
6.4.7	Otimização do DE por Lobo Cinzento (GWO) – Estudo de caso.....	119
6.4.8	GWO comparativo com o Sistema de Teste. ....	121
6.4.9	Otimização do DE por Recozimento Simulado (RS) – Estudo de caso.....	122
6.4.10	RS comparativo com o Sistema de Teste. ....	124
6.4.11	Otimização do DE por Colônias de Abelhas Artificial (ABC) – Estudo de caso.....	125
6.4.12	ABC comparativo com o Sistema de Teste.....	128
6.5	Implementação dos Métodos Heurísticos Multiobjetivos .....	128
6.5.1	Otimização do DEA por NSGA II – Estudo de caso. ....	129
6.5.2	NSGA II comparativo com o Sistema de Teste. ....	131
6.5.3	Otimização do DEA por NSGA III – Estudo de caso. ....	132
6.5.4	NSGA III comparativo com o Sistema de Teste. ....	135
6.6	Conclusões do capítulo .....	136
<b>7</b>	<b>CAPÍTULO VII.....</b>	<b>137</b>
	<b>APRESENTAÇÃO DOS RESULTADOS .....</b>	<b>137</b>
7.1	Introdução .....	137
7.2	Aplicação dos Métodos Determinísticos .....	137
7.2.1	Aplicação do MIL – Estudo de Caso .....	137

7.2.2	Aplicação do MIL – Sistema de Teste .....	139
7.2.3	Aplicação do MN – Estudo de Caso .....	142
7.2.4	Aplicação do MN – Sistema de Teste .....	144
7.2.5	Aplicação do Método da PQ – Estudo de Caso .....	147
7.2.6	Aplicação do Método da PQ – Sistema de Teste .....	149
7.3	Aplicação dos Métodos Heurísticos Mono-objetivo.....	152
7.3.1	Otimização do DE por Algoritmo Genético (AG) – Estudo de caso .....	152
7.3.2	GA comparativo com o Sistema de Teste. ....	154
7.3.3	Otimização do DE por Enxame de Partículas (PSO) – Estudo de caso. ....	157
7.3.4	PSO comparativo com o Sistema de Teste.....	159
7.3.5	Otimização do DE por Evolução Diferencial (ED) – Estudo de caso.....	162
7.3.6	ED comparativo com o Sistema de Teste.....	164
7.3.7	Otimização do DE por Lobo Cinzento (GWO) – Estudo de caso.....	167
7.3.8	GWO comparativo com o Sistema de Teste. ....	169
7.3.9	Otimização do DE por Recozimento Simulado (RS) – Estudo de caso.....	172
7.3.10	RS comparativo com o Sistema de Teste.....	174
7.3.11	Otimização do DE por Colônias de Abelhas Artificial (ABC) – Estudo de caso.....	177
7.3.12	ABC comparativo com o Sistema de Teste.....	179
7.4	Aplicação dos Métodos Heurísticos Multiobjetivos .....	182
7.4.1	Otimização do DEA por NSGA II – Estudo de caso. ....	182
7.4.2	NSGA II comparativo com o Sistema de Teste. ....	186
7.4.3	Otimização do DEA por NSGA III – Estudo de caso. ....	190
7.4.4	NSGA III comparativo com o Sistema de Teste. ....	197
7.5	Conclusões do capítulo .....	206
<b>8</b>	<b>CAPÍTULO VIII .....</b>	<b>207</b>
	<b>CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS .....</b>	<b>207</b>
8.1	Conclusões .....	207
8.2	Algumas sugestões para Futuros Trabalhos.....	208
<b>9</b>	<b>REFERÊNCIAS .....</b>	<b>210</b>
<b>10</b>	<b>ANEXOS .....</b>	<b>218</b>

## LISTA DE FIGURAS

<b>Figura 3.1</b> - Turbina a gás principais componentes. ....	40
<b>Figura 3.2</b> - Turbina a gás com ciclo simples. ....	41
<b>Figura 3.3</b> - Caldeira de Recuperação de Calor (HRSG). ....	41
<b>Figura 4.1</b> - Parâmetro/solução e superfície de Pareto, para um problema bidimensional. ....	46
<b>Figura 4.2</b> - Conceito geral da Curva de Pareto. ....	49
<b>Figura 4.3</b> - Conjunto de combinações de Pareto para dois objetivos. ....	49
<b>Figura 4.4</b> - Representação geométrica da soma ponderada no caso da curva de Pareto convexa. ....	52
<b>Figura 4.5</b> - Representação geométrica da soma ponderada, Curva de Pareto não - convexa. ....	53
<b>Figura 5.1</b> - MIL.....	55
<b>Figura 5.2</b> – Algoritmo da Programação Quadrática. ....	59
<b>Figura 5.3</b> – Algoritmo do Método de Newton. ....	61
<b>Figura 5.4</b> – Fluxograma básico do AG. ....	65
<b>Figura 5.5</b> - Seleção pelo método da roleta. ....	67
<b>Figura 5.6</b> - Processo de cruzamento de um ponto. ....	67
<b>Figura 5.7</b> - Processo de mutação. ....	68
<b>Figura 5.8</b> – Funcionamento do NSGA-II. ....	71
<b>Figura 5.9</b> – Sequência do algoritmo ABC. ....	79
<b>Figura 5.10</b> - Hierarquia de caça dos lobos cinzentos. ....	81
<b>Figura 5.11</b> - Vetor de posicionamento bidimensional e alguns dos possíveis vizinhos. ....	83
<b>Figura 5.12</b> - Possíveis posições no espaço 3D. ....	84
<b>Figura 5.13</b> - Posição atualização em GWO. ....	85
<b>Figura 5.14</b> - Atacando presas versus à procura de presas. ....	86
<b>Figura 5.15</b> - Quinze pontos de referência estruturados em um plano de referência normalizado para um problema de três objetiva com $p = 4$ . ....	88
<b>Figura 5.16</b> - Procedimento para calcular intercepto e, em seguida, formar a <i>hyper-plane</i> de pontos extremos, para um problema de três objetivos. ....	89
<b>Figura 5.17</b> - Associação dos membros da população com pontos de referência. ....	90
<b>Figura 6.1</b> - Diagrama Geral da Usina (a). ....	93
<b>Figura 6.2</b> - Diagrama Geral da Usina (b). ....	93
<b>Figura 6.3</b> - Diagrama Geral da Usina (c). ....	94
<b>Figura 6.4</b> - Curva de custo incremental de combustível. ....	103
<b>Figura 6.5</b> - Fluxograma de execução do Algoritmo Genético para Resolução do DE. ....	111
<b>Figura 6.6</b> - Fluxograma de execução do PSO para Resolução do DE. ....	115
<b>Figura 6.7</b> - Fluxograma de execução do ED para Resolução do DE. ....	118
<b>Figura 6.8</b> – Fluxo da proposta GWO para Resolução do DE. ....	121
<b>Figura 6.9</b> – Fluxo da proposta RS para Resolução do DE. ....	124
<b>Figura 6.10</b> – Fluxo da proposta ABC para Resolução do DE. ....	127
<b>Figura 6.11</b> – Fluxo da proposta NSGA II para Resolução do DEA. ....	131
<b>Figura 6.12</b> – Fluxo da proposta NSGA III para Resolução do DEA. ....	135
<b>Figura 7.1</b> – Gráfico Comparativo de Potência MIL – Estudo de Caso. ....	138
<b>Figura 7.2</b> – Gráfico Comparativo de Custo MIL – Estudo de Caso. ....	138
<b>Figura 7.3</b> - Gráfico Comparativo de Potência MIL vs Métodos Heurísticos. ....	140
<b>Figura 7.4</b> – Gráfico Comparativo de Potência, MIL - Sistema de Teste. ....	141
<b>Figura 7.5</b> – Gráfico Comparativo de Custo, MIL - Sistema de Teste. ....	142
<b>Figura 7.6</b> – Gráfico Comparativo de Potência MN – Estudo de Caso. ....	143
<b>Figura 7.7</b> – Gráfico Comparativo de Custo MN – Estudo de Caso. ....	143
<b>Figura 7.8</b> - Gráfico Comparativo de Potência MN vs Métodos Heurísticos. ....	145
<b>Figura 7.9</b> – Gráfico Comparativo de Potência, MN - Sistema de Teste. ....	146

<b>Figura 7.10</b> – Gráfico Comparativo de Custo, MN - Sistema de Teste. ....	147
<b>Figura 7.11</b> – Gráfico Comparativo de Potência MPQ – Estudo de Caso. ....	148
<b>Figura 7.12</b> – Gráfico Comparativo de Custo MPQ – Estudo de Caso. ....	148
<b>Figura 7.13</b> - Gráfico Comparativo de Potência MPQ – Métodos Heurísticos. ....	150
<b>Figura 7.14</b> – Gráfico Comparativo de Potência, MPQ - Sistema de Teste. ....	151
<b>Figura 7.15</b> – Gráfico Comparativo de Custo, MPQ - Sistema de Teste. ....	151
<b>Figura 7.16</b> – Gráfico Comparativo de Potência, AG – Estudo de Caso. ....	153
<b>Figura 7.17</b> – Gráfico Comparativo de Custo, AG – Estudo de Caso. ....	153
<b>Figura 7.18</b> - Gráfico Comparativo de Potência AG vs Métodos Heurísticos. ....	155
<b>Figura 7.19</b> – Gráfico Comparativo de Potência, AG - Sistema de Teste. ....	156
<b>Figura 7.20</b> – Gráfico Comparativo de Custo, AG - Sistema de Teste. ....	156
<b>Figura 7.21</b> – Gráfico Comparativo de Potência, PSO – Estudo de Caso. ....	158
<b>Figura 7.22</b> – Gráfico Comparativo de Custo, PSO – Estudo de Caso. ....	158
<b>Figura 7.23</b> - Gráfico Comparativo de Potência PSO vs Métodos Heurísticos. ....	160
<b>Figura 7.24</b> – Gráfico Comparativo de Potência, PSO - Sistema de Teste. ....	161
<b>Figura 7.25</b> – Gráfico Comparativo de Custo, PSO - Sistema de Teste. ....	161
<b>Figura 7.26</b> – Gráfico Comparativo de Potência, ED – Estudo de Caso. ....	163
<b>Figura 7.27</b> – Gráfico Comparativo de Custo, ED – Estudo de Caso. ....	163
<b>Figura 7.28</b> - Gráfico Comparativo de Potência ED vs Métodos Heurísticos. ....	165
<b>Figura 7.29</b> – Gráfico Comparativo de Potência, ED - Sistema de Teste. ....	166
<b>Figura 7.30</b> – Gráfico Comparativo de Custo, ED - Sistema de Teste. ....	166
<b>Figura 7.31</b> – Gráfico Comparativo de Potência, GWO – Estudo de Caso. ....	168
<b>Figura 7.32</b> – Gráfico Comparativo de Custo, GWO – Estudo de Caso. ....	168
<b>Figura 7.33</b> - Gráfico Comparativo de Potência GWO vs Métodos Heurísticos. ....	170
<b>Figura 7.34</b> – Gráfico Comparativo de Potência, GWO - Sistema de Teste. ....	171
<b>Figura 7.35</b> – Gráfico Comparativo de Custo, GWO - Sistema de Teste. ....	171
<b>Figura 7.36</b> – Gráfico Comparativo de Potência, RS – Estudo de Caso. ....	173
<b>Figura 7.37</b> – Gráfico Comparativo de Custo, RS – Estudo de Caso. ....	173
<b>Figura 7.38</b> - Gráfico Comparativo de Potência RS vs Métodos Heurísticos. ....	175
<b>Figura 7.39</b> – Gráfico Comparativo de Potência, RS - Sistema de Teste. ....	176
<b>Figura 7.40</b> – Gráfico Comparativo de Custo, RS - Sistema de Teste. ....	176
<b>Figura 7.41</b> – Gráfico Comparativo de Potência, ABC – Estudo de Caso. ....	178
<b>Figura 7.42</b> – Gráfico Comparativo de Custo, ABC – Estudo de Caso. ....	178
<b>Figura 7.43</b> - Gráfico Comparativo de Potência ABC vs Métodos Heurísticos. ....	180
<b>Figura 7.44</b> – Gráfico Comparativo de Potência, ABC - Sistema de Teste. ....	181
<b>Figura 7.45</b> – Gráfico Comparativo de Custo, ABC - Sistema de Teste. ....	181
<b>Figura 7.46</b> – Gráfico Comparativo de Potência, NSGA II – Estudo de Caso. ....	184
<b>Figura 7.47</b> – Gráfico Comparativo de Custo, NSGA II – Estudo de Caso. ....	184
<b>Figura 7.48</b> – Gráfico Comparativo de Emissões, NSGA II – Estudo de Caso. ....	185
<b>Figura 7.49</b> – Frente de Pareto da Solução Clássica, NSGA II – Estudo de Caso. ....	185
<b>Figura 7.50</b> – Frente de Pareto da Redução de Custos, NSGA II – Estudo de Caso. ....	186
<b>Figura 7.51</b> – Frente de Pareto da Redução de Emissões, NSGA II – Estudo de Caso. ....	186
<b>Figura 7.52</b> – Gráfico Comparativo de Potência, NSGA II – Sistema de Teste. ....	188
<b>Figura 7.53</b> – Gráfico Comparativo de Custo, NSGA II – Sistema de Teste. ....	188
<b>Figura 7.54</b> – Gráfico Comparativo de Emissões, NSGA II – Sistema de Teste. ....	189
<b>Figura 7.55</b> – Frente de Pareto da Solução Clássica, NSGA II – Sistema de Teste. ....	189
<b>Figura 7.56</b> – Frente de Pareto da Redução de Custos, NSGA II – Sistema de Teste. ....	190
<b>Figura 7.57</b> – Frente de Pareto da Redução de Emissões, NSGA II – Sistema de Teste. ....	190
<b>Figura 7.58</b> – Gráfico Comparativo de Potência, NSGA III – Estudo de Caso. ....	192
<b>Figura 7.59</b> – Gráfico Comparativo de Custo de Combustível, NSGA III – Estudo de Caso. ....	193
<b>Figura 7.60</b> – Gráfico Comparativo de emissões de NOx, NSGA III – Estudo de Caso. ....	194

<b>Figura 7.61</b>	– Gráfico Comparativo de emissões de CO <sub>2</sub> , NSGA III – Estudo de Caso.....	195
<b>Figura 7.62</b>	– Melhores indivíduos para solução Clássica, NSGA III – Estudo de Caso. ....	196
<b>Figura 7.63</b>	– Melhores indivíduos para Redução de Custo, NSGA III – Estudo de Caso.....	196
<b>Figura 7.64</b>	– Melhores indivíduos para Redução de CO <sub>2</sub> , NSGA III – Estudo de Caso. ....	197
<b>Figura 7.65</b>	– Melhores indivíduos para Redução de NO <sub>x</sub> , NSGA III – Estudo de Caso.....	197
<b>Figura 7.66</b>	– Gráfico Comparativo de Potência, NSGA III – Sistema de Teste. ....	199
<b>Figura 7.67</b>	– Gráfico Comparativo de Custo de Combustível, NSGA III – Sistema de Teste. ....	200
<b>Figura 7.68</b>	– Gráfico Comparativo de emissões de NO <sub>x</sub> , NSGA III – Sistema de Teste.....	201
<b>Figura 7.69</b>	– Gráfico Comparativo de emissões de CO <sub>x</sub> , NSGA III – Sistema de Teste.....	202
<b>Figura 7.70</b>	– Melhores indivíduos para solução Clássica, NSGA III – Sistema de Teste. ....	203
<b>Figura 7.71</b>	– Melhores indivíduos para Redução de Custo, NSGA III – Sistema de Teste.....	203
<b>Figura 7.72</b>	– Melhores indivíduos para Redução de CO <sub>2</sub> , NSGA III – Sistema de Teste. ....	204
<b>Figura 7.73</b>	– Melhores indivíduos para Redução de NO <sub>x</sub> , NSGA III – Sistema de Teste. ....	204
<b>Figura 7.74</b>	– Consolidado de Custos DE – Estudo de Caso. ....	205
<b>Figura 7.75</b>	– Consolidado de Custos DE – Sistema de Teste. ....	206

## LISTA DE TABELAS

<b>Tabela 2.1</b> - Classificação dos combustíveis segundo seu estado físico. ....	35
<b>Tabela 3.1</b> - Classificação dos combustíveis segundo seu estado físico .....	39
<b>Tabela 6.1</b> - Principais componentes.....	94
<b>Tabela 6.2</b> - Dados característicos dos geradores da planta. ....	95
<b>Tabela 6.3</b> - Coeficientes de Perdas $B_i$ . ....	95
<b>Tabela 6.4</b> – Coeficientes de Emissões Gerais - Estudo de Caso.....	96
<b>Tabela 6.5</b> – Coeficientes de Emissões de $\text{NO}_x$ - Estudo de Caso.....	96
<b>Tabela 6.6</b> – Coeficientes de Emissões de $\text{CO}_2$ - Estudo de Caso.....	97
<b>Tabela 6.7</b> - Características dos geradores do Sistema de Teste DE.....	97
<b>Tabela 6.8</b> - Dados característicos dos geradores do Sistema de Teste - NSGA II.....	98
<b>Tabela 6.9</b> – Coeficientes de Emissões Gerais Sistema de Teste – NSGA II. ....	98
<b>Tabela 6.10</b> – Coeficientes de Perdas Sistema de Teste – NSGA II. ....	99
<b>Tabela 6.11</b> - Dados característicos dos geradores do Sistema de Teste - NSGA III.....	99
<b>Tabela 6.12</b> – Coeficientes de Emissões de $\text{NO}_x$ Sistema de Teste – NSGA III.....	99
<b>Tabela 6.13</b> – Coeficientes de Emissões de $\text{CO}_x$ Sistema de Teste – NSGA III.....	100
<b>Tabela 6.14</b> – Coeficientes de Perdas Sistema de Teste – NSGA III.....	100
<b>Tabela 7.1</b> - Relatório de saída do MIL – Estudo de Caso.....	137
<b>Tabela 7.2</b> - Comparação dos resultados de cada método com o MIL - Sistema de Teste. ....	139
<b>Tabela 7.3</b> - Relatório de saída do MIL – Sistema de Teste.....	140
<b>Tabela 7.4</b> - Relatório de saída do MN – Estudo de Caso.....	142
<b>Tabela 7.5</b> - Comparação dos resultados de cada método com o MN - Sistema de Teste. ....	144
<b>Tabela 7.6</b> - Relatório de saída do MN – Sistema de Teste.....	145
<b>Tabela 7.7</b> - Relatório de saída do MPQ – Estudo de Caso. ....	147
<b>Tabela 7.8</b> - Comparação dos resultados de cada método com o MPQ - Sistema de Teste.....	149
<b>Tabela 7.9</b> - Relatório de saída do MPQ – Sistema de Teste. ....	150
<b>Tabela 7.10</b> - Relatório de saída do AG – Estudo de Caso. ....	152
<b>Tabela 7.11</b> - Comparação dos resultados de cada método para o Sistema de Teste.....	154
<b>Tabela 7.12</b> - Relatório de saída do AG – Sistema de Teste. ....	155
<b>Tabela 7.13</b> - Relatório de saída do PSO – Estudo de Caso.....	157
<b>Tabela 7.14</b> - Comparação dos resultados de cada método para o Sistema de Teste.....	159
<b>Tabela 7.15</b> - Relatório de saída do PSO – Sistema de Teste.....	160
<b>Tabela 7.16</b> - Relatório de saída do ED – Estudo de Caso.....	162
<b>Tabela 7.17</b> - Comparação dos resultados de cada método para o Sistema de Teste. ....	164
<b>Tabela 7.18</b> - Relatório de saída do ED – Sistema de Teste.....	165
<b>Tabela 7.19</b> - Relatório de saída do GWO – Estudo de Caso.....	167
<b>Tabela 7.20</b> - Comparação dos resultados de cada método para o Sistema de Teste.....	169
<b>Tabela 7.21</b> - Relatório de saída do GWO – Sistema de Teste. ....	170
<b>Tabela 7.22</b> - Relatório de saída do RS – Estudo de Caso. ....	172
<b>Tabela 7.23</b> - Comparação dos resultados de cada método para o Sistema de Teste.....	174
<b>Tabela 7.24</b> - Relatório de saída do RS – Sistema de Teste.....	175
<b>Tabela 7.25</b> - Relatório de saída do ABC – Estudo de Caso.....	177
<b>Tabela 7.26</b> - Comparação dos resultados de cada método para o Sistema de Teste.....	179
<b>Tabela 7.27</b> - Relatório de saída do ABC – Sistema de Teste.....	180
<b>Tabela 7.28</b> - Resultados de saída do NSGA II – Estudo de Caso.....	183
<b>Tabela 7.29</b> - Comparação dos resultados para o Sistema de Teste - NSGA II. ....	187
<b>Tabela 7.30</b> – Parâmetros do DEA. NSGA III – Estudo de Caso. ....	191
<b>Tabela 7.31</b> - Resultados de saída de potência ótima. NSGA III – Estudo de Caso. ....	191
<b>Tabela 7.32</b> - Resultados de custos totais (R\$). NSGA III – Estudo de Caso.....	192

<b>Tabela 7.33</b> - Resultados de emissões de NO <sub>x</sub> . NSGA III – Estudo de Caso. ....	193
<b>Tabela 7.34</b> - Resultados de emissões de CO <sub>2</sub> . NSGA III – Estudo de Caso. ....	195
<b>Tabela 7.35</b> – Parâmetros do DEA. NSGA III – Sistema de Teste. ....	198
<b>Tabela 7.36</b> - Resultado de saída de potência ótima. NSGA III – Sistema de Teste. ....	198
<b>Tabela 7.37</b> - Resultados de custos totais (R\$). NSGA III – Sistema de Teste. ....	199
<b>Tabela 7.38</b> - Resultados de emissões de NO <sub>x</sub> . NSGA III – Sistema de Teste. ....	200
<b>Tabela 7.39</b> - Resultados de emissões de CO <sub>x</sub> . NSGA III – Sistema de Teste. ....	202
<b>Tabela 7.40</b> – Consolidado de Custo Métodos Propostos – Estudo de Caso. ....	205
<b>Tabela 7.41</b> – Consolidado de Custo Métodos Propostos – Sistema de Teste. ....	205

## GLOSSÁRIO

<b>PIM</b>	Polo Industrial de Manaus
<b>UTE</b>	Usinas Termoeletricas
<b>DE</b>	Despacho Economico
<b>DEA</b>	Despacho Economico e Ambiental
<b>MIL</b>	Metodo de Iteracao Lambda
<b>MPQ</b>	Metodo Programacao Quadratica
<b>MN</b>	Metodo de Newton
<b>AG</b>	Algoritmos Geneticos
<b>PSO</b>	Otimizacao por Enxame de Particulas
<b>ED</b>	Evolucao Diferencial
<b>RS</b>	Recozimento Simulado
<b>GWO</b>	Otimizacao por Lobo Cinzento
<b>ABC</b>	Colonia de Abelhas Artificiais
<b>NSGA</b>	Algoritmo Genetico de Classificacao Nao-dominado
<b>NSGA II</b>	O Elitista Algoritmo Genetico de Classificacao Nao-Dominado II
<b>NSGA III</b>	Algoritmo Genetico de Classificacao Nao-dominado III
<b>MOP</b>	Problema de Otimizacao Multiobjetivo
<b>AI</b>	Inteligencia Artificial
<b>LR</b>	Relaxamento Lagrangiano
<b>PD</b>	Programacao Dinamica
<b>MH</b>	Metodo Hierarquico
<b>CF</b>	Colonia de Formigas
<b>FB</b>	FORAGEAMENTO Bacteriano
<b>BBO</b>	Otimizacao Baseada Biogeografia
<b>MCS</b>	Simulacao de Monte Carlo
<b>DED</b>	Despacho Economico Dinamico
<b>IWO</b>	Ervas Daninhas Invasoras
<b>IWO</b>	Opositoras Ervas Daninhas Invasoras
<b>MOEA</b>	Algoritmo Evolutivo Multiobjetivo
<b>UHC</b>	Hidro Carbono nao Queimado
<b>MCI</b>	Motor de Combustao Interna
<b>SI</b>	<i>Spark Ignition</i>
<b>CI</b>	Ignicao por Compressao
<b>CC</b>	Camara de Combustao
<b>HRSG</b>	Caldeira de Recuperacao de Calor
<b>CHP</b>	Sistemas Combinados de Calor e de Energia
<b>WSM</b>	Metodo da Soma Ponderada
<b>PQS</b>	Programacao Quadratica Sequencial
<b>PQ</b>	Programacao Quadratica
<b>VEGA</b>	Vetor de Evolucao GA
<b>MOO</b>	Otimizacao Multiobjetivo
<b>SBX</b>	Crossover Binario Simulado
<b>GPDF</b>	Funcao de Distribuicao de Probabilidade Gaussiana
$F_i$	Custo total de combustivel
$P_D$	Demanda de potencia
$P_{mini}$	Potencia minima
$P_{maxi}$	Potencia maxima
$P_L$	Perda da rede de transmissao
$F_i^{min}$	Limite inferior de combustivel fornecido
$F_i^{max}$	Limite superior de combustivel fornecido
$V_{min}$	Limite inferior de armazenamento de combustivel
$V_{max}$	Limite superior de armazenamento de combustivel
<b>CTPSO</b>	O PSO convencional com a estrategia de tratamento de restricao
<b>CSPSO</b>	PSO com sequencias caoticas
<b>COPSO</b>	PSO com a operacao de cruzamento
<b>CCPSO</b>	PSO com ambas as sequencias caoticas e operacao de cruzamento

$\text{NO}_x$	Oxido de Nitrogênio
$\text{CO}$	Monóxido de carbono
$\text{CO}_2$	Dióxido de Carbono
$\text{SO}_x$	Óxido de Enxofre
$Eg_i$	Função de Emissão Geral
$NOx_i$	Função de Emissão de $\text{NO}_x$
$CO_{2i}$	Função de Emissão de $\text{CO}_2$
$f_1$	Função do custo total de combustível, considerando o efeito de <i>valve-point</i>
$f_2$	Função de Emissão Geral – (NSGA II)
$F_{FC}$	Função do custo total de combustível – (NSGA III)
$F_{NX}$	Função de Emissão de $\text{NO}_x$ – (NSGA III)
$F_{CX}$	Função de Emissão de $\text{CO}_x$ – (NSGA III)

## RESUMO

Devido ao crescimento industrial da Região Norte, principalmente do Polo Industrial de Manaus (PIM) e conseqüentemente o aumento da necessidade de geração de energia, que nesta região é fornecida em mais de 90% de seu total por Usinas Termoelétricas (UTE), tornou-se necessário a implementação de ferramentas computacionais que propiciem ao especialista, ou operador de sistemas elétricos, tomar decisões sobre o despacho de potência ótima de cada unidade geradora, contemplando não somente a redução de custos, mas também a diminuição dos índices de poluição na atmosfera. O Despacho Econômico (DE), ou despacho ótimo, é uma das tarefas mais antigas e importantes na gestão de usinas de energia elétrica, e atualmente, devido às crescentes preocupações com o meio ambiente, este problema vem sendo estendido para a otimização do Despacho Econômico e Ambiental (DEA). Esta tese tem como objetivo geral analisar uma nova proposta de solução para o antigo problema de otimização do DE e do DEA implementada por diversos métodos Determinísticos (Iteração Lambda, Programação Quadrática e Método de Newton) e métodos Heurísticos (Algoritmos Genéticos, Enxame de Partículas, Evolução Diferencial, Recozimento Simulado, Otimização por Lobo Cinzento e Colônia de Abelhas Artificiais) para o problema do DE e para o problema do DEA (Algoritmo Genético de Classificação Não-dominado, NSGA II e NSGA III), considerando o desligamento dos geradores com maior custo de operação, com a conseqüente redução no custo dos combustíveis. O método do custo incremental e as perdas de transmissão são utilizados para determinar os valores de potência ativa de cada unidade geradora, assegurando o balanço energético entre a potência total gerada, a demanda do sistema elétrico, as perdas, e minimizando, por outro lado, o custo total do combustível, reduzindo as emissões, e ainda melhorando a eficiência não somente dos geradores, mas também da UTE como um todo. A solução proposta nesta tese tem as seguintes contribuições: contempla o desligamento dos sistemas de geração que apresentam maior custo com combustível, reduz os custos totais permitindo uma manutenção preditiva nestas máquinas; determina soluções ótimas para a potência de saída em vários cenários característicos e não característicos das usinas, considerando variações na geração de potência ativa e na redução das emissões de gases poluentes como,  $\text{NO}_x$  e o  $\text{CO}_2$ . Para analisar a viabilidade da solução proposta por esta tese, utilizou-se um conjunto de dez unidades geradoras térmicas como parâmetros para o estudo de caso e três conjuntos de geradores, descritos na literatura, como sistema de teste para validação da robustez da proposta de solução apresentada. Foram aplicados diversos métodos determinísticos e de computação Bio-inspirada para a otimização mono-objetivo e multiobjetivo. Os resultados apresentados na tese, a partir da análise de vários exemplos práticos, mostram as vantagens da nova solução proposta.

**Palavras-Chave:** Otimização, Despacho Econômico, Despacho Econômico e Ambiental, Métodos Determinísticos e Heurísticos e Computação Bio-inspirada.

## ABSTRACT

Due to the significant industrial growth in the North of Brazil, especially at the Industrial Pole of Manaus (PIM), it has been an increased necessity for energy generation, which in this region is provided by thermoelectric plants (UTES) in over 90% of its total. Thus, it became necessary the use of computational tools that help the specialists or operators of electrical systems, for making decisions about the optimal power dispatch of each generating unit that contemplate not only to reduce costs but also reduce the atmospheric pollution levels. Optimization of Economic Dispatch (ED) is one of the oldest and most important tasks in power plant management, and currently, due to growing concerns about the environment, this problem is extended to the optimization of the Economic and Environmental Dispatch (EAD). This thesis has as main objective to analyze a new proposal to solve the old optimization problem of ED and the EAD implemented by several Deterministic methods (Iteration Lambda, Quadratic Programming and Newton method) and Heuristic methods (Genetic Algorithms, Particle Swarm, Differential evolution, Simulated Annealing, Optimization by Grey Wolf and Artificial Bee Colonies) for the ED problem. Non-dominated Sorting Genetic Algorithms (NSGA II and NSGA III), were used for evaluating the problem of EAD, considering the shutdown of the generators with higher losses and thus reducing the fuel cost. The method of incremental cost and transmission losses are used to determine the best active power values for each generating unit. It was ensured the energy balance between the total generated power, the demand of the electrical system, losses and minimizing, on the other hand, the total cost of fuel, reducing emissions, and further improving efficiency not only for generators but also to UTE as a whole. Consequently, the proposed new solution has the following contributions: contemplates the turning off generation systems that have higher fuel cost, reducing the overall costs and enabling predictive maintenance on these machines. This approach also determines optimal solutions for the power output in various scenarios characteristic and not characteristic of UTES or power plants, considering changes in active power generation and reducing greenhouse gas emissions as  $\text{NO}_x$  and  $\text{CO}_2$ . To explore the feasibility of the new solution proposed by this theory, it was used as a test system a set of ten (10) generating units for the case study and three sets of generators' parameters described in the literature. They were used for demonstrating the robustness of the proposed solution considering the use of various deterministic and Bio-inspired computing methods for mono-objective and multi-objective optimization. The results presented here, from an analysis of several practical examples show the advantages of the new proposed solution.

**Keywords:** Economic dispatch, optimization, economic environmental dispatch, deterministic and heuristic methods, bio – inspired computing.

---

# CAPÍTULO I

---

## INTRODUÇÃO

### 1.1 Motivação

Recursos energéticos limitados levaram à busca de fontes alternativas de energia, especialmente nos países em desenvolvimento. O fato de que o consumo de energia renovável é menos prejudicial ao meio ambiente também desencadeou a busca por novas alternativas para geração de energia, diversificando a matriz mundial (DESTEK, 2016).

Por outro lado, o uso dos combustíveis fósseis ainda tem uma grande importância na matriz energética mundial, e nas últimas décadas o mundo tem sido confrontado com a falta de energia elétrica, devido também à escassez desses recursos convencionais, e claro ao aumento das restrições ambientais. Esta situação trouxe a necessidade da busca por metodologias mais eficientes que tornem o uso dos combustíveis fósseis mais competitivos, em termos técnicos e econômicos.

Desenvolver sistemas de geração de energia mais eficientes tem sido uma busca incessante por diversas nações, não somente preocupadas com a geração da energia para atender sua crescente demanda, mas também por uma geração de energia menos poluente, com reduções nos níveis de emissão de gases geradores do efeito estufa.

Ao mesmo tempo, o esgotamento rápido dos combustíveis fósseis, a taxa alarmante de elevação dos índices de poluição da atmosfera terrestre, o aumento do impacto do aquecimento global e as rigorosas leis de antipoluição impostas em alguns países geraram um estímulo extra para a exploração e avaliação de combustíveis alternativos para motores de combustão interna (ABEDIN *et al.*, 2013).

O aumento da consciência ambiental global tem levado muitos pesquisadores a considerarem as emissões no problema do Despacho Econômico. As emissões de poluentes perigosos e nocivos, como dióxido de enxofre (SO<sub>2</sub>), óxido de nitrogênio (NO<sub>x</sub>), monóxido de carbono (CO) e dióxido de carbono (CO<sub>2</sub>) deram origem a apelos generalizados para as concessionárias de energia elétrica desenvolverem maneiras de reduzir esses poluentes (NWULU e XIA, 2015). Como as questões ambientais, particularmente as alterações climáticas, tornam-se cada vez mais importantes, as exigências relativas ao consumo e à produção de energia elétrica vêm sofrendo cada vez mais exigências para o enquadramento

dentro de determinados padrões internacionais. Nacionalmente, a legislação brasileira delimita o nível de emissões de gases poluentes na atmosfera, oriundos da produção de energia em usinas termoelétricas, com multas e outras punições (CONAMA, 2006).

O crescimento no consumo de energia é um resultado do aumento populacional e do desenvolvimento dos países, resultando em um grande aumento na demanda por energia elétrica. No ritmo atual de aumento no uso de energia, a demanda desta deverá aumentar 65% dos níveis de 2004 até 2030. No entanto, a maior parte da energia atualmente utilizada em todo o mundo é derivada das fontes não renováveis (IRANDOUST, 2016). Assim, desenvolver novas metodologias que reduzam as emissões de gases poluentes ou que tornem mais eficientes o uso dos motores de combustão interna tratados na presente tese, trará uma redução significativa nos impactos ambientais oriundos da produção de energia em sistemas termoelétricos.

De 1999 a 2013, programas de eletrificação rural trouxeram acesso à energia elétrica para 16 milhões de habitantes no Brasil. Mesmo assim, cerca de 155.000 famílias rurais continuam sem acesso à energia elétrica na Região Amazônica, vivendo em comunidades muito isoladas que não podem ser atendidas pela expansão da rede e do sistema interligado nacional existente. Para fornecer eletricidade a essas comunidades, geração *off-grid* através de combustível diesel tem sido tradicionalmente a única opção considerada (SÁNCHEZ *et al.*, 2015).

Aliado a este contexto, devido à grande capacidade de produção industrial na Região Norte e, em especial, o Polo Industrial de Manaus/AM (PIM), onde cerca de mais de 90% de sua energia é oriunda de Usinas Termoelétricas (UTE), torna-se necessária a utilização de ferramentas computacionais que propiciem aos gestores e especialistas destas UTE's a tomada de decisões sobre a otimização no consumo de combustível, manutenção dos geradores, produção de energia, eficiência energética e redução nos níveis de poluição, ainda levando em conta o atendimento da conformidade com os padrões das normas de qualidade de energia correspondentes.

Neste sentido, o problema do Despacho Econômico (DE) baseia-se em minimizar simultaneamente o custo total e ao mesmo tempo satisfazer a demanda de potência da planta produtora, não desprezando as restrições de carga e operação da UTE (AYDIN *et al.*, 2014); (TIAN *et al.*, 2015). No problema clássico do DE, a geração de potência ativa a partir de combustíveis fósseis, tais como carvão, petróleo e gás liberam uma grande quantidade de emissões atmosféricas, representadas por gases poluentes, como óxidos de enxofre (SO<sub>x</sub>), NO<sub>x</sub>,

CO<sub>2</sub> e algumas partículas. Assim, com a crescente sensibilização da população mundial para a proteção ambiental e a implementação de alterações em tais leis, tornou-se essencial para a otimização a consideração não apenas do custo de combustível, mas também os níveis de emissões de poluentes nocivos, ampliando o problema do DE para um problema multiobjetivo de Despacho Econômico e Ambiental (DEA) (GENT e LAMONT, 1971); (JIANG *et al.*, 2014).

Esta Tese apresenta uma nova proposta de solução, que contempla o desligamento dos geradores de maior consumo de combustível, implementada por diversas técnicas determinísticas e da computação Bio-Inspirada, as quais são apropriadas para resolver o problema de otimização do Despacho Econômico e do Despacho Econômico e Ambiental em usinas Termoelétricas. Tal implementação caracteriza-se por incorporar algumas inovações, tais como, a redução dos custos de combustíveis e a redução das emissões de gases poluentes.

## **1.2 A Tese em Duas Etapas**

A presente proposta foi desenvolvida cronologicamente em duas etapas, onde a primeira apresenta os seguintes tópicos:

Caracterização das principais metodologias existentes para a otimização mono-objetivo e multiobjetivo; Aplicação dos modelos e ferramentas computacionais para a resolução dos problemas de otimização mono-objetivo e multiobjetivo;

Estudos sobre métodos determinísticos e da Computação Bio-Inspirada para a determinação de soluções ótimas, do ponto de vista técnico e econômico, aplicadas ao processo de geração de energia elétrica nas UTE's.

A segunda etapa da Tese consiste principalmente na avaliação dos resultados obtidos com a aplicação da nova proposta de solução, implementada por diversos métodos determinísticos e heurísticos.

## **1.3 Objetivos:**

### ***1.3.1. Objetivo Geral***

Implementação e análise de diversas técnicas determinísticas e da computação Bio-Inspirada apropriadas para o problema de otimização do DE e do DEA em UTE's, que contemple o desligamento dos geradores com maior custo de combustível, reduzindo o custo total de combustível para atender determinada demanda de Potência.

### **1.3.2. Objetivos Específicos**

- 1) Reduzir o custo total de combustível na produção de energia em UTE's com o desligamento dos geradores de maior consumo de energia.
- 2) Formular o problema de otimização do DE com soluções por diversos métodos Determinísticos e Heurísticos da Computação Bio-Inspirada;
- 3) Modelar o problema de otimização do DEA, para ser resolvido por meio da utilização do Algoritmo Genético de Classificação Não-dominado, NSGA-II e NSGA-III;
- 4) Propor uma nova solução para o DE e para o DEA que reduza os custos totais de combustíveis e as emissões de poluentes para a atmosfera;
- 5) Avaliar os resultados obtidos pela utilização dos diversos métodos Determinísticos e Heurísticos para o DE e para o DEA.

### **1.4 Contribuição e Relevância do Estudo**

A presente tese justifica-se pela necessidade de superar algumas limitações dos métodos desenvolvidos na literatura nacional e internacional entre as quais pode-se citar a seguir:

1. Existe uma variedade de abordagens para a solução dos problemas do DE e do DEA com a distribuição de geração de potência entre todas as unidades geradoras, mas não contemplando os benefícios do desligamento dos geradores com maior custo de combustível;
2. Muitos autores analisam apenas um cenário de operação da usina, de modo que os resultados podem não ser adequados para outros cenários com variações das características de geração (Características dos Geradores, Número de Geradores, Diferenças de Potências entre os Geradores e Tipos de Combustíveis utilizados);
3. Na literatura há poucas aplicações de otimização para casos reais;

Para superar as limitações indicadas, foi proposta uma nova solução para o problema de otimização do DE e do DEA, implementada com métodos determinísticos e heurísticos da computação Bio-inspirada, considerando os parâmetros de funcionamento dos geradores e utilizando técnicas de otimização simples e multiobjetivo que tenham as seguintes novidades ou contribuições:

- a. Uma nova solução para o problema de otimização do DE e do DEA, que garanta a eficácia econômica, considerando o sistema de tarifas elétricas do Brasil, como a redução dos

indicadores de consumo, desperdício, poluição ambiental em conformidade com as restrições adequadas para o problema segundo as normas pertinentes, e;

- b. Implementação computacional da nova solução, determinando os parâmetros de otimização utilizando para tanto diversos métodos determinísticos e heurísticos da computação Bio-Inspirada, que apresentem as seguintes características:
  - i. Tenha a possibilidade do desligamento dos geradores que apresentam maior custo relacionado com o consumo de combustível e que não são necessários no momento da otimização para o suprimento de uma determinada demanda de potência;
  - ii. Minimizem o custo computacional (tempo de processamento), devido a dinâmica de operação das UTE's;
  - iii. Minimizem convergência para os ótimos locais;
  - iv. Utilização de algoritmos que tenham a capacidade de trabalhar duas ou mais funções objetivas de forma separada.

## 1.5 Estrutura da Tese

No **capítulo 1**, são apresentados os aspectos introdutórios sobre as questões que motivaram a realização desta pesquisa, contendo a justificativa, o objetivo geral e os específicos, a relevância e a contribuição da pesquisa. Ao decorrer dos próximos capítulos, serão descritos o estado da arte sobre DE e DEA, os modelos matemáticos propostos para resolução do DE e do DEA, bem como, o detalhamento dos métodos Determinísticos e Heurísticos da Computação Bio-inspirada, aplicados nesta tese e resultados.

No **capítulo 2**, apresenta-se o Referencial Teórico sobre o Despacho Econômico e o Despacho Econômico e Ambiental. Descreve também os procedimentos metodológicos para realização do trabalho.

No **capítulo 3**, apresenta-se a fundamentação teórica de acordo com as bibliografias estudadas sobre as Usinas Térmicas, uma breve descrição dos motores de combustão interna para geração de energia, recursos energéticos, ciclo combinado, co-geração e a termoeconomia.

No **capítulo 4**, apresenta-se a fundamentação teórica sobre os métodos de Otimização Mono-objetivo e Multiobjetivo, como Gerenciar Múltiplos Objetivos, Soluções Ótimas de Pareto, Técnicas de Resolução de Problemas de Otimização Multiobjetivo.

No **capítulo 5** é apresentado os métodos determinísticos e heurísticos para otimização do DE e do DEA utilizados neste trabalho.

O **capítulo 6** é apresentado a metodologia para implementação da nova solução que contempla o desligamento dos geradores de maior consumo de combustível para o DE e o DEA, as características da UTE (estudo de Caso), os parâmetros para otimização do estudo de caso e do sistema de teste, bem como, as formulações matemáticas dos problemas do DE e do DEA.

O **capítulo 7** apresenta os resultados da aplicação da nova solução para o problema do DE e do DEA, utilizando diversos métodos Determinísticos e Heurísticos da computação Bio-inspirada.

No **capítulo 8**, as conclusões resultantes da pesquisa e as recomendações para possível continuidade e aplicações futuras.

Ainda fazem parte desta tese alguns Anexos contendo os resultados de medições em campo para cálculo dos parâmetros do estudo de caso utilizado nas simulações.

---

## CAPÍTULO II

---

### PESQUISAS RELACIONADAS COM O DE E O DEA

#### 2.1 Introdução

Neste capítulo serão apresentadas as pesquisas correlatas que apresentam o estado da arte sobre o DE e o DEA, envolvendo a otimização de problemas simples ou multiobjetivos, assim como, a metodologia aplicada à pesquisa.

##### 2.1.1. Despacho Econômico (DE)

O DE é uma das tarefas mais importantes no processo de otimização e decisão operacional, visto que o problema do despacho econômico consiste em minimizar simultaneamente o custo total, satisfazendo a demanda de potência ativa da planta produtora. O problema clássico do DE visa assim fornecer a quantidade requerida de potência ao menor custo possível (WOOD e WOLLENBERG, 1984), desde que satisfaçam as restrições operacionais e de carga. Este é um problema muito complexo de ser resolvido devido a sua grande dimensão, por ter uma função objetivo não-linear e um grande número de restrições (SAHOO *et al.*, 2015).

O custo do combustível e a eficiência do sistema de energia determinam os custos operacionais de produção da energia elétrica. Assim, o problema do DE tornou-se uma tarefa muito importante na operação e planejamento de sistemas de energia. Seu principal objetivo é otimizar a geração de potência ativa a partir das unidades disponíveis, de modo que o custo total de geração é minimizado enquanto as restrições consideradas pelo sistema são satisfeitas (ARAGÓN *et al.*, 2015).

O principal objetivo no problema do DE é determinar o valor mais econômico para o despacho de carga no sentido de minimizar o custo de geração, de tal forma que no horizonte da programação as demandas das cargas  $P_D$  possam ser atendidas satisfazendo simultaneamente, as restrições de equilíbrio de potência e os limites de geração (BARISAL e PRUSTY, 2015).

Ao longo dos últimos anos, têm sido propostos vários métodos para solucionar o problema de DE. Estes podem ser divididos em três grupos principais: Clássico, os baseados em Inteligência Artificial (AI) e Métodos Híbridos (ARAGÓN *et al.*, 2015).

As técnicas clássicas se tornam muito difíceis de aplicar quando trata-se de problemas complexos de DE, e estas são limitadas muitas vezes devido à sua falta de robustez e eficiência em inúmeras aplicações práticas. Exemplos de métodos clássicos incluem Relaxamento Lagrangiano (LR) e Programação Dinâmica (PD) (ARAGÓN *et al.*, 2015).

Mesmo quando os métodos de AI, com base em técnicas de otimização, a princípio não garantam encontrar a solução ótima global, estes normalmente produzem soluções factíveis em um tempo computacional razoavelmente aceitável, razão pela qual são amplamente utilizados para resolver o problema do DE (ARAGÓN *et al.*, 2015).

Finalmente, pode-se relatar o uso de abordagens híbridas, tais como: uma combinação de um algoritmo genético e o método Taguchi; um algoritmo híbrido por enxame de partícula (PSO) e otimização difusa adaptativa; um algoritmo híbrido de PSO baseado multi-agente, uma combinação de evolução diferencial (ED) caótica e PQ, etc.. (ARAGÓN *et al.*, 2015). Estes métodos heurísticos modernos provaram ser capazes de lidar com os problemas de otimização não linear (ARAGÓN *et al.*, 2015).

Os métodos heurísticos utilizam da força bruta (tentativa e erros) para encontrar não uma, mas um conjunto de soluções factíveis na resolução do problema do DE. Estes métodos têm-se mostrados eficientes, principalmente pela natureza complexa das equações envolvidas na otimização do DE.

Os métodos convencionais incluem metodologias de cálculos clássicos como:

- O ponto base e o método de fator de participação;
- O método de pesquisa gradiente;
- A programação linear;
- A programação não-linear, etc.

Um método de Programação Dinâmica (PD) pode resolver esses problemas em diferentes formulações. No entanto, a desvantagem da PD é a sua grande sobrecarga computacional existente quando aplicada em problemas práticos de DE (BARISAL e PRUSTY, 2015).

Tentativas de pesquisadores de todo o mundo para superar as limitações da programação matemática convencional são conduzidas pela introdução de algoritmos meta-heurísticos como algoritmo genético (AG), recozimento simulado (RS) e método hierárquico (MH), além de outros que demonstraram ser muito eficientes na resolução de problemas complexos do sistema elétrico de potência, contudo estes métodos heurísticos não garantem sempre a solução

globalmente ideal. Nos últimos anos, a evolução diferencial (ED), a otimização por colônia de formigas (CF), os sistemas imunológicos artificiais (AIS), a otimização por forrageamento bacteriano (FB), as modificações do algoritmo genético, a otimização por enxame de partículas (PSO) e a otimização baseada em biogeografia (BBO), têm sido aplicados com sucesso em problemas do DE (BARISAL e PRUSTY, 2015).

Devido a não convexidade do problema do despacho ótimo de carga, torna-se difícil garantir o ótimo global (TIAN *et al.*, 2015).

Um algoritmo evolutivo denominado de “*Cuckoo Search*” foi aplicado na resolução de problemas de Despacho Econômicos não-convexos com excelentes resultados (SAHOO *et al.*, 2015).

Uma metodologia para resolver o problema do DE, considerando incerteza da confiabilidade de geração das turbinas eólicas, comparando os resultados com o método de simulação de Monte Carlo (MCS) é apresentado em (OSÓRIO *et al.*, 2015).

A programação linear é a estratégia que apresenta o menor aumento nos custos de geração, mas a estratégia baseada nos algoritmos genéticos é a que melhor minimiza os custos de operação diárias e a demanda total de energia do sistema (NEVES e SILVA, 2015).

Em seu artigo Barisal e Prusty (2015), apresentam um algoritmo evolutivo híbrido de otimização por ervas daninhas invasoras (IWO), fundindo-o com a aprendizagem de oposição como base para resolver os problemas de DE em grande escala. A metodologia de otimização por opositoras ervas daninhas invasoras (OIWO) proposta foi desenvolvida para minimizar o custo total de geração, satisfazendo várias restrições como: limites de geração, demanda de carga com efeito de ponto de válvula, opções de multi-combustível e as perdas de transmissão. O algoritmo proposto foi testado e validado utilizando-se cinco diferentes sistemas de teste. O ponto principal da metodologia proposta é a alta precisão e melhores características de convergência, além da robustez para resolver problemas de DE (BARISAL e PRUSTY, 2015).

Um algoritmo híbrido que combina o método simplex *Firefly Algorithm* (FA) e *NDECer Mead* (NM) foi desenvolvido e implementado para a resolução do problema de Despacho de Potência Reativa Ótima (ORPD) (RAJAN e MALAKAR, 2015).

A fim de resolver efetivamente o problema do DE, considerando o efeito das válvulas das unidades geradoras, é proposto uma metodologia de solução baseada na integração do algoritmo de evolução diferencial, com uma medida de diversidade populacional e voos de passeios

aleatórios Lévy (DEL) no sentido de melhorar o ajuste das taxas de cruzamento e mutação (COELHO *et al.*, 2014).

Aragon, (2015), para resolução do problema de DE, utiliza um algoritmo baseado no modelo de Células-T, ou seja, um Sistema Imunológico Artificial. A abordagem proposta é chamada de *Immune Algorithm for Economic Dispatch Problem (IA\_EDP)* (ARAGÓN *et al.*, 2015).

### **2.1.2. Despacho Econômico e Ambiental (DEA)**

Nos últimos anos as questões ambientais e energéticas têm atraído atenções consideráveis, a maior parte da energia que está sendo utilizada ainda é a partir da combustão de combustíveis fósseis, que liberam simultaneamente quantidades significativas de calor e resíduos (DU *et al.*, 2015).

A crescente conscientização mundial sobre os efeitos da poluição ambiental causada pela produção de energia em usinas termoeletricas, vem pressionando as autoridades a criarem legislações que limitem os níveis de emissões de poluentes, o que torna uma questão crucial a ser considerada no despacho econômico.

As usinas geradoras que utilizam combustíveis fósseis como a sua principal fonte de energia geram partículas e gases poluentes como o dióxido de carbono, óxidos de enxofre e óxidos de azoto, podendo violar a regulamentação de proteção ambiental e provocando efeitos ecológicos negativos. As emissões de poluentes podem ser reduzidas através da utilização de combustíveis alternativos como biogás e biomassa, como alternativa, ao DEA (otimização simultânea de custos e emissões), proposto como uma solução viável para reduzir as emissões de poluentes com menor custo de geração (WANG e SINGH, 2007b).

O problema típico de DEA pode ser formulado como um problema de otimização multiobjetivo que envolve, simultaneamente, minimizar os custos de emissão e de combustível sob restrições de taxa de rampa convencionais, limitações de carga, etc. (GHASEMI *et al.*, 2015).

O problema geral do DEA pode ser classificado também como um problema de otimização multicritério amplamente não linear (BASU, 2008). A finalidade do DEA é estimar a parcela ótima de energia gerada por cada gerador, minimizando o custo de combustível e os níveis de emissão de poluentes simultaneamente, mantendo a demanda de carga satisfatória, além de atender as restrições operacionais (NWULU e XIA, 2015).

Um resumo dos métodos convencionais de otimização do DEA utilizando algoritmos que datam da década de 1970, têm sido explanados em (TALAQ *et al.*, 1994). No entanto, percebe-se que técnicas convencionais tornam-se muito trabalhosas quando se trata de problemas cada vez mais complexos do DEA, e são ainda mais limitadas pela sua falta de robustez e eficiência em um número de aplicações práticas.

Assim, vários métodos têm sido utilizados para representar os níveis de emissões. Por exemplo a técnica de programação por metas (fator de multiplicação) para avaliar o quanto é melhorado no custo marginal ambiental, a qual indica o impacto do aumento da porção do custo de operação do sistema sobre o meio ambiente (KERMANSHAHI *et al.*, 1990).

Em Nanda *et al.*, (1988), buscou-se encontrar as melhores soluções de compromisso entre as metas conflitantes de custo mínimo e mínima emissão por meio de procedimentos adequados multiobjetivos através do desenvolvimento de um algoritmo por programação de metas não-lineares (NLGP) (NANDA *et al.*, 1988). Este algoritmo se propõe a resolver o problema do DEA, uma vez que ele minimiza o custo de combustível durante um certo tempo pré-selecionado e complementarmente leva em conta as limitações ambientais (GRANELLI *et al.*, 1992).

Um melhoramento na rede neural de *Hopfield* para o problema do DEA é apresentada em (KING *et al.*, 1995).

Um fator de penalidade de preço para resolver o problema do DEA, combinando as funções de emissão e de custos de combustível em uma única função objetivo, é proposto por (GOPALAKRISHNAN e KRISHNAN, 2012).

Um fator de mutação do “arrefecimento” e remapeamento da população no *evolutionary-programming-based* para resolver o problema DEA de um sistema de 9 unidades geradoras pode ser encontrado em (KIT PO e YURYEVICH, 1998).

Um algoritmo genético com cruzamento aritmético foi proposta para resolver o DEA (YALCINOZ e ALTUN, 2002).

Várias estratégias para reduzir as emissões atmosféricas têm sido propostas e discutidas as quais incluem instalação de equipamentos de limpeza de poluentes, a mudança para combustíveis de baixa emissão, substituição dos combustíveis e queimadores antigos por outros mais recentes e limpos, como em (EL-KEIB *et al.*, 1994); (HESLIN e HOBBS, 1989).

As três primeiras opções exigem a instalação de novos equipamentos e/ou modificação dos existentes o que envolve consideráveis investimentos de capital e, portanto, podem ser consideradas como opções a longo prazo.

Por outro lado, a opção de otimização do DEA é uma atraente alternativa de curto prazo em que as emissões devem ser minimizadas, além do objetivo de redução do custo de combustível. Assim, o problema do DEA pode ser tratado como um problema de otimização multicritério com objetivos não comensuráveis e contraditórios.

Diferentes técnicas têm sido assim relatadas na literatura referentes ao problema do DEA. O problema tem sido reduzido, muitas vezes, a um único problema objetivo, tratando as emissões como uma restrição. Esta formulação, contudo, tem uma grave dificuldade em obter as relações de compensação entre o custo e a emissão (BRODSKY e HAHN, 1986); (GRANELLI *et al.*, 1992). Alternativamente, a minimização da emissão tem sido tratada como um outro objetivo diferente da redução do custo. Os procedimentos de estudo da otimização de programação linear com base no qual os objetivos são considerados um a um (FARAG *et al.*, 1995). No entanto, muitas suposições matemáticas têm que ser consideradas para simplificar o problema. Além disso, esta abordagem não dá qualquer informação sobre a compensação dos envolvidos.

Em outra direção, o problema multiobjetivo pode ser convertido a um único problema objetivo por combinação linear dos diferentes objetivos, proposto como uma soma ponderada como em (ZAHAVI e EISENBERG, 1975); (CHANG *et al.*, 1995).

Um aspecto importante do método da soma ponderada é que um conjunto de soluções não-inferiores (ou soluções ótimas de Pareto) podem ser obtidas através da variação dos pesos. Infelizmente, esta técnica requer várias execuções, tantas vezes quanto sejam o número de soluções ótimas de Pareto desejadas. Além disso, este método não pode ser utilizado em problemas não convexos com uma solução ótima da frente Pareto. Para evitar essa dificuldade, a técnica de  $\epsilon$ -restrição, otimiza o mais preferido objetivo e considera os outros objetivos como restrições delimitadas por alguns níveis de permissões (YOKOYAMA *et al.*, 1988); (YING-TUNG *et al.*, 1994). As fraquezas mais óbvias desta abordagem são o custo computacional e a tendência para encontrar soluções fracamente não dominadas.

Os estudos sobre algoritmos evolucionários têm mostrado que estes métodos podem ser utilizados de forma eficiente para eliminar a maioria das dificuldades dos métodos clássicos (FONSECA e FLEMING, 1995). Desde que utilizem uma grande população de soluções na sua

pesquisa, múltiplas soluções ótimas de Pareto podem, em princípio, ser encontrado em uma única execução do algoritmo (COELLO COELLO, 1999).

Para resolver o problema do DEA-Dinâmico, propõem na literatura três versões do algoritmo de busca harmônica diferencial (DHS), são eles: o algoritmo de busca harmônica diferencial caótico (CDHS), o algoritmo de busca harmônica diferencial auto-adaptativo (SADHS) e o algoritmo de busca harmônica diferencial auto-adaptativo caótico (CSADHS) (ARUL *et al.*, 2015).

O problema típico do DEA pode ser formulado como um modelo de otimização multicritérios, com pelo menos dois objetivos conflitantes, ou seja, o custo de combustível e as emissões de poluentes. Este problema pode ser formulado como se segue:

**Objetivo 1: Minimização do custo de combustível**

As curvas de custos dos geradores são representadas por funções quadráticas  $F(P_i)$ . O problema de minimizar o custo (\$/h) total de combustível pode ser representado da seguinte forma, Eq. (2.30) (SAHOO *et al.*, 2015):

$$\text{Minimize } F = \sum_{i=1}^n f_i(P_i) \tag{2.30}$$

$$f_i(P_i) = a_i + b_i P_i + c_i P_i^2 \quad (\$/h) \tag{2.31}$$

onde  $a_i$ ,  $b_i$  e  $c_i$  são os coeficientes de custo do  $i_{th}$  gerador e  $P_i$  é a potência real do  $i_{th}$  gerador.

**Objetivo 2: Minimização das emissões de poluentes**

As emissões mais importantes consideradas na indústria de geração de energia, devido aos seus efeitos sobre o meio ambiente são: o dióxido de enxofre (SO<sub>2</sub>) e óxido de nitrogênio (NO<sub>x</sub>). Estas emissões podem ser modeladas através de funções que associam as emissões com a produção de energia para cada unidade. Emissões de dióxido de enxofre são dependentes de consumo de combustível e eles tomam a mesma forma que as funções de custo dos combustíveis utilizados no despacho econômico. Emissões NO<sub>x</sub> são mais difíceis de modelar uma vez que provêm de diferentes fontes e sua produção está associada a vários fatores, como temperatura da caldeira e do conteúdo do ar (WANG e SINGH, 2007b).

O total ton/h de emissões de poluentes  $E(P_i)$  da atmosfera tal como dióxido de enxofre, SO<sub>2</sub> e oxido de nitrogênio NO<sub>x</sub>, causado pela queima de combustível nas unidades geradoras, pode ser expresso como (PURKAYASTHA e SINHA, 2010):

$$\text{Minimize } E = \sum_{i=1}^n f_i(P_i) \tag{2.32}$$

$$f_i(P_i) = \alpha_i + \beta_i P_i + \gamma_i P_i^3 \quad (\text{ton/h}) \quad (2.33)$$

onde  $\alpha_i$ ,  $\beta_i$  e  $\gamma_i$  são os coeficientes característicos das emissões do  $i_{th}$  gerador.

Como restrições para a solução do problema, consideram-se as mesmas restrições do DE.

Em resumo, o objetivo da otimização do DEA é minimizar  $F(P_i)$  e  $E(P_i)$  simultaneamente, sujeito às restrições do sistema. É revisado e ampliado o algoritmo básico por enxame de partículas para abordar o caso multiobjetivo. O algoritmo proposto revela-se eficaz, pois as soluções obtidas têm algumas características superiores em comparação com outras abordagens, incluindo agregação ponderada (WA) e (MOEA). Além disso, a abordagem proposta aborda os problemas de otimização multiobjetivo de forma mais eficiente, uma vez que é capaz de obter um conjunto gerenciável de soluções não dominadas em uma única solução (WANG e SINGH, 2007b). Com o aumento do interesse na poluição ambiental, o DE tradicional, que ignora as emissões de poluentes dos combustíveis fósseis utilizados pelas usinas térmicas, já não satisfaz as necessidades. Portanto, o DEA, como uma alternativa, tornou-se mais atraente, porque considera as emissões de poluentes, bem como vantagens econômicas (AYDIN *et al.*, 2014). A solução do problema DEA compreende alguns critérios de avaliação importantes, como o custo de combustível, impacto ambiental e perda de potência ativa total. Então, o problema DEA é um problema matemático multiobjetivo em que objetivos conflitantes são otimizados simultaneamente (AYDIN *et al.*, 2014).

Na literatura em geral, o problema de DEA pode ser resolvido por três abordagens, como descrito a seguir:

Na primeira abordagem, a quantidade de emissão é calculada como uma constante dentro dos limites permitidos. No entanto, é muito difícil formular as relações de *tradeoff* entre o custo de combustível e de emissões. Como um exemplo desta abordagem, o problema de DEA foi resolvido com Método de *Davidon-Fletcher-Powell* (DFPM) *apud* (AYDIN *et al.*, 2014), com a quantidade de emissão tomada como uma constante nos limites permitidos.

Na segunda abordagem, a diminuição das emissões é considerada para além da minimização de custos. Neste caso, o problema de otimização para múltiplos objetivos na solução do problema DEA é convertido num problema de otimização de objetivo único que considera apenas um objetivo de cada vez ou a combinação linear dos dois objetivos. Na literatura, este tipo de problema de otimização foi resolvido por meio de algoritmos, como algoritmo genético, algoritmo de ED, algoritmo de otimização por PSO, algoritmo de colônia

de ABC, algoritmo rápido sucessiva de programação linear (SLP), algoritmos de computação evolutiva (PE), algoritmo híbrido de forrageamento bacteriana *NDECer-Mead* (MF-NM), algoritmo de otimização baseado em biogeografia com evolução diferencial híbrida (DE/BBO), solução analítica (AS), método de *Newton-Raphson* (NRM), algoritmo de busca baseado em oposição gravitacional (OGSA) e método de gradiente de primeira ordem (FOGM) (AYDIN *et al.*, 2014).

Quanto à terceira abordagem, simultaneamente objetivos contraditórios são avaliados em conjunto na solução do problema de DEA. Tanto o custo de combustível e as emissões são minimizados juntos. Na literatura, como um exemplo para tal abordagem, o problema de otimização foi resolvido com métodos tais como Programação Matemática Multiobjetivo (MMP), formulação baseada na abordagem de rápida  $\epsilon$ -restrição (CE), algoritmos como a classificação não-dominado forrageamento bacteriana (NSBF) e forrageamento bacteriana baseada em domínio *Fuzzy* (FSBF) (AYDIN *et al.*, 2014).

Uma combinação do problema de DE e o de emissão de NO<sub>x</sub> em um problema de otimização mono-objetivo, pode ser resolvido pelo método da soma ponderada (WSM) (AYDIN *et al.*, 2014).

A transformação do problema de otimização multiobjetivo para o problema de um único objetivo, usando as transformações adequadas é chamado escalonamento. WSM é um dos mais antigos e mais comuns métodos de escalonamento. O método é principalmente apropriado para problemas convexos. Mais do que uma função objetivo são escalonadas com este método, multiplicando estas com pesos positivos a elas adicionadas. Desta forma, o problema de otimização multiobjetivo é transformado em problema de otimização mono-objetivo. Depois disso, ambos os algoritmos, colônia de abelhas artificial e colônia de abelhas artificial incremental, de tamanho populacional dinâmica, são utilizadas para a solução do problema convertido (AYDIN *et al.*, 2014).

## **2.2 Regulamentação Ambiental**

O Conselho Nacional do Meio Ambiente - CONAMA, no uso das competências que lhe são conferidas pela Lei no 6.938, de 31 de agosto de 1981, regulamentada pelo Decreto no 99.274, de 6 de julho de 1990, e tendo em vista o disposto em seu Regimento Interno e Considerando o disposto na Resolução CONAMA no 5, de 15 de junho de 1989, que estabelece o Programa Nacional de Controle da Poluição do Ar – PRONAR (CONAMA, 2006).

De acordo com os limites de emissão de poluentes atmosféricos, provenientes de Turbinas a Gás para geração de energia elétrica, definidos pelo PRONAR estabelece (CONAMA, 2006):

1. Ficam aqui definidos os limites de emissão para poluentes atmosféricos gerados por turbinas destinadas à geração de energia elétrica, movidas a gás natural ou combustíveis líquidos, em ciclo simples ou ciclo combinado, sem queima suplementar, com potência elétrica acima de 100 MW. 1.1. Quando a somatória total de geração elétrica por empreendimento for superior a 100 MW, os limites aqui estabelecidos também são requeridos para cada turbina individualmente, independentemente de sua capacidade de geração.
2. Para aplicação deste Anexo deve ser considerada a seguinte definição do termo: a) turbinas a gás: equipamento que converte parte da energia contida no combustível em energia mecânica, por meio da rotação axial de um eixo, que aciona um gerador elétrico.
3. Ficam estabelecidos os seguintes limites de emissão para poluentes atmosféricos gerados em processos de geração de energia elétrica por turbinas a gás, Tabela 2.1.

Tabela 2.1 - Classificação dos combustíveis segundo seu estado físico.

Turbina por tipo de combustível	NO <sub>x</sub> <sup>(1)</sup> (como NO <sub>2</sub> )	CO <sup>(1)</sup>	S <sub>ox</sub> <sup>(1)</sup> (como SO <sub>2</sub> )	MP <sup>(1)</sup>
Gás natural	50	65	N.A.	N.A.
Combustível líquido	135	N.A.	200	50

Fonte: (CONAMA, 2006).

<sup>(1)</sup> os resultados devem ser expressos na unidade de concentração mg/Nm<sup>3</sup>, em base seca e 3% de excesso de oxigênio.

N.A. – Não aplicável.

3.1. Os limites estabelecidos para turbinas movidas a combustível líquido também se aplicam a turbinas movidas a gás natural, quando estas utilizarem combustível líquido em situações emergenciais ou em caso de desabastecimento.

3.2. Em teste de desempenho de novos equipamentos, o atendimento aos limites estabelecidos deverá ser verificado nas condições de plena carga.

3.3. Na avaliação periódica, o atendimento aos limites estabelecidos poderá ser verificado em condições típicas de operação, a critério do órgão ambiental licenciador.

4. As atividades ou fontes emissoras de poluentes deverão, quando da realização da amostragem, contar com a estrutura necessária e/ou determinação direta de poluentes em

dutos e chaminés, de acordo com metodologia normatizada ou equivalente aceita pelo órgão ambiental licenciador.

5. Na ocorrência de duas ou mais fontes cujo lançamento final seja efetuado em duto ou chaminé comum, as medições devem ser feitas individualmente.

5.1. Quando houver impossibilidade de realização de medições individuais, de acordo com a metodologia normatizada ou equivalente aceita pelo órgão ambiental licenciador, estas poderão ser efetuadas no duto ou chaminé comum e os limites de emissão devem ser ponderados individualmente com as respectivas potências térmicas nominais das fontes em questão.

6. O lançamento de efluentes gasosos na atmosfera deverá ser realizado através de dutos ou chaminés, cujo projeto deve levar em consideração as edificações do entorno à fonte poluidora e os padrões de qualidade do ar estabelecidos.

7. Em função das características locais da área de influência da fonte poluidora sobre a qualidade do ar, o órgão ambiental licenciador poderá estabelecer limites de emissão mais restritivos, inclusive considerando a alternativa de utilização de combustíveis com menor potencial poluidor.

---

## CAPÍTULO III

---

### USINAS TÉRMICAS

#### 3.1 Introdução

Neste capítulo serão apresentadas as características do motor a combustão interna (MCI) o qual representa a tecnologia mais comumente usada entre máquinas térmicas, devido à sua simplicidade e robustez; Recursos Energéticos; Cogeração e Termoeconomia.

#### 3.2 O motor diesel

O motor diesel continua a ser a unidade de queima mais eficiente do combustível líquido ainda concebido e têm demonstrado a sua confiabilidade para as unidades de transporte em massa e de geração de energia. Assim, o funcionamento adequado e eficiente de um motor diesel é um objetivo importante, especialmente para aplicações marítimas e industriais (ou seja, a geração de energia) (HOUNTALAS *et al.*, 2014).

O fator mais significativo para que o uso dos motores a diesel ultrapassasse o uso dos motores a gasolina, é o seu baixo consumo de combustível associado com a alta potência e torque. Apesar do fato de que os motores diesel atendem a crescente demanda de energia diária e parecem ser uma ferramenta promissora para atender o consumo eficiente de combustível, o ciclo do diesel convencional apresenta altos níveis de  $NO_x$ , emissões de fuligem em cargas elevadas do motor, baixa eficiência térmica e níveis elevados das emissões de Hidro Carbono não Queimado (*Unburned Hydro Carbon - UHC*) em baixas condições de carga do motor (MAGHBOULI *et al.*, 2013).

Adicionalmente, deve-se considerar que a modularidade dos equipamentos de uma Usina Termelétrica (UTE) operando com ciclo diesel permite um curto espaço de tempo de montagem e um mínimo espaço para construção, além da excelente flexibilização de carga. São inúmeras as aplicações de grupos motogeradores, podendo ir desde da produção de poucos kW até centenas de MW, para fins de geração isolada ou interligada, propulsão ou como geradores de suporte a falta de energia.

#### 3.3 Motores de Combustão Interna

Poucas invenções tiveram um impacto tão grande na sociedade, na economia e no meio ambiente como o alternativo MCI, sendo esses Motores comumente usados para a propulsão de

sistemas móveis. A Combustão interna é vantajosa em cenários móveis, uma vez que pode fornecer uma alta relação entre peso e potência (DELIGIANNIS e MANESIS, 2006).

Estes motores são utilizados também em aplicações industriais, tais como na produção de petróleo e gás, compressão, exploração de pedreiras, reciclagem, e geração de energia elétrica. Sua ampla utilização deriva do fato de que eles podem funcionar com uma variedade de combustíveis em uma ampla gama de velocidades e com cargas variáveis (DELIGIANNIS e MANESIS, 2006).

### **3.3.1 Tipos Básicos de Motores Alternativos**

Os Motores de Ignição por Centelha são motores no qual a ignição é ordinariamente provocada por uma centelha elétrica.

Os Motores de Ignição por Compressão são motores no qual a ignição tem lugar ordinariamente sem a necessidade de uma centelha elétrica ou de uma superfície aquecida por uma fonte externa de energia. Esses motores receberam nos últimos anos muita atenção devido às suas baixas emissões e alta eficiência (NIKHIL *et al.*, 2010).

Os dois tipos principais de motores de combustão interno são: Motores de *Spark Ignition* (SI), onde o combustível é inflamado por uma faísca e os motores de ignição por compressão (CI), em que o aumento de temperatura e pressão durante a compressão é suficiente para provocar a ignição espontânea do combustível (DELIGIANNIS e MANESIS, 2006).

O motor de SI é também referido como a gasolina, ou a gás a partir de seus combustíveis típicos, dentro do ciclo de Otto. O motor CI também é referido como o diesel ou o motor de óleo (DELIGIANNIS e MANESIS, 2006).

### **3.3.2 Processo de Geração de Energia com Motores de Combustão**

O calor e energia de sistemas combinados (CHP) permite uma das melhores maneiras de consumir combustíveis fósseis de forma eficiente. Estes sistemas emitem menos poluição em comparação com uma produção separada da mesma quantidade de potência e calor, e, devido à sua economia significativa e os benefícios ambientais, há uma tendência crescente para utilização destes na indústria de geração de energia (ABUSOGLU e KANOGLU, 2009); (MEYBODI e BEHNIA, 2011).

Os MCI's são amplamente utilizados como o principal motor de sistemas de cogeração. O combustível preferido de motores de ignição por faísca (SI) para geração de energia é o gás natural. Motores IC, que são mais comumente motores a diesel, operam principalmente com

este combustível. Alternativamente, tanto os motores a gás quanto os motores a diesel podem ser configurados para funcionar com outros combustíveis (MEYBODI e BEHNIA, 2011).

Sistemas de cogeração com base nos motores de combustão interna têm sido estudados nos últimos anos. Como exemplo, pode-se destacar o modelo desenvolvido para conceber e avaliar sistemas de cogeração para uso residencial (MEYBODI e BEHNIA, 2011).

### 3.4 Recursos Energéticos

Na geração de energia termelétrica, o termo fonte de insumo energético está diretamente associado ao termo combustível, o qual se define, como uma substância que ao se combinar quimicamente com um composto oxidante gera uma reação exotérmica liberando elevadas quantidades de calor (LORA e NASCIMENTO, 2004).

Uma classificação dos combustíveis, conforme o seu estado físico, é apresentada na Tabela 3.1 a seguir:

Tabela 3.1 - Classificação dos combustíveis segundo seu estado físico

Estado Físico	Combustível
Sólido	Carvão mineral
	Carvão vegetal
	Xisto
	Turfa
	Lenha
	Resíduos Agroindustriais
Líquido	Gasolina
	Querosene
	Diesel
	Óleos combustíveis
Gasoso	Gás Natural
	GLP
	Biogás

Fonte: (LORA e NASCIMENTO, 2004).

Os recursos energéticos disponíveis para a geração de energia elétrica, a partir dos combustíveis fósseis, estão diretamente relacionados com esta classificação, podendo-se neste sentido trabalhar com sistemas de geração a gás, vapor, ciclo combinado, etc.

#### 3.4.1 Turbina a gás

O principal dispositivo das UTE's de ciclo combinado é a turbina a gás, uma tecnologia proveniente do desenvolvimento das turbinas de propulsão a jato, desenvolvido para as aeronaves militares e civis, onde o combustível é o querosene.

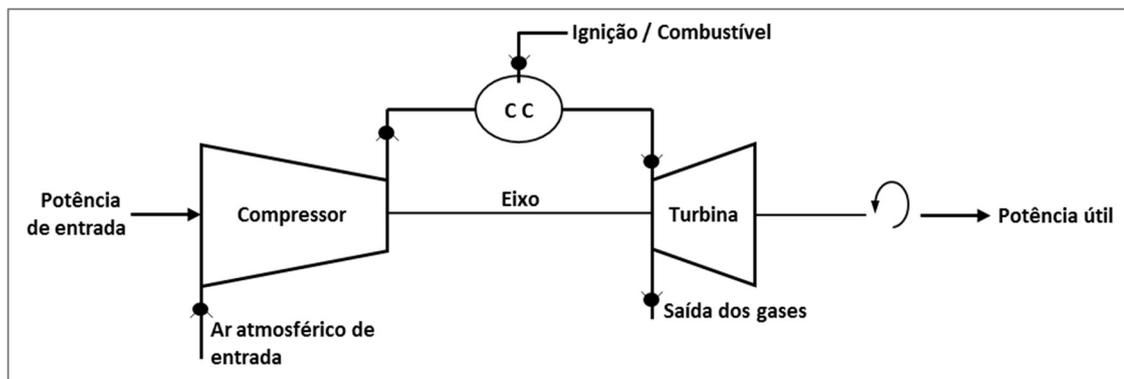
Nas UTE's, o combustível mais utilizado é o gás natural, embora quase sempre exista a possibilidade de operar com um segundo combustível, como o óleo diesel, por exemplo, para evitar interrupções no caso de problemas no suprimento do gás.

Pode-se distinguir três componentes principais em uma turbina a gás:

- O compressor;
- A câmara de combustão (CC);
- A turbina propriamente dita.

A figura 3.1 ilustra os três principais componentes de uma turbina a gás.

Figura 3.1 - Turbina a gás principais componentes.



Fonte: (LORA e NASCIMENTO, 2004).

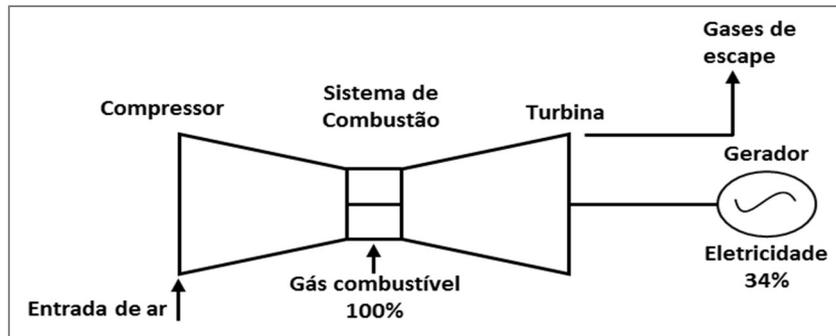
A turbina é uma fonte de acionamento mecânico tanto do compressor como do gerador elétrico. Como mencionado, uma turbina a gás consiste basicamente de um compressor com sua respectiva seção de entrada de ar, um sistema de combustão e uma turbina de expansão associada à seção dos gases de escape.

A turbina pode estar operando de forma isolada (ciclo simples), como nas aeronaves, sua eficiência térmica é baixa, cerca de 64% do calor gerado pela queima do combustível é perdido nos gases de exaustão.

Poderia se elevar esta eficiência térmica através da elevação de temperaturas e pressões de entrada, porém isto elevaria demasiadamente o custo de construção e manutenção dos equipamentos do processo, inviabilizando o projeto.

Na figura 3.2, é apresentado um arranjo característico de uma turbina a gás em ciclo simples, expondo a distribuição de energia de entrada e saída.

Figura 3.2 - Turbina a gás com ciclo simples.



Fonte: (LORA e NASCIMENTO, 2004).

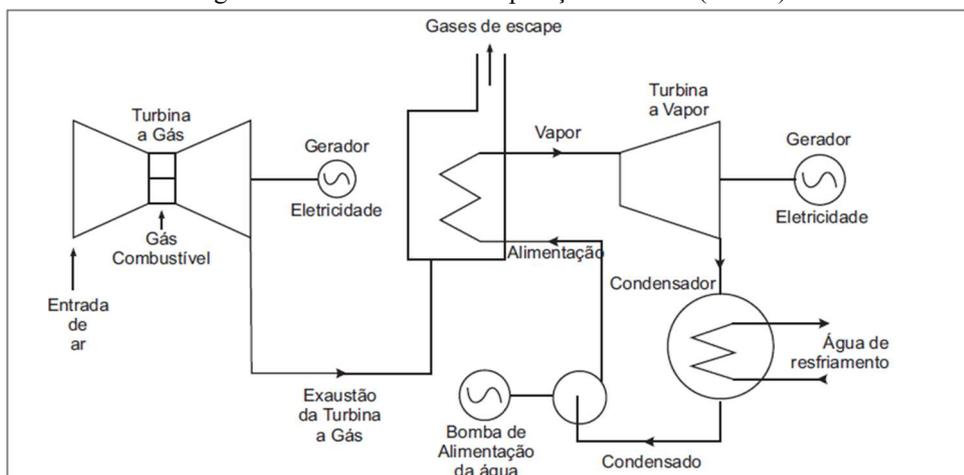
As turbinas a gás são ótimas para a produção de energia elétrica em ciclo simples ou cogeração, principalmente ao ser utilizado o gás natural ao invés de combustíveis líquidos.

Quando se utiliza o gás natural como combustível, as emissões de poluentes, tais como  $\text{NO}_x$ ,  $\text{SO}_2$  e  $\text{CO}$ , são muito baixas. Quanto aos combustíveis líquidos, os mesmos são conhecidos por acarretarem problemas de manutenção devido à presença de elementos químicos e sais que aceleram a corrosão dos componentes que se encontram na câmara de combustão e no caminho dos gases quentes.

### 3.4.2 Caldeira de Recuperação de Calor (HRSG)

As usinas de ciclo combinado têm como um dos seus principais elementos um gerador de vapor capaz de recuperar parte do calor dos gases de exaustão das turbinas a gás. Este gerador de vapor, ou caldeira, é normalmente conhecido pela sigla de origem inglesa HRSG, que significa Caldeira de Recuperação de Calor. Usando um HRSG, a eficiência térmica eleva-se substancialmente, como se vê na figura 3.3, pois o vapor assim produzido aciona uma turbina, sem necessidade de queima de combustível adicional.

Figura 3.3 - Caldeira de Recuperação de Calor (HRSG).



Fonte: (LORA e NASCIMENTO, 2004).

### **3.5 Cogeração**

Sistemas de cogeração são empregados nas situações em que são necessárias eletricidade e calor. Estes sistemas utilizam o calor residual produzido durante a geração de eletricidade e permitem um consumo de combustível mais eficiente. Assim, um método mais econômico é obtido em comparação com os sistemas em que a eletricidade e calor são produzidos separadamente (ABUSOGLU e KANOGLU, 2009). Desde que os CHP envolvam a produção tanto de energia térmica, geralmente sob a forma de vapor ou de água quente, quanto a eletricidade, a eficiência de produção de energia pode ser aumentada relativamente aos níveis atuais, que variam de 35% a 55% nas centrais de energia convencionais para mais de 90% nos sistemas de cogeração (ABUSOGLU e KANOGLU, 2009). Cogeração com motor de combustão interna, consiste no próprio motor ligado a um gerador elétrico e também aos permutadores de calor em camisas de água e de gás de escape para a recuperação de calor. Plantas de calor e energia combinados com motores de combustão interna são amplamente utilizados por causa da sua relação custo eficácia, mobilidade e alta eficiência (ABUSOGLU e KANOGLU, 2009). Os CHP's permitem uma das melhores maneiras de consumir combustíveis fósseis de forma eficiente. Estes sistemas emitem menos poluição em comparação com a produção separada de a mesma quantidade de eletricidade e calor. Os sistemas de cogeração estão começando a atrair alguma atenção devido aos seus benefícios econômicos e ambientais significativos, há uma tendência crescente para a utilização destes sistemas na indústria de geração de energia (MEYBODI e BEHNIA, 2011); (MUCCILLO e GIMELLI, 2014).

### **3.6 Termoeconomia**

A análise termoeconômica, possui grande relevância acadêmica, permitindo a avaliação simultânea de aspectos tecnológicos, termodinâmicos, econômicos e financeiros, portanto, fornece resultados mais sólidos na tomada de decisões (DINCER e CENGEL, 2001).

A aplicação da termoeconomia para instalações industriais consiste da determinação do produto (efeito útil) e seu custo em combustível (conjunto de bens de energia ou materiais consumidos) e gastos (investimentos de capital, operação, manutenção, etc.), tudo avaliado em termos de seu conteúdo energético. A otimização energético-econômica implica na obtenção do mínimo custo total unitário relativo ao produto, ou seja, consiste na implementação gradual de um projeto de desenvolvimento, de acordo com um plano que leve a um mínimo custo total unitário do produto. Um importante problema a ser resolvido com os meios proporcionados pela termoeconomia se refere a decisão macro-econômica sobre o destino mais vantajoso para

o investimento dos recursos financeiros disponíveis ao desenvolvimento da indústria de energia (DINCER e CENGEL, 2001); (WALL e GONG, 2001); (ABUSOGLU e KANOGLU, 2009).

Vantagens do método de análise termoeconômico:

- A termoeconomia permite, diferentemente de outros métodos, otimizar a utilização dos recursos técnicos, energéticos e financeiros; dando as empresas maior competitividade tendo em conta a escassez de recursos e a necessidade de produzir mais com menos e com o menor custo possível.
- A termoeconomia permite calcular o custo energético real em cada um dos fluxos envolvidos no processo, e somente o conhecimento dos verdadeiros custos permitirá racionalizar os recursos finitos.
- A termoeconomia, baseando-se em uma propriedade, como a exergia, é capaz de classificar de acordo com sua essência (sua qualidade) a todos os fluidos físicos. Este fato une todos os fluxos em um único tipo e pode assim ser tratado, não só por seu conteúdo, mas também pela sua qualidade.
- A termoeconomia permite a quantificação e a identificação das causas das irreversibilidades nos sistemas concebidos pelo homem. Ao quantificá-las em unidades de energia, a termoeconomia consegue fazer a mudança de qualidades em algo mensurável, matematicamente tratável e com a possibilidade de ser submetido a discussão científica.

### **3.7 Conclusões do capítulo**

Neste capítulo foram apresentadas as características do MCI, a tecnologia mais comumente usada entre máquinas térmicas. São sistemas que podem ser montados dentro de um curto espaço de tempo, utilizando uma área mínima para construção, além da excelente flexibilidade para o trabalho com carregamento variável. Além disso, esses sistemas permitem a geração de energia termoelétrica associada com seus recursos energéticos; além da Cogeração para o reaproveitamento do calor

Foram apresentados neste capítulo ainda aspectos relacionados com a Termoeconomia, para avaliação simultânea de aspectos tecnológicos, termodinâmicos, econômicos e financeiros.

---

## CAPÍTULO IV

---

### TÉCNICAS DE OTIMIZAÇÃO

#### 4.1 Introdução

Neste capítulo serão abordados os principais conceitos sobre otimização multiobjetivo, descrevendo e exemplificando as técnicas empregadas em diversos tipos de problemas atuais, modelando a solução multiobjetivo de modo a obter um grupo de soluções ótimas que auxiliem a tomada de decisões, minimizem situações conflitantes e maximizem a sua eficiência.

##### 4.1.1. Otimização multiobjetivo

As aplicações estudadas na prática normalmente envolvem a otimização simultânea de múltiplos objetivos, que são geralmente não comensuráveis e conflitantes entre si. Os propósitos dos problemas multiobjetivos no âmbito da programação matemática se baseiam em otimizar diferentes funções objetivo, sujeitas a um conjunto de restrições do sistema (VAHIDINASAB e JADID, 2008).

Otimização multiobjetivo, também chamada de otimização multicritérios ou otimização vetorial, tem sido definida como: encontrar um vetor com variáveis de decisões que satisfaçam as restrições atribuindo valores factíveis para todas as funções objetivo (ATASHKARI *et al.*, 2007). Na ausência de qualquer informação preferencial, um conjunto não-dominado de soluções é obtida, ao invés de uma única solução ótima. Estas soluções ótimas são denominadas como soluções ótimas de Pareto (PANIGRAHI *et al.*, 2010) (ALBERTO *et al.*, 2014).

Neste contexto, a Dominância de Pareto é um vetor  $U = [u_1, u_2, \dots, u_k] \in R^k$  o qual é dominante a um vetor  $V = [v_1, v_2, \dots, v_k] \in R^k$  (Representado por  $U < V$ ) se e somente se  $\forall i \in \{1, 2, \dots, k\}, u_i \leq v_i \exists j \in \{1, 2, \dots, k\}: u_j < v_j$ . Em outras palavras, existe pelo menos um  $u_j$  que é menor do que  $v_j$  enquanto o restante dos  $u$ 's são menores ou iguais aos seus correspondente  $v$ 's (ATASHKARI *et al.*, 2007).

Muitos problemas de otimização envolvem múltiplos objetivos. Um problema de otimização multiobjetivo (MOP) pode ser matematicamente formulado como a seguir, (ZHOUA *et al.*, 2011):

$$\begin{aligned} \text{Minimize } F_{(x)} &= (f_1(x), \dots, f_m(x))^T \\ \text{e} \quad & x \in \Omega, \end{aligned} \tag{4.1}$$

onde  $\Omega$  é o espaço de decisão e  $x \in \Omega$  é um vetor de decisão.  $F(x)$  consiste de  $m$  funções objetivos  $f_i: \Omega \rightarrow R, i = 1, \dots, m$ , onde  $R^m$  é o espaço objetivo.

Os objetivos na Eq. (2.1), no caso desta tese, existem conflito entre os objetivos minimizados. A melhoria de um objetivo pode levar à deterioração do outro. Assim, uma solução única, que possa otimizar todos os objetivos ao mesmo tempo não existe, mas sim um conjunto de soluções de *tradeoff*, chamadas de soluções Ótimas de Pareto, que são importantes para a tomada de decisões (ZHOUA *et al.*, 2011).

Matematicamente, o problema geral de otimização multiobjetivo é encontrar o vetor  $\vec{x}$  que satisfaça as  $m$  restrições de desigualdade e  $p$  restrições de igualdade e que otimize o vetor de funções objetivo Eq. (4.2) (VAHIDINASAB e JADID, 2008).

$$\begin{aligned} & \text{Minimizar } \vec{F}(\vec{x}) \\ & \text{com } \vec{h}(\vec{x}) = \vec{0} \\ & \text{e } \vec{g}(\vec{x}) \leq \vec{0}, \end{aligned} \tag{4.2}$$

onde  $\vec{x} \in R^n, \vec{F}(\vec{x}) \in R^m, \vec{h}(\vec{x}) \in R^p$  e  $\vec{g}(\vec{x}) \in R^q$ .

As restrições de igualdade e de desigualdade definem uma subárea limitada de procura da solução ideal, que é chamada de área viável. Qualquer ponto nesta área define assim uma solução viável.

Devido à natureza dos objetivos conflitantes, uma solução ideal que otimize simultaneamente todos os critérios geralmente não é atingível. Portanto, muitas vezes é preferível dar um conjunto de soluções, ao invés de uma única solução para este tipo de problema de otimização. Estas soluções são chamadas soluções eficientes ou Ótimos de Pareto, que são as soluções que não podem ser melhoradas em uma função objetivo, sem deteriorar o desempenho em pelo menos um dos outros objetivos (VAHIDINASAB e JADID, 2008).

Um problema geral de otimização multiobjetivo pode ser expresso pela Eq. (4.3). Supõe-se que existem  $k$  funções objetivas que irão ser minimizados.

$$\text{Min}F(X) = (f_1(X), f_2(X), \dots, f_k(X))^T \quad X \in S \tag{4.3}$$

A forma geral do problema  $F$ , é não linear e multimodal, e  $S$  pode ser definido por restrições não-lineares contendo as variáveis de decisão tanto contínuas como discretas:

Definição 1 (Dominado).

Vetor  $y$  será dominado pelo vetor  $w$ , se:

$$\forall i \in (1, 2, \dots, k): f_i(w) \leq f_i(y) \text{ e } \exists j \in (1, 2, \dots, k): f_j(w) < f_j(y) \quad (4.4)$$

Definição 2 (Ótimo de Pareto).

Vetor  $X \in S$  é uma solução ótima de Pareto se, e apenas se não houver nenhum vetor  $Y \in S$ , em que:

$$F(Y) = (f_1(Y), f_2(Y), \dots, f_k(Y)) \text{ domina } F(X) = (f_1(X), f_2(X), \dots, f_k(X)) \quad (4.5)$$

O espaço  $\rho$  em  $R^k$  é conhecido como a fronteira ótima de Pareto, sendo formado pelos vetores objetivos de soluções ótimas de Pareto. Obviamente qualquer solução, se possível definir, deve pertencer ao ótimo de Pareto. Outras terminologias tais como soluções não-dominadas ou eficientes também são utilizados na literatura, em vez de soluções ótimas de Pareto (GITIZADEH e AGHAEI, 2013).

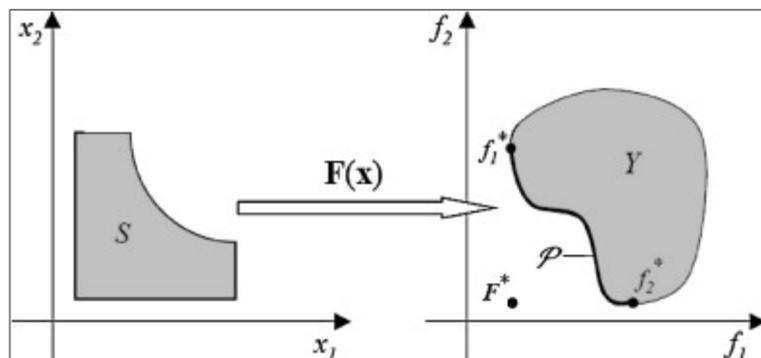
Um ponto  $X^* \in \Omega$  (Onde  $\Omega$  é uma região viável em  $R^n$ ), é dito ser ótimo de Pareto no que diz respeito a todos os  $X \in \Omega$  se e somente se  $F(X^*) < F(X)$ . Alternativamente, pode ser facilmente atualizado como a Eq. (4.6):

$$\forall i \in \{1, 2, \dots, k\},$$

$$\forall X \in \Omega - \{X^*\} f_i(X^*) \leq f_i(X) \wedge \exists j \in \{1, 2, \dots, k\}: f_j(X^*) < f_j(X) \quad (4.6)$$

Em outras palavras, a solução  $X^*$  é declarada como um Ótimo de Pareto (mínimo), se não poder ser encontrada outra solução para dominar  $X^*$  utilizando a definição de dominância de Pareto (ATASHKARI *et al.*, 2007). Uma representação gráfica deste conceito é ilustrada na figura 4.1 a seguir.

Figura 4.1- Parâmetro/solução e superfície de Pareto, para um problema bidimensional.



Fonte: (GITIZADEH e AGHAEI, 2013).

Na figura 4.1,  $f_1^*$  e  $f_2^*$  serão utilizados para designar os mínimos individuais correspondentes de cada função objetivo, e a solução é definida como utópico  $F^* = (f_1^*, f_2^*)^T$ . Note-se que, para o caso de  $k$  funções objetivo  $f_1^*, f_2^*, \dots, f_k^*$  serão utilizados para designar os mínimos individuais de cada função objetivo e a solução é utópico  $F^* = (f_1^*, f_2^*, \dots, f_k^*)^T$ . Como  $F^*$  minimiza simultaneamente todos os objetivos, esta é uma solução ideal que raramente é viável (GITIZADEH e AGHAEI, 2013).

Para um dado MOP a frente de Pareto  $PT^*$  é um conjunto de vetores de funções objetivo que são obtidos usando os vetores de variáveis de decisão na série de Pareto  $P^*$ , que corresponde a  $PT^* = F(X) = (f_1(X), f_2(X), \dots, f_k(X))$ :  $X \in P^*$ . Em outras palavras, a frente de Pareto é um conjunto de vetores de funções objetivo mapeados a partir de  $P^*$  (ATASHKARI *et al.*, 2007).

## 4.2 Como Gerenciar Múltiplos Objetivos

Quando se está configurando os geradores para o atendimento de uma certa demanda de potência  $P_D$ , em nível gerencial, diversas decisões devem ser levadas em consideração como por exemplo: custo total de combustível, eficiência energética das máquinas, capacidade de geração mínima e máxima da usina, instalação de equipamentos de suporte, dentre outras. Estas decisões não podem ser formuladas ou estipuladas por uma única equação matemática sujeita a várias restrições.

Isto se deve ao fato de que a otimização busca encontrar um mínimo ou um máximo global e em todos os casos nos quais os objetivos forem divergentes do objetivo da otimização, definir uma única função torna-se quase impossível, dada a complexidade e o número de variáveis do problema. Um exemplo clássico: Deseja-se maximizar a potência e em contra partida deseja-se minimizar os custos de combustível definindo-se o menor custo total.

Determinadas técnicas tratam um problema multiobjetivo de forma particionada tratando objetivo e restrições de modo separado e por último cada solução é comparada, porém existem variáveis que influenciam não somente em um, mas em vários objetivos de modo a reduzir a eficiência das respostas de cada função levando a soluções muitas vezes locais e não globais.

## 4.3 Otimização Multiobjetivo e Soluções Ótimas de Pareto

Um problema de otimização de objetivo único pode ser formulado conforme a expressão a seguir (IDOUMGHAR *et al.*, 2013); (TAGHDISIAN *et al.*, 2015); (CASTRO, 2015):

$$\begin{aligned} \min f(x) \\ x \in S \end{aligned} \tag{4.7}$$

onde  $f$  é uma função escalar e  $S$  é um grupo de restrições que podem ser definidas como:

$$S = \{x \in R^m: h(x) = 0, g(x) \geq 0\} \quad (4.8)$$

A otimização multiobjetivo, por outro lado, pode ser escrita em termos matemáticos da seguinte forma:

$$\min[f_1(x), f_2(x), \dots, f_n(x)] \quad x \in S, \quad (4.9)$$

onde  $n > 1$  e  $S$  é o grupo de restrições previamente definidas. O espaço denominado como “espaço de objetivos” contém o vetor com os vários objetivos e o espaço alcançado contém a imagem de todo grupo considerado apto pela função de aptidão  $F$ . Tal espaço é definido da seguinte forma (CARAMIA e DELL'OLMO, 2008); (GHANE-KANAFI e KHORRAM, 2015); (CASTRO, 2015):

$$C = \{y \in R^n: y = f(x), x \in S\}. \quad (4.10)$$

O conceito de escalar “ótimo” não se aplica diretamente a um grupo de otimização multiobjetivo. Ao invés de um número escalar indicando o "ótimo" a solução multiobjetivo introduz um conceito de "Pareto ótimo".

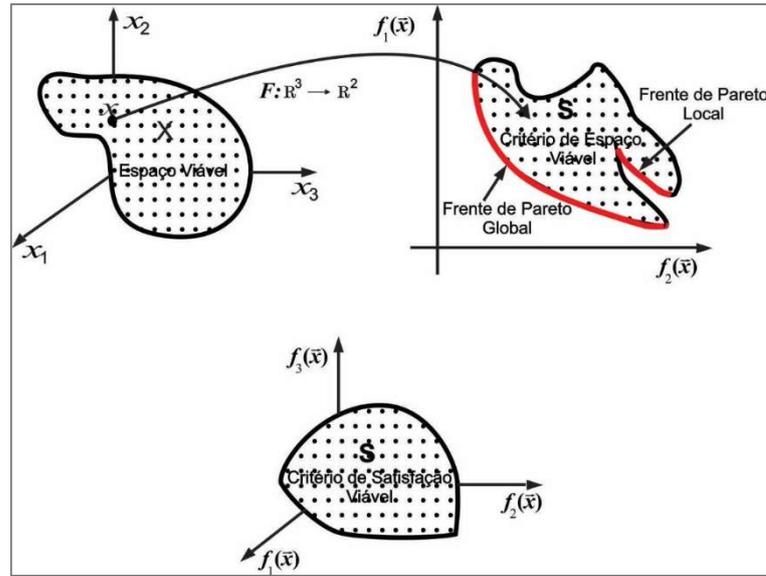
O conceito consiste no fato que todo o vetor  $x^* \in S$  é considerado contido no Pareto ótimo de um problema multiobjetivo se e somente se todos os vetores  $x \in S$  tiverem um valor maior ou igual do que o vetor  $x^*$ , e pelo menos um  $x^*$  seja menor que uma das funções objetivo  $f_i$ , sendo  $i = 1, 2, \dots, n$ .

A que contém todas as soluções eficientes é conhecida como frente de Pareto, curva de Pareto ou superfície de Pareto. A forma da figura de Pareto indica a natureza das trocas entre as funções objetivo (CARAMIA e DELL'OLMO, 2008); (GITIZADEH e AGHAEI, 2013); (CASTRO, 2015).

A figura 4.2. Mostra um espaço de decisão viável e a frente de Pareto para um problema multiobjetivo com dois ou três objetivos. Estes pontos são conhecidos como pontos não dominados ou não inferiores.

Na parte superior da figura 4.2 o espaço de decisão viável e a Frente de Pareto para o problema com dois objetivos. Na parte inferior uma superfície de Pareto 3D para um problema de otimização com três objetivos.

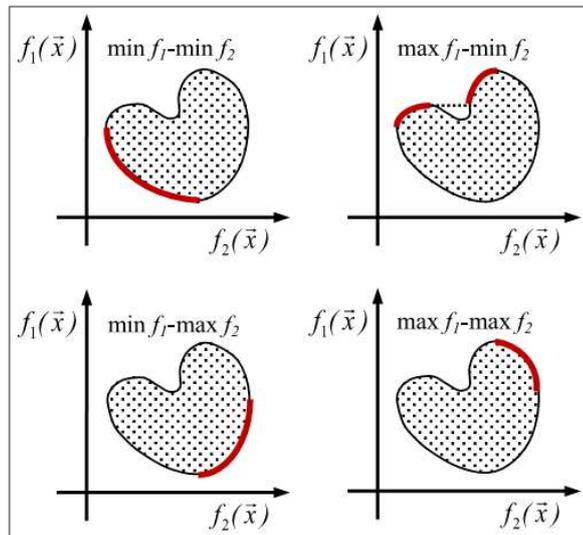
Figura 4.2 - Conceito geral da Curva de Pareto.



Fonte: adaptado de (TAGHDISIAN *et al.*, 2015).

Na figura 4.3, é visualizado o conjunto de Pareto por quatro possíveis combinações dos dois tipos de objetivos.

Figura 4.3 - Conjunto de combinações de Pareto para dois objetivos.



Fonte: (CARAMIA e DELL'OLMO, 2008).

#### 4.4 Técnicas de Resolução de Problemas de Otimização Multiobjetivo

Em certos casos as curvas de Pareto não podem ser computadas de maneira eficiente. Embora na teoria seja possível encontrar exatamente todos os pontos, é possível que haja problemas de tamanho exponencial. Para estes existem métodos de aproximação que são frequentemente utilizados. No entanto, muitas vezes a aproximação não representa uma escolha secundária para o tomador de decisão. De fato, existem muitos problemas da vida real dos quais são muito difíceis para o tomador de decisão obter todas as informações para formular estes

problemas de maneira correta. Levando em consideração que os tomadores de decisão tendem a entender mais sobre o problema assim que algumas soluções preliminares são apresentadas, ter algumas soluções aproximadas pode ajudar o especialista em sua tarefa (BAZGAN *et al.*, 2013); (MIRJALILI e LEWIS, 2015); (CASTRO, 2015).

Técnicas de aproximação geralmente apresentam objetivos variados tais como: representação de um grupo de soluções gráficas que podem ser convertidos para números (problemas multiobjetivo convexos); representação de um grupo de soluções gráficas onde apenas algumas curvas de Pareto podem ser representadas numericamente (problemas multiobjetivo não-lineares); representação de um grupo de soluções gráficas onde todo grupo eficiente de soluções não pode ser representado numericamente (problemas multiobjetivo discretos) (CASTRO, 2015).

#### 4.4.1 A Técnica de Transformação Escalar

Classicamente, um modelo de otimização multiobjetivo pode ser escalonado ou transferidos para um único problema de otimização objetivo. Dois métodos simples desta abordagem são: o método da soma ponderada (WSM) e o método do produto ponderado (WPM). No primeiro método, a função composta é gerada pela pré-multiplicação de cada objetivo por um peso fornecido pelo usuário (Eq. (4.11)), enquanto que no último método a composição da função é gerada através da multiplicação dos objetivos com uma potência fornecida pelo usuário (Eq.(4.12)). Os pesos e as potências referidas geralmente representam a preferência de paradigma na otimização multicritério (TAGHDISIAN *et al.*, 2015); (GHANE-KANAFI e KHORRAM, 2015).

$$\text{minimize } F_{eq}(\vec{x}) = \sum_{i=1}^k w_i f_i(\vec{x}) \quad (4.11)$$

$$\text{minimize } F_{eq}(\vec{x}) = \prod_{i=1}^k [f_i(\vec{x})]^{w_i} \quad (4.12)$$

Nas Eqs. (4.11) e (4.12)  $w_i$  é um vetor de pesos (ou potências), normalmente definido pelos tomadores de decisão. Ambos os métodos têm suas vantagens e limitações. Por exemplo, embora o WSM seja o mais simples e provavelmente a abordagem mais amplamente utilizada, a seleção de valores apropriados para fatores de peso ainda é mais um marco para o sistema de decisões. (GHANE-KANAFI e KHORRAM, 2015); (CARAMIA e DELL'OLMO, 2008).

No caso de WPM, potencializar aumentando as não linearidades na composição da função impede a utilização generalizada deste método. Este é o caso, onde solucionadores clássicos são usados, caso contrário, otimizadores evolutivos podem lidar com as não linearidades muito habilmente.

Um problema multiobjetivo geralmente é solucionado através da combinação de vários objetivos em uma única função objetivo escalar. Esta técnica é denominada como soma ponderada ou método de transformação escalar. Mais detalhadamente, o método da soma ponderada minimiza positivamente a soma ponderada conexa das funções objetivo, tal que (CARAMIA e DELL'OLMO, 2008); (GHANE-KANAFI e KHORRAM, 2015); (CASTRO, 2015):

$$\min \sum_{i=1}^n \gamma_i \cdot f_i(x) \quad (4.13)$$

$$\sum_{i=1}^n \gamma_i = 1$$

$$\gamma_i > 0, i = 1, \dots, n$$

$$x \in S, \quad (4.14)$$

Ao qual representa uma nova otimização de apenas uma função objetivo. A esta nova denominação da soma ponderada pode-se atribuir a função  $P_s(\gamma)$ .

É possível provar que ao minimizar a função mono-objetivo  $P(\gamma)$  encontra-se uma solução eficiente para o problema multiobjetivo original, devido ao fato da imagem desta função pertencer a curva de Pareto. Em particular, se o vetor ponderado  $\gamma$  tiver todos os seus elementos maiores que zero, então a minimização converge para a região ótima de Pareto restrita ( $P(\gamma)$ ), em contrapartida se ao menos 1 elemento de  $\gamma$  for igual a zero, então a minimização converge para a região ótima de Pareto fraca. Não existe uma relação, a priori, entre o vetor ponderado  $\gamma$  e a solução do vetor, cabendo ao tomador de decisão determinar os coeficientes apropriados, muito embora o coeficiente não se relacione diretamente com a importância das funções objetivo. Além do fato de o tomador de decisão não estar ciente de quais coeficientes são apropriados para obter a solução de forma satisfatória. Tendo isto em mente pode-se afirmar também que a tarefa de desenvolver uma heurística para auxiliar o tomador de decisão é significativamente difícil pois, deve-se partir do conceito de inicializar a busca com determinados coeficientes e de forma interativa com os vetores ponderados alcançar determinada região da curva de Pareto (ANTCZAK, 2011) (GHANE-KANAFI e KHORRAM, 2015); (CASTRO, 2015).

Uma vez que a criação de um vetor ponderado leva à apenas um ponto na curva de Pareto, realizar várias otimizações exige um grande poder de processamento e um elevado custo computacional. No entanto cabe ao especialista técnico determinar quais combinações diferentes dos coeficientes devem ser consideradas para que uma boa parte da frente de Pareto

possa ser representada (GHANE-KANAFI e KHORRAM, 2015). Além do elevado custo computacional, o método de transformação escalar também apresenta duas deficiências técnicas que são explicadas a seguir (CASTRO, 2015):

- A relação entre os coeficientes da função objetivo e a curva de Pareto é tal que uma distribuição uniforme dos coeficientes, em geral, não reproduz uma distribuição uniforme na curva de Pareto. Isto pode ser observado pelo fato de que alguns pontos são agrupados em algumas partes da frente de Pareto enquanto algumas partes (as vezes as mais significantes) não são reproduzidas.
- As partes não convexas do grupo de Pareto não podem ser alcançadas pela combinação da minimização convexa das funções objetivo. Para ilustrar, considera-se uma interpolação geométrica do método de soma ponderada em duas dimensões, quando  $n = 2$ . EM um espaço bidimensional a função objetivo pode ser expressa da seguinte forma:

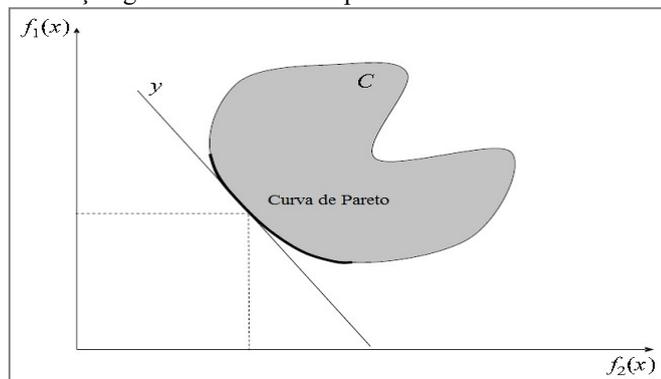
$$y = \gamma_1 \cdot f_1(x) + \gamma_2 \cdot f_2(x), \quad (4.15)$$

onde

$$f_2(x) = -\frac{\gamma_1 \cdot f_1(x)}{\gamma_2} + \frac{y}{\gamma_2}. \quad (4.16)$$

A minimização de  $\gamma \cdot f(x)$  no método de soma ponderada pode ser interpretado como a tentativa de encontrar o valor de  $y$  tal que a reta cuja a inclinação é determinada por  $-\frac{\gamma_1}{\gamma_2}$  seja tangente a região  $C$ . Obviamente, ao mudar os parâmetros dos coeficientes é possível alcançar diferentes pontos contidos na frente de Pareto. Se a curva de Pareto for convexa existe maior possibilidade de calcular tais pontos para diferentes vetores de  $\gamma$  (como pode ser observado na figura 4.4).

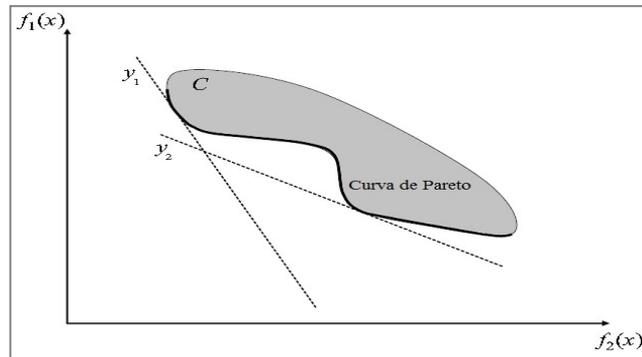
Figura 4.4 - Representação geométrica da soma ponderada no caso da curva de Pareto convexa.



Fonte: (CARAMIA e DELL'OLMO, 2008).

De forma análoga, quando a curva é não convexa existe um grupo de pontos que não podem ser alcançados por quaisquer combinações do vetor ponderado  $\gamma$  (conforme a figura 4.5).

Figura 4.5 - Representação geométrica da soma ponderada, Curva de Pareto não - convexa.



Fonte: (CARAMIA e DELL'OLMO, 2008).

De acordo com Geoffrion *apud* Caramia, (2008), as condições necessárias e suficientes para casos de convexidade são:

- Se um grupo de soluções  $S$  for convexa e os  $n$  objetivos de  $f_i$  são convexos em  $S$ , onde  $x^*$  é considerado uma solução restrita de Pareto ótimo, se e somente se, existir um  $\gamma \in \mathbb{R}^n$  tal que  $x^*$  é uma solução ótima do problema  $P_r(\gamma)$ ;
- Da mesma forma: Se um grupo de soluções  $S$  for convexa e os  $n$  objetivos de  $f_i$  são convexos em  $S$ , onde  $x^*$  é considerado uma solução fraca de Pareto ótimo se e somente se existir um  $\gamma \in \mathbb{R}^n$  tal que  $x^*$  é uma solução ótima do problema  $P_f(\gamma)$ .

Se a hipótese de convexidade não for satisfeita, apenas as condições necessárias permanecerão válidas, isto é, as soluções ótimas de  $P_r(\gamma)$  e  $P_f(\gamma)$  são respectivamente os ótimos de Pareto restrito e fraco (CARAMIA e DELL'OLMO, 2008); (ANTCZAK, 2011); (GHANE-KANAFI e KHORRAM, 2015); (CASTRO, 2015).

---

## CAPÍTULO V

---

### MÉTODOS PARA OTIMIZAÇÃO DO DE/DEA

#### 5.1 Introdução

A abordagem descrita a seguir, inclui um detalhamento dos métodos Determinísticos e Heurísticos utilizados para a otimização do DE e do DEA, considerados neste trabalho.

#### 5.2 Métodos Determinísticos

Os métodos de otimização determinísticos, também denominados métodos clássicos, nos quais se incluem os métodos de programação matemática, em geral são baseados nos cálculos de derivadas de primeira ou segunda ordem ou de uma aproximação dessas derivadas. Enquanto isso, os métodos baseados nos algoritmos probabilísticos introduzem no processo de otimização dados e parâmetros estocásticos resolvendo o problema do ponto de vista probabilístico (MEDEIROS e KRIPKA, 2012).

Uma limitação imprescindível para a utilização dos métodos determinísticos é a necessidade de que a função objetivo seja contínua e diferenciável relativo ao espaço de busca. No entanto, esta prerrogativa não ocorre na maioria dos problemas práticos de engenharia.

Embora a maioria dos métodos convencionais terem excelentes características de convergência, no entanto eles enfrentam dificuldades em lidar com o processo de restrições de desigualdade e o processo de resolução da solução diminuem a velocidade com funções objetivo complexas (RAJAN e MALAKAR, 2015).

Diversos métodos determinísticos têm sido aplicados para resolver o problema do DE, sua grande vantagem é o baixo custo computacional (tempo de resolução) e a fácil implementação em computador.

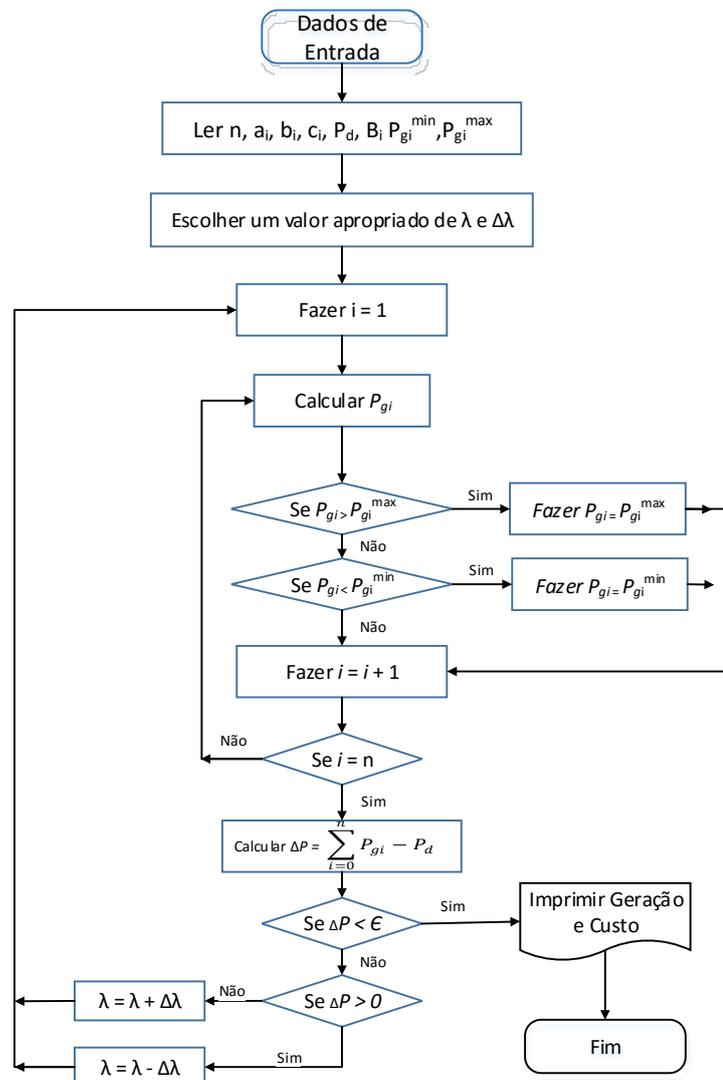
##### 5.2.1 Método de Iteração Lambda (MIL)

Uma das técnicas tradicionais mais populares para resolver o problema do DE e minimizar o custo de cada unidade geradora é o MIL. Embora o procedimento computacional da técnica de iteração lambda seja complexo, o mesmo converge muito rápido para este tipo de problema de otimização (DHAMANDA *et al.*, 2013).

O MIL é mais convencional para lidar com a minimização do custo de geração de potência a qualquer demanda. Para um número grande de unidades, o MIL é mais preciso e as curvas

incrementais de custo mais precisas de todas as unidades são armazenados na memória (RAHUL DOGRA, 2014). O algoritmo detalhado do MIL para resolução do problema do DE é dado na figura 5.1.

Figura 5.1 - MIL



Fonte: adaptado de (DHAMANDA *et al.*, 2013).

Os passos para resolver o Algoritmo do MIL ( $\lambda$ ) são descritos a seguir:

1. Ler os dados do problema:
  - O número de geradores ( $n$ )
  - Os coeficientes de custo ( $a_i, b_i, c_i$ )
  - Os coeficientes de perdas ( $B_i$ )
  - Os limites de Potência ( $P_{gi}^{min}$  e  $P_{gi}^{max}$ )
  - A demanda de Potência ( $P_d$ )
2. Supor um valor inicial de  $\lambda$  e  $\Delta\lambda$  com a utilização das equações das curvas de custo.
3. Calcular a Potência gerada por cada  $P_{gi}$  unidade.

4. Checar os limites de geração de cada unidade:

$$\begin{aligned} \text{if } P_{gi} > P_{gi}^{max} &, \quad \text{set } P_{gi} = P_{gi}^{max} \\ \text{if } P_{gi} < P_{gi}^{min} &, \quad \text{set } P_{gi} = P_{gi}^{min} \end{aligned}$$

5. Calcular a potência gerada.

6. Calcular a diferença de potência, que é dada pela seguinte equação:

$$\Delta P = \sum_{i=0}^{N_g} P_{gi} - P_d \quad (5.1)$$

7. *if*  $\Delta P < \varepsilon$  (valor de tolerância), então deter os cálculos e calcular o custo de geração. Caso contrário, ir à próxima etapa.

8. *if*  $\Delta P > 0$ , então  $\lambda = \lambda - \Delta\lambda$

9. *if*  $\Delta P < 0$ , então  $\lambda = \lambda + \Delta\lambda$

10. Repetir o procedimento a partir do passo 3

### 5.2.2 Programação Quadrática Sequencial (SQP)

Uma solução eficiente e precisa para o problema do DE não depende apenas do tamanho do problema, em termos do número de restrições e das variáveis do projeto, mas também de suas características.

Quando ambas as funções objetivo e restrições são funções lineares, o problema do DE é conhecido como um problema de programação linear. O problema de PQ refere-se à minimização ou maximização de uma função objetivo quadrática que é linearmente restrita. A PQ é um método de otimização eficaz para encontrar a solução global, se a função objetivo é quadrática e as restrições são lineares (BENHAMIDA *et al.*, 2013). Porém o problema mais difícil de resolver é o problema de programação não-linear em que a função objetivo e as restrições podem ser funções não-lineares das variáveis de projeto. A solução deste último problema requer um procedimento iterativo para obter uma direção de busca em cada iteração.

Esta direção pode ser encontrada pela solução de um subproblema de PQ. Os métodos para resolver estes problemas são comumente referidos como SQP desde que um subproblema de PQ seja resolvido em cada iteração maior, também são conhecidos como programação quadrática iterativa, programação quadrática recursiva ou método restrito de variável métrica. Os problemas resolvidos, no presente trabalho, são de programação quadrática e não-linear porque a função objetivo é quadrática e não-linear, respectivamente.

O SQP é, em muitos casos, superior aos demais métodos de programação não linear para otimização com restrições, possuindo vantagens em termos de eficiência, precisão e sucesso na obtenção de soluções, em um grande número de problemas testes disponíveis na literatura (FLETCHER, 1987); (BOGGS e TOLLE, 2000); (RODRÍGUEZ-TORAL *et al.*, 2001).

### a. Algoritmo da Programação Quadrática.

A PQ é um método de otimização eficaz para encontrar a solução global, se a função objetivo é quadrática e as restrições são lineares. Pode ser aplicado à otimização de problemas com funções objetivo quadráticas e restrições não lineares através da aproximação das funções objetivo a uma função quadrática e as restrições quando lineares. Para todos os problemas cujos os objetivos e as restrições são quadráticas, as restrições devem ser linearizadas (DHANRAJ e GAJENDRAN, 2005); (BENHAMIDA *et al.*, 2013).

As equações e inequações não lineares são resolvidas através dos seguintes passos (DEVENDRA BISEN, 2012):

**Etapa 1:** Para inicializar o procedimento é necessário alocar o limite inferior de geração de cada planta, calcular as perdas na transmissão e os coeficientes incrementais de perda e atualizar a demanda.

$$P_i = P_i^{min}, \quad x_i = 1 - \sum_{j=1}^n B_{ij} P_j \quad (5.2)$$

e,

$$PD^{new} = PD + P_L^{old} \quad (5.3)$$

**Etapa 2:** Substituir os coeficientes de custos incrementais e resolver o conjunto de equações lineares para determinar o custo de combustível incremental  $\lambda$  como:

$$\lambda = \frac{\sum_{i=1}^n 0,5 \times \frac{b_i}{a_i}}{P_D^{new} + \sum_{i=1}^n 0,5 \times \frac{b_i}{a_i}} \quad (5.4)$$

**Etapa 3:** Determinar a alocação de potência de cada planta.

$$P_i^{new} = \frac{\lambda - \frac{b_i}{a_i}}{2 \times \left(\frac{a_i}{x_i}\right)} \quad (5.5)$$

Se a planta violar seus limites deve ser fixado esse limite e as plantas restantes só devem ser consideradas para a próxima iteração.

**Etapa 4:** Checar a convergência.

$$|\sum_{i=1}^n P_i - PD^{new} - P_L| \leq \epsilon \quad (5.6)$$

$\epsilon$  - é o valor da tolerância, para a violação de balance de potência.

**Etapa 5:** Executar as etapas 2-4 até que a convergência seja alcançada. Para todos os quatro passos acima o objetivo é quadrático, mas também as restrições são quadráticas, assim as restrições devem ser feitas lineares:

$$\text{Minimizar: } XH X^T + f^T X \quad (5.7)$$

Sujeita a:  $KX \leq R, X^{min} \leq X \leq X^{max}$

$$X = [x_1, x_2, x_3, \dots, x_n]^n$$

$$f = [f_1, f_2, f_3, \dots, f_n]^n$$

$$R = [R_1, R_2, R_3, \dots, R_n]^T$$

$H$  é a matriz Hessiana de tamanho,  $n \times n$  e  $A$  é a matriz  $m \times n$  que representam as desigualdades. Para o DE com perdas o algoritmo de PQ pode ser efetivamente implementado, definindo as matrizes  $H, f, K$  e  $R$ .

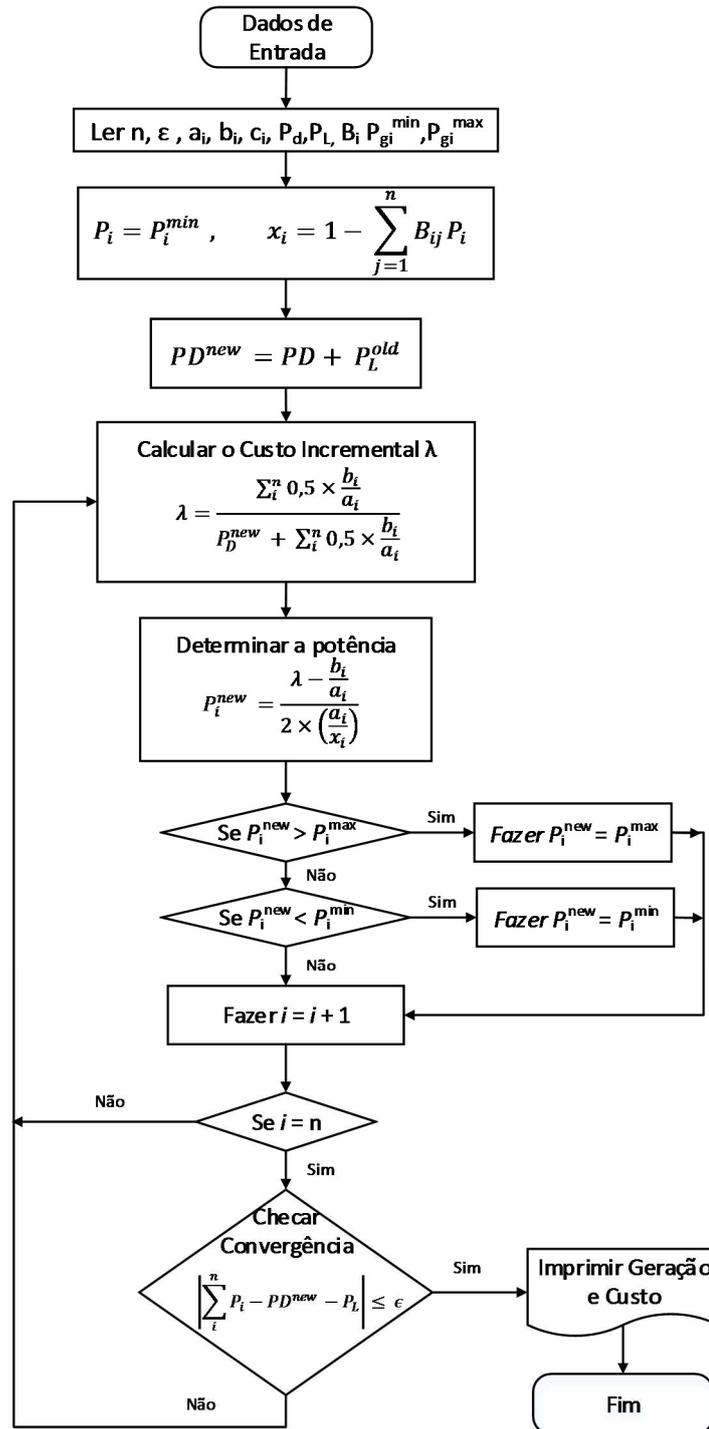
$$H = \text{diag} \left( \left[ \frac{a_1}{x_1}, \frac{a_2}{x_2}, \dots, \frac{a_n}{x_n} \right] \right) \quad (5.8)$$

$$f = \left[ \frac{b_1}{x_1}, \frac{b_2}{x_2}, \dots, \frac{b_n}{x_n} \right]$$

onde  $K$  é uma matriz:  $1 \times n$   $K = [1, 1, \dots, 1]$ , e  $R = PD + P_L^{old}$

Na figura 5.2, o fluxograma dos passos do algoritmo da PQ:

Figura 5.2 – Algoritmo da PQ.



Fonte: Autor, (2016).

### 5.2.3 Método de Newton (MN)

O DE também pode ser resolvido por meio da observação de que o objetivo é sempre gerar ou conseguir que  $\nabla L_x = 0$

Uma vez que esta é uma função vetorial, o problema pode ser formulado como aquele de procurar uma correção que conduza exatamente o gradiente a zero (isto é, há um vetor, cujos elementos são iguais a zero). O MN pode ser utilizado para isto. Este método para uma função de mais de uma variável é desenvolvido como se segue (RAHUL DOGRA, 2014); (CHU, 2009); (KNOLL e KEYES, 2004):

Supor que a função  $g(x)$  será conduzida a zero. A função  $g$  é um vetor e as incógnitas,  $x$ , são também vetores.

Então para usar o MN, é necessário seguir o procedimento descrito a seguir:

$$g(x + \Delta x) = g(x) + [g'(x)]\Delta x = 0 \quad (5.9)$$

Se a função for definida como:

$$g(x) = \begin{bmatrix} g_1(x_1, x_2, x_3) \\ g_2(x_1, x_2, x_3) \\ g_3(x_1, x_2, x_3) \end{bmatrix} \quad (5.10)$$

Então:

$$g'(x) = \begin{bmatrix} \frac{\partial g_1}{\partial x_1} & \frac{\partial g_1}{\partial x_2} & \frac{\partial g_1}{\partial x_3} \\ \frac{\partial g_2}{\partial x_1} & \frac{\partial g_2}{\partial x_2} & \frac{\partial g_2}{\partial x_3} \\ \frac{\partial g_3}{\partial x_1} & \frac{\partial g_3}{\partial x_2} & \frac{\partial g_3}{\partial x_3} \end{bmatrix} \quad (5.11)$$

Que é a conhecida matriz Jacobiana. O ajuste a cada passo é então:

$$\Delta x = -[g'(x)]^{-1}g(x) \quad (5.12)$$

Agora, se a função  $g$  e o vetor gradiente:  $\nabla L_x$ , então:

$$\Delta x = -inv \left[ \frac{\partial}{\partial x} \nabla L_x \right] \cdot \nabla L \quad (5.13)$$

Para o problema do DE, a expressão a usar é:

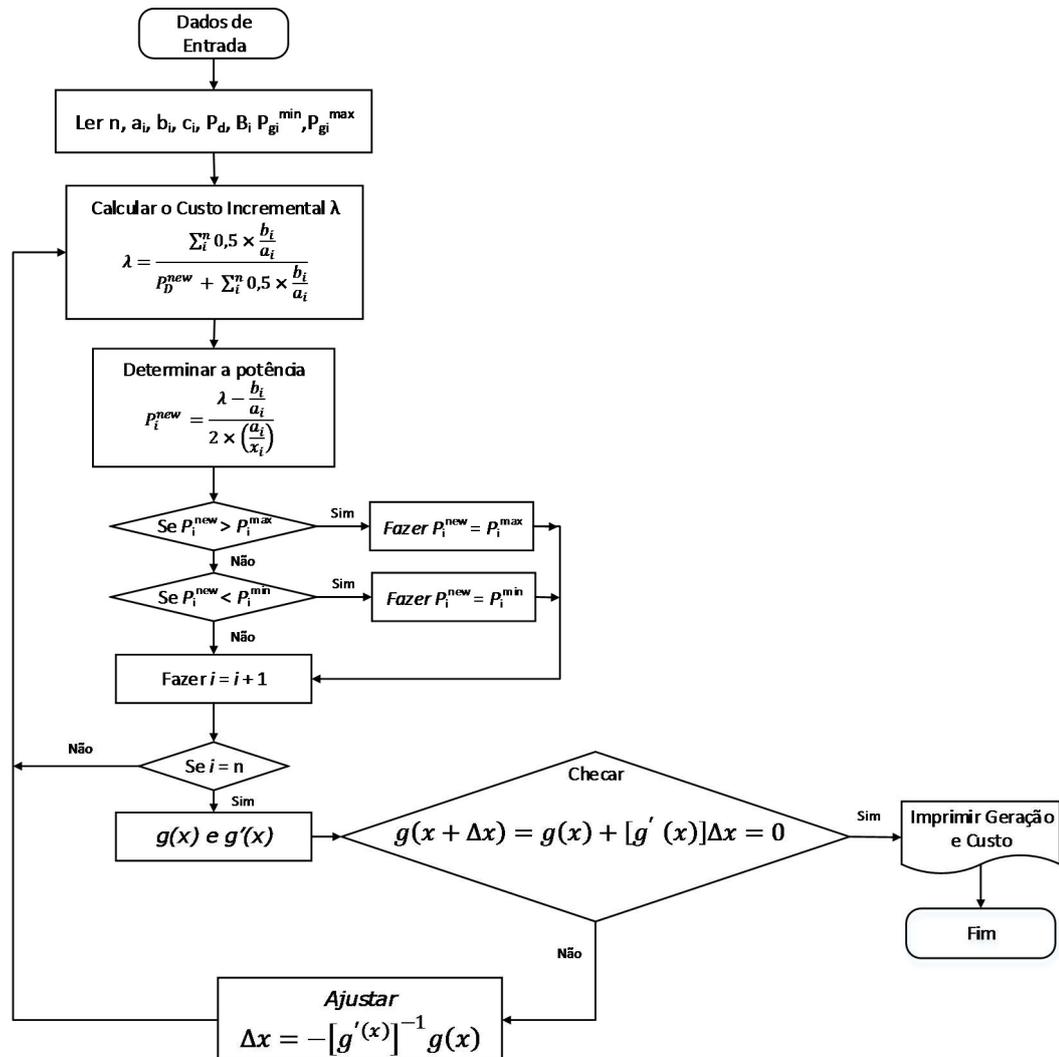
$$L = \sum_{i=1}^N F_i(P_i) + \lambda(P_{load} - \sum_{i=1}^N P_i) \quad (5.14)$$

e  $\nabla L$  é tal como foi definido antes. A matriz Jacobiana agora se torna um composto de segundas derivadas e é chamada a matriz Hessiana:

$$\left[ \frac{\partial}{\partial x} \nabla L_x \right] = \begin{bmatrix} \frac{d^2 L}{dx_1^2} & \frac{d^2 L}{dx_1 dx_2} & \dots \\ \frac{d^2 L}{dx_2 dx_1} & \dots & \\ \vdots & & \vdots \\ \frac{d^2 L}{d\lambda dx_1} & & \end{bmatrix} \quad (5.15)$$

Geralmente, o MN, em um passo, obtém uma solução que é muito mais próxima do custo mínimo de geração do que seria o método do gradiente (RAHUL DOGRA, 2014). Na figura 5.3, o fluxograma dos passos do algoritmo do MN:

Figura 5.3 – Algoritmo do MN.



Fonte: Autor, (2016).

### 5.3 Métodos Heurísticos

Um método heurístico é um conjunto de regras práticas derivadas da experiência. Não existe uma prova definitiva de sua veracidade, mas espera-se que a técnica heurística funcione na maioria das vezes, porém, não todas. Uma heurística nos auxiliará a encontrar soluções boas, mas não necessariamente ótimas. Para aplicação de regras heurísticas foram desenvolvidas diversas técnicas metaheurísticas.

Uma metaheurística é um conjunto de conceitos que possam ser utilizados para definir métodos heurísticos que podem ser aplicados a um grande conjunto de diferentes problemas. Em outras palavras, uma metaheurística pode ser vista como um *framework* algorítmico geral que pode ser aplicado a diferentes problemas de otimização com relativamente poucas modificações para torná-lo adaptado para um problema específico (SILVA e SILVA, 2014).

Algoritmos de metaheurísticas modernos são uma alternativa promissora para solução de problemas de otimização do DE e do DEA complexos (BASU, 2014b). Nas seções seguintes são descritas com detalhes as técnicas de inteligência computacional aplicadas neste trabalho.

#### 5.3.1 Algoritmo Evolução Diferencial (ED)

O algoritmo de ED foi desenvolvido para ser um algoritmo de otimização heurística promissora em problemas de otimização numérica (STORN, 1997). A ED foi projetado para cumprir a exigência de técnicas de minimização práticas com a convergência consistente para o mínimo global em ensaios independentes consecutivos, pode resolver funções não-diferenciáveis, não-lineares e funções de custo multimodal (BEHERA *et al.*, 2015).

O algoritmo ED é uma estratégia simples de otimização estocástica. Ele usa uma abordagem voraz e menos estocástica com codificação de ponto flutuante na resolução de problemas, ao contrário de outros algoritmos evolutivos (COELHO *et al.*, 2014).

A ED usa os operadores aritméticos para evoluir a partir de uma população inicial gerada aleatoriamente até uma solução final. Basicamente, a diferença ponderada entre dois indivíduos é adicionada a um terceiro indivíduo na população. Desta forma, nenhuma distribuição separada de probabilidade tem de ser usada, o que faz com que o esquema seja completamente auto organizado (COELHO *et al.*, 2014).

Existem várias estratégias variantes de ED. Em expressões gerais são divididas em duas partes, a primeira parte representa um vetor a ser perturbado. A primeira parte é ‘*rand*’ (vetor escolhidos aleatoriamente) ou “melhor” (melhor vetor da população atual). A segunda parte é o número de vetores de diferença (um ou dois) escolhidos para vetores de perturbação da

primeira parte, e a última parte indica o tipo de cruzamento a ser utilizado. O tipo de cruzamento pode ser ‘bin’ (binomial) ou ‘exp’ (exponencial) (COELHO *et al.*, 2014).

### a. Inicialização

A inicialização da ED pode ser feita gerando aleatoriamente soluções candidatas com  $NP$   $D$ -dimensional vetores de parâmetros reais avaliados (ROQUE e MARTINS, 2015).

$$X_{j,i,0} = X_{j,min} + rand_{ij}[0,1](X_{j,max} - X_{j,min}) \quad (5.16)$$

onde  $rand_{ij}[0,1]$  é um número aleatório, que é multiplicado pelo comprimento do intervalo  $0 \leq rand_{ij}[0,1] \leq 1$ ,  $(X_{j,max} - X_{j,min})$  garante uma amostragem distribuída do parâmetro de domínio do intervalo  $[X_{j,min}, X_{j,max}]$  (ROQUE e MARTINS, 2015).

Existem outras abordagens para determinar a população inicial, embora igualdade aleatória seja a mais comum. Nos problemas atuais de otimização, um parâmetro de solução possível é adicionado à população inicial, a fim de aperfeiçoar a convergência.

### b. Mutações

Mutação diferencial acrescenta uma escala, amostragem aleatória, de um vetor de diferença a um terceiro vetor. Vetores mutantes  $\vec{V}_{i,G}$ , também chamados de doadores são obtidos através da operação de mutação diferencial (ROQUE e MARTINS, 2015):

$$\vec{V}_{i,G} = \vec{X}_{r_1^i,G} + F(\vec{X}_{r_2^i,G} - \vec{X}_{r_3^i,G}) \quad (5.17)$$

onde  $F$  é um número real positivo que controla a taxa de evolução da população.

Vetores  $\vec{X}_{r_1^i,G}$ ,  $\vec{X}_{r_2^i,G}$  e  $\vec{X}_{r_3^i,G}$  são mostrados aleatoriamente para formar a população atual e  $r_1^i$ ,  $r_2^i$ ,  $r_3^i$  são números que se excluem mutuamente escolhidos no intervalo  $\{1, \dots, Np\}$ . Em clássicos ED, valores pequenos de  $F$  são associados com Exploração, entendida como uma estratégia oportunista, se algumas das soluções de teste estão na vizinhança do mínimo global. Por outro lado, valores grandes de  $F$  são associados com exploração de novas soluções de testes mutantes (doadores) incorporando maiores diferenças em relação à população original (alvos) (ROQUE e MARTINS, 2015).

### c. Crossover

O crossover aumenta a diversidade potencial de uma população. No caso de binomial *Crossover*, vetores de teste  $U_{i,G}$  são produzidos de acordo com:

$$u_{i,j,G} = \begin{cases} v_{j,i,G} & \text{se } \text{rand}_{i,j}[0,1] \leq Cr \text{ ou } j = j_{rand} \\ x_{j,i,G} & \text{outros casos} \end{cases} \quad (5.18)$$

O *Crossover* pode ser entendida como uma taxa de mutação ou uma probabilidade de herança entre sucessivas gerações. Existem alternativas para binomial *Crossover*. O mais comum é a exponencial *Crossover*. Ambas as abordagens são válidas para todos os problemas, embora o sucesso/melhoria de um sobre o outro varia de acordo com o problema considerado (ROQUE e MARTINS, 2015).

### d. Seleção

Seleção pode ser entendida como uma forma de competição, em linha com muitos exemplos diretamente observáveis na natureza. Muitos esquemas de otimização evolutiva, como a ED ou AG usam alguma forma de seleção, por exemplo a Eq. 5.19:

$$\vec{X}_{i,G+1} = \begin{cases} \vec{U}_{i,G} & \text{se } f(\vec{U}_{i,G}) \leq f(\vec{X}_{i,G}) \\ \vec{X}_{i,G} & \text{se } f(\vec{U}_{i,G}) > f(\vec{X}_{i,G}) \end{cases} \quad (5.19)$$

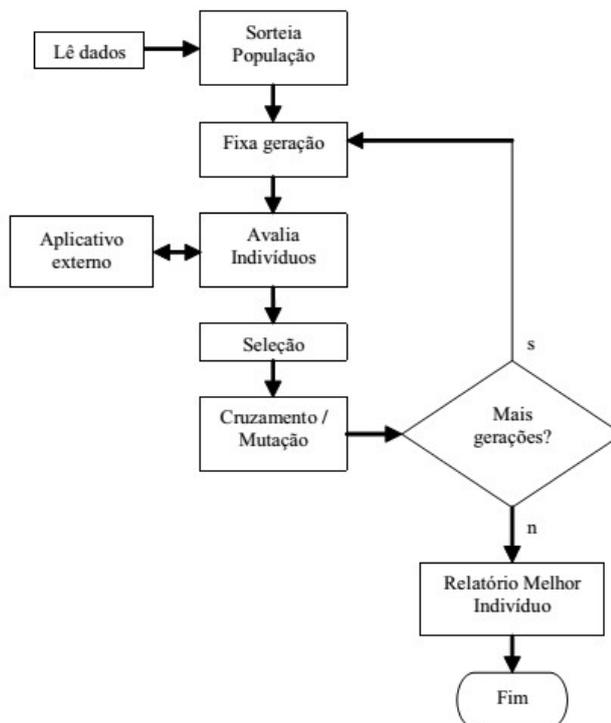
Quanto a uma operação de seleção, a seleção de pares, também chamada seleção ávido ou seleção elite, é constantemente utilizada no algoritmo. Como um critério de parada, um número máximo de gerações  $G_{max}$  é definido (ROQUE e MARTINS, 2015).

### 5.3.2 Algoritmos Genéticos (AGs)

O Algoritmo Genético (AG), que foi proposto no início da década 1970, é um método de pesquisa global estocástica que imita a metáfora de avaliação biológica natural. O AG é iniciado com uma população (geração) de indivíduos que são gerados aleatoriamente. Cada indivíduo (cromossomo) codifica uma única solução possível para o problema em questão. Os indivíduos mais aptos são escolhidos de acordo com uma função de aptidão (*fitness*) pré-definida, que é avaliada para cada membro dessa população. Os indivíduos com altos valores de aptidão representam, portanto, uma melhor solução para o problema do que indivíduos com valores de aptidão inferiores (ELATTAR, 2015).

O fluxograma básico de um Algoritmo Genético está ilustrado na Figura 5.4.

Figura 5.4 – Fluxograma básico do AG.



Fonte: adaptado de (RAMOS e SUSTERAS, 2006).

### a. População Inicial

O sorteio da população inicial é realizado através da geração de números aleatórios de probabilidade uniforme, de tal forma que para cada bit, se o valor sorteado for menor do que 0,5 o bit será 0, caso contrário será 1 (RAMOS e SUSTERAS, 2006).

A definição da população inicial é realizada da forma mais simples possível, fazendo-se uma escolha aleatória independente para cada indivíduo ou por processo heurístico, isto é simplesmente escolher  $n$  indivíduos dentro do espaço de pesquisa.

### b. Avaliação

A avaliação dos indivíduos de cada geração é feita pela função de avaliação definida inicialmente. Para o processo de seleção, deve-se normalizar a função de avaliação de forma a associar o resultado da função de avaliação a uma probabilidade de ser selecionado para o processo de cruzamento (RAMOS e SUSTERAS, 2006).

Este é o elemento mais significativo de qualquer algoritmo genético. É através desta função que se avalia quão próximo um indivíduo está da solução desejada ou quão boa é esta

solução. A função de avaliação deve refletir os objetivos a serem alcançados na resolução de um problema e é derivada diretamente das condições impostas pelo problema.

Antes de proceder à seleção, deve-se fazer o escalamento da função aptidão. No começo da execução do AG é comum a existência de poucos indivíduos extraordinários em uma população com colegas medíocres. Quando se utiliza o método de seleção proporcional (roleta, conforme será explicado mais adiante), os indivíduos extraordinários ocuparão uma grande fatia do círculo conduzindo a uma convergência prematura (RAMOS e SUSTERAS, 2006).

Durante a execução, pode ainda existir uma diversidade significativa dentro da população. Entretanto, o valor médio de aptidão da população pode estar próximo do melhor valor de aptidão da população. Se esta situação não é controlada, membros médios e melhores membros produzem o mesmo número de cópias em futuras gerações e a sobrevivência do mais apto, necessária para o aperfeiçoamento, torna-se uma caminhada aleatória entre os medíocres. Em ambos os casos, o escalamento pode ajudar (RAMOS e SUSTERAS, 2006).

### **c. Seleção**

A seleção dos indivíduos da população deve simular o mecanismo de seleção natural das espécies, onde os indivíduos mais fortes e adaptados ao ambiente são os que sobrevivem.

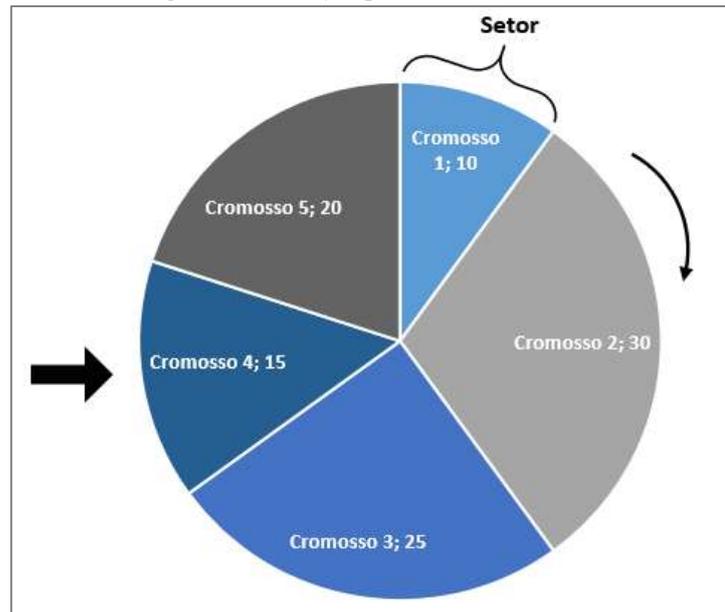
O algoritmo permite também que alguns indivíduos menos aptos gerem filhos, garantindo a diversidade entre os indivíduos melhores e os piores. Se apenas os melhores indivíduos se reproduzirem a população tenderá a ser cada vez mais semelhante, não ocorrendo a evolução. Há diversas formas de seleção, entre eles há o método de seleção por Roleta e o método de seleção por Torneio.

No caso do AG simples, a solução adotada está embasada no método da roleta. O método da roleta consiste em associar a cada cromossomo um pedaço da roleta (ou setor) de tamanho proporcional à sua função de avaliação. A seleção é feita da seguinte forma (RAMOS e SUSTERAS, 2006):

1. Sorteia-se um número entre 0 e a soma das funções de avaliação.
2. Soma-se, em qualquer ordem, o valor do setor alocado de cada cromossomo.
3. O cromossomo cujo setor fizer esta soma ultrapassar o número sorteado será o cromossomo escolhido.

Na figura 5.5 é ilustrado o método da roleta.

Figura 5.5 - Seleção pelo método da roleta.



Fonte: adaptado de (RAMOS e SUSTERAS, 2006).

Durante a seleção, por se tratar de um processo probabilístico, pode ocorrer a perda do melhor indivíduo daquela geração, isto é, pode acontecer de o indivíduo mais apto não ser escolhido para formar a geração seguinte. Para solucionar esta questão existe o processo de Elitismo, no qual os  $n$  melhores indivíduos da geração atual são copiados na geração seguinte (RAMOS e SUSTERAS, 2006).

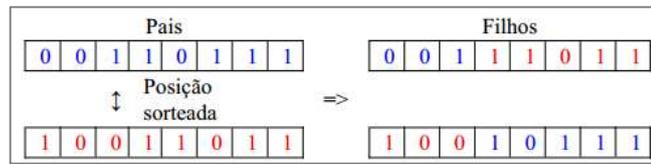
#### d. Cruzamento

Uma vez selecionados os indivíduos, a etapa seguinte é a do cruzamento. Primeiro, sorteia-se um número de 0 a 1 e caso o valor sorteado seja menor que a taxa de cruzamento, procede-se o referido processo; caso contrário, apenas repetem-se os cromossomos dos “pais” para a próxima geração (RAMOS e SUSTERAS, 2006).

O processo de cruzamento pode ser feito em único ponto e múltiplos pontos. Significa dizer que o ponto de corte dos pais para a formação dos novos indivíduos pode ser único ou múltiplo.

Para o processo de cruzamento de um ponto, sorteia-se um número  $n$  entre 1 e o tamanho do *string*, de tal forma que um dos filhos terá os genes de 1 a  $n$  de um dos pais e de  $n+1$  até o final do outro. Analogamente, o outro filho receberá os  $n$  primeiros genes do segundo pai e os demais genes do primeiro, conforme ilustrado na figura 5.6 (RAMOS e SUSTERAS, 2006):

Figura 5.6 - Processo de cruzamento de um ponto.

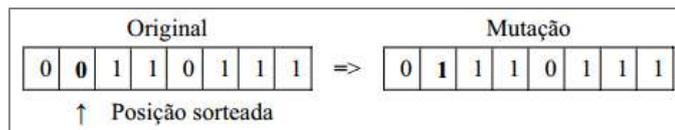


Fonte: (RAMOS e SUSTERAS, 2006).

### e. Mutação

Um dos operadores mais importantes no AG é a mutação. É a partir deste mecanismo que saltos qualitativos na população podem ser verificados. Para executar tal processo, para cada gene (*bit*) de toda a população sorteia-se um número de 0 a 1 e, caso o número sorteado seja menor do que a taxa de mutação definida, faz-se a troca do valor daquele *bit*, de forma que se era 0 passa a ser 1 e vice-versa (RAMOS e SUSTERAS, 2006). O processo pode ser assim ilustrado:

Figura 5.7 - Processo de mutação.



Fonte: (RAMOS e SUSTERAS, 2006).

Na sequência deste processo inicial, as operações de crossover e mutação são usadas onde os indivíduos da população atual produzem os descendentes. Para estes descendentes são atribuídas pontuações chamadas de *fitness*.

Após seleção, cruzamento e mutação serem aplicadas à população inicial, uma nova população vai sendo formada e o contador de gerações é incrementado em um. Este processo de seleção, cruzamento e mutação é continuado até que uma condição de terminação seja atingida (ELATTAR, 2015).

Basicamente o AG consiste em três etapas principais: Seleção, Cruzamento e Mutação. A aplicação destas três operações básicas permite a criação de novos indivíduos que podem ser melhores do que seus pais.

Este algoritmo é repetido para muitas gerações e finalmente para em uma solução ótima para o problema (BEHERA *et al.*, 2015).

### 5.3.3 Algoritmo Genético de Classificação Não-Dominado (NSGA)

Em sua pesquisa Fonseca e Fleming, expuseram o procedimento de *ranking* de soluções baseadas em um sistema de nível de dominância conhecido como NSGA que foi implementado em sua totalidade (SRINIVAS e DEB, 1993); (1993) (FONSECA e FLEMING, 1995).

Um novo algoritmo genético de classificação não-dominado (NSGA), com base na sugestão de Goldberg. Este algoritmo elimina o viés do Vetor de Evolução GA (VEGA) e, assim distribui a população sobre as regiões inteiras do ótimo de Pareto. Embora existam outras duas implementações com base nesta ideia, o NSGA é diferente dos seus princípios de trabalho, conforme explicado como se segue (SRINIVAS e DEB, 1993):

Uma vez que o algoritmo é baseado no procedimento de classificação não dominada, é nomeado de NSGA.

O NSGA varia do algoritmo genético simples somente na forma como o operador de seleção funciona. Os operadores de cruzamento e mutação permanecem do mesmo modo. (SRINIVAS e DEB, 1993); (COELLO COELLO, 1999).

Antes de a seleção ser realizada, a população é classificada com base na não-dominação de um indivíduo. Os indivíduos não dominados presentes na população são primeiramente identificados a partir da população atual.

Então, todos esses indivíduos são admitidos para constituírem a primeira frente não dominada da população e atribui-se um alto valor de aptidão padrão.

O compartilhamento é conseguido através da realização da operação de seleção usando uma redução dos valores de aptidão, que são obtidas através da divisão do valor inicial de aptidão de um indivíduo por uma quantidade proporcional ao número de indivíduos em sua volta. Isto causa múltiplos pontos ideais de coexistência na população.

Depois do compartilhamento, os indivíduos não dominados são ignorados temporariamente para processamento do resto da população do mesmo modo para identificar indivíduos para a segunda frente não dominada.

Então, a este novo conjunto de pontos é atribuído um novo valor padrão de aptidão que é mantido menor do que o mínimo valor de aptidão compartilhado da frente anterior. Este processo é continuado até que toda a população seja classificada em várias frentes.

A população então é reproduzida de acordo com os valores de aptidão. Uma vez que, os indivíduos na primeira frente têm um valor de aptidão máxima, eles sempre obtêm mais cópias do que o resto da população.

Esta foi a intenção de procurar regiões não dominadas ou frentes ótimas de Pareto. Isso resulta em uma convergência rápida da população em direção a regiões não dominadas nesta região.

Ao enfatizar pontos não dominados, o NSGA está realmente processando os esquemas que representam regiões ótimas de Pareto.

A eficiência do NSGA está na maneira de como objetivos múltiplos são reduzidos a uma função padrão de aptidão usando o procedimento de classificação não dominada (SRINIVAS e DEB, 1993).

Outro aspecto do método é que praticamente quaisquer números de objetivos podem ser resolvidos. Ambos os problemas de minimização e maximização também podem ser tratados por este algoritmo.

O único lugar que requer uma mudança para os dois casos acima é na maneira de identificação dos pontos não dominados (SRINIVAS e DEB, 1993).

#### **5.3.4 O Elitista Algoritmo Genético de Classificação Não-Dominado II (NSGA II)**

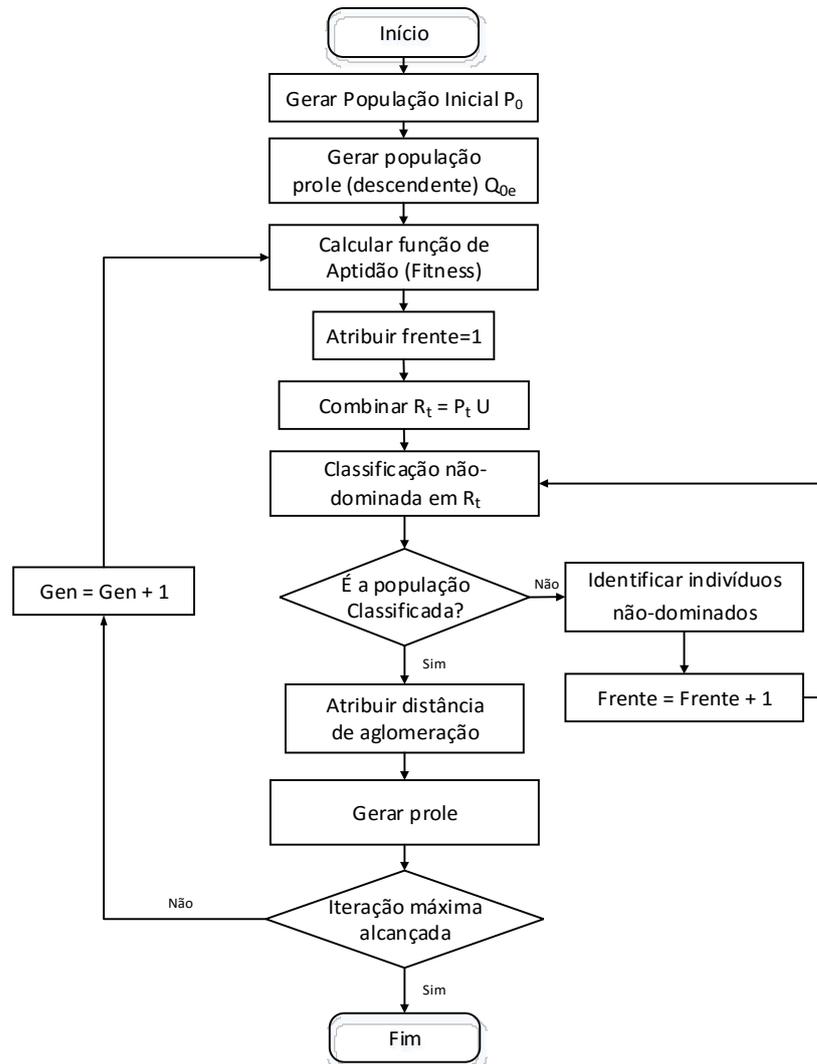
O Elitista Algoritmo Genético de Classificação Não-Dominado (NSGA-II) é um algoritmo usado para resolver os problemas de Otimização Multiobjetivo (MOO) (DEB *et al.*, 2002).

O NSGA-II é um dos algoritmos mais utilizados para resolver problemas de MOO (GOLCHHA e QURESHI, 2015).

O NSGA-II, difere do NSGA por, usar um procedimento mais rápido de triagem, uma abordagem de preservação elitista e um parâmetro para o operador de segmento (GOLCHHA e QURESHI, 2015).

O funcionamento do NSGA-II é demonstrado na figura 5.8:

Figura 5.8 – Funcionamento do NSGA-II.



Fonte: Adaptado de (GOLCHHA e QURESHI, 2015).

### a. População Inicial

Inicialmente, uma população aleatória pai é criada. A população é ordenada com base na não-dominância. A cada solução é atribuída uma aptidão igual ao seu nível de não dominância (1 é o melhor nível). Assim, a minimização de aptidão é assumida. São usados operadores de seleção por torneio, recombinação e mutação para criar população descendente de tamanho  $N$  (KALAIVANI *et al.*, 2013).

A população é inicializada com base no intervalo do problema e restrições, se houver, e esta população é inicializada e ordenada com base na não-dominância.

## b. Seleção

No original NSGA-II é usada a seleção por torneio binário (BTS), onde torneio é disputado entre duas soluções e a melhor é selecionada para o cruzamento. Duas outras soluções são novamente tomadas e outra abertura na associação de cruzamento é preenchida. Ele é realizado de tal modo que cada solução pode vir a participar em exatamente dois torneios (GOLCHHA e QURESHI, 2015).

## c. Crossover (Cruzamento)

No NSGA-II é usado o Crossover Binário Simulado (SBX), que trabalha com duas soluções pais e gera dois descendentes. O seguinte procedimento passo-a-passo é descrito (GOLCHHA e QURESHI, 2015):

Passo 1: Escolha um número aleatório  $u_i \in [0, 1]$ ;

Passo 2: Calcular usando a Eq. (5.20);

Passo 3: Calcular descendente usando a Eq. (5.21).

A formulação matemática pode ser descrita como se segue:

$$\beta_{qi} = \begin{cases} (2u_i)^{\frac{1}{n_c+1}} & \text{se } u_i \leq 0,5; \\ \left(\frac{1}{2(1-u_i)}\right)^{\frac{1}{n_c+1}} & \text{outros casos.} \end{cases} \quad (5.20)$$

$$X_i^{(1,t+1)} = 0,5[(1 + \beta_{qi})X_i^{(1,t)} + (1 - \beta_{qi})X_i^{(2,t)}],$$

$$X_i^{(2,t+1)} = 0,5[(1 - \beta_{qi})X_i^{(1,t)} + (1 + \beta_{qi})X_i^{(2,t)}]. \quad (5.21)$$

Aqui:

$u_i$ : Um número aleatório de tal modo que  $u_i \in [0, 1]$ ;

$n_c$ : Índice de Distribuição (número real não-negativo);

$X_i^{(1,t)}$  &  $X_i^{(2,t)}$ : Soluções pais;

$X_i^{(1,t+1)}$  &  $X_i^{(2,t+1)}$ : Soluções descendentes.

#### d. Mutação

É usada a mutação polinomial, que transforma cada solução separadamente, isto é, uma solução-mãe dá uma descendência depois de ser mutada. A formulação matemática pode ser descrita como na Eq. (5.22) (GOLCHHA e QURESHI, 2015):

$$y_i^{(1,t+1)} = (y_i^{(1,t+1)} + X_i^{(U)} - X_i^{(L)})\bar{\delta}_1 \quad (5.22)$$

Onde:

$$\bar{\delta}_1 = \begin{cases} (2r_i)^{1/(n_m+1)-1}, & \text{se } r_i < 0,5, \\ 1 - [2(1 - r_i)]^{1/(n_m+1)}, & \text{se } r_i \geq 0,5. \end{cases} \quad (5.23)$$

Aqui:

$r_i$ : Um número aleatório de tal modo que  $u_i \in [0, 1]$ ;

$n_m$ : Índice de Distribuição (número real não-negativo);

$X_i^{(1,t+1)}$ : Solução-mãe;

$X_i^{(U)}$ : Limite superior da solução precursora;

$X_i^{(L)}$ : Limite inferior da solução precursora;

$y_i^{(1,t+1)}$ : Solução descendente.

#### e. Seleção Torneio Aglomerado

Para obter uma estimativa da densidade de soluções próxima de uma particular solução  $i$  na população, tomamos a média das duas soluções de ambos os lados da solução  $i$  juntamente com cada um dos objetivos. Esta quantidade  $d_i$  é Distância de Aglomeração. O algoritmo que se segue é usado para calcular a distância de aglomeração de cada ponto no conjunto  $\mathcal{F}$  (GOLCHHA e QURESHI, 2015).

Procedimento de atribuição: Aglomeração-Seleção ( $\mathcal{F}, < c$ )

**Passo 1:** Considerar o número de soluções em  $\mathcal{F}$  como  $l = |\mathcal{F}|$ . Para cada  $i$  no conjunto, em primeiro lugar atribuir  $d_i = 0$ .

**Passo 2:** Para cada função objetivo  $m = 1, 2, \dots, M$ , classificar o conjunto em pior ordem de  $f_m$ . Encontrar vetor de índices classificação  $I_m = \text{Seleção}(f_m, >)$ .

**Passo 3:** Para  $m = 1, 2, \dots, M$ , atribuir uma grande distância para as soluções de ponta,  $d_{I_1^m} = \infty$ , e para todas as outras soluções  $j = 2$  para  $(l - 1)$  calcule:

$$d_{I_j^m} = d_{I_j^m} + \frac{f_m^{(I_{j+1}^m)} - f_m^{(I_{j-1}^m)}}{f_m^{max} - f_m^{min}}$$

O NSGA-II apresenta uma técnica melhorada para a manutenção da diversidade de soluções, propondo um método de aglomeração da distância de classificação. No entanto, no seu processo, a técnica de classificação permaneceu inalterada da sua versão anterior. (SUKSONGHONG *et al.*, 2014).

Em NSGA-II, todos os indivíduos são classificados em populações combinadas (pais e descendentes) com base na relação de dominância de Pareto e, em seguida, classificados em várias camadas com base na frente ao qual um indivíduo está localizado. Em cada frente, os indivíduos estão dispostos em ordem decrescente de magnitude do valor da distância de aglomeração. No processo de seleção por torneio binário, o algoritmo primeiro seleciona um indivíduo posicionado em uma melhor frente não-dominada. Nos casos em que os indivíduos com uma frente idênticos são comparados, o operador de seleção por torneio escolhe o vencedor com base no valor da distância de aglomeração (SUKSONGHONG *et al.*, 2014).

A estratégia elitista do NSGA II considera todas as combinações de soluções não-dominadas das populações como os candidatos de soluções para a próxima geração. Se o número de soluções não-dominadas é menor do que o tamanho da população, todos eles são mantidos como as soluções da última geração. Caso contrário, os candidatos para a próxima geração são selecionados através do critério de distância de aglomeração. Este critério tem a vantagem de manter a diversidade de soluções na população, a fim de evitar a convergência prematura (SUKSONGHONG *et al.*, 2014); (LIU *et al.*, 2015).

### 5.3.5 Otimização por enxame de partículas (PSO)

A Otimização por Enxame de Partículas (PSO) é uma técnica de otimização estocástica de base populacional, inspirado no comportamento social dos pássaros ou cardumes de peixes. Moore e Chapman estenderam essa ideia para otimização multiobjetivo em 1999 (ZHOUA *et al.*, 2011).

O Simplex PSO não pode ser aplicado diretamente para otimização multiobjetivo visto que, há duas questões a serem consideradas quando estender a otimização PSO para problemas multiobjetivo (ZHOUA *et al.*, 2011):

A primeira é como selecionar as melhores partículas globais e locais (líderes) para orientar a busca de uma partícula. A segunda é como manter bons pontos encontrados até o momento. Para o último, uma população secundária é normalmente utilizada para manter as soluções não-dominadas.

Seja  $p$ (posição) e  $v$ (velocidade) coordenadas de uma partícula e sua velocidade de vôo correspondente em um espaço de busca, respectivamente. Portanto, a  $i$ -ésima partícula é representado como  $P_i = [P_{i1}, P_{i2}, P_{i3}, \dots, P_{iNG}]$ , no espaço NP-dimensional. A melhor posição anterior de cada partícula é registrada e representada como  $Pb_i = [Pb_{i1}, Pb_{i2}, Pb_{i3}, \dots, Pb_{iNG}]$ . O índice da melhor partícula entre as partículas do grupo é representado pelo vetor  $[G_1, G_2, G_3, \dots, G_{NG}]$ . A taxa de velocidade da partícula é representada como:  $v_i = [v_{i1}, v_{i2}, v_{i3}, \dots, v_{iNP}]$  A nova velocidade e posição de cada partícula podem ser calculadas utilizando a velocidade atual e a distância do  $Pb_{ij}$  para  $G_j$ , como visualizado na Eq. (5.24). (SINGH *et al.*, 2013).

$$v_{ij}^{r+1} = w \times v_{ij}^r + C_1 \times R_1 \times (Pb_{ij}^r - P_{ij}^r) + C_2 \times R_2 \times (G_{jr} - P_{ij}^r)$$

$$(i = 1, 2, \dots NP; j = 1, 2, \dots NG) \quad (5.24)$$

$$P_{ij}^{r+1} = P_{ij}^r + v_{ij}^{r+1}$$

$$(i = 1, 2, \dots NP; j = 1, 2, \dots NG) \quad (5.25)$$

onde:

NP é o número de partículas no grupo.

NG é o número de membros na partícula

R é o ponteiro de iteração (geração)

w é o fator de peso de inércia

$C_1$  e  $C_2$  são as constantes de aceleração

$R_1$  e  $R_2$  são valores aleatórios no intervalo [0,1]

$v_{ij}^r$  é a velocidade do  $j$ th membro da  $i$ th partícula na  $r$ th iteração, limitada pela Eq.(5.26).

$$v_j^{min} \leq v_{ij}^r \leq v_j^{max} \quad (5.26)$$

$P_{ij}^r$  é a posição atual do  $j$ th membro da  $i$ th partícula na  $r$ th iteração.

Os parâmetros  $v_j^{min}$  e  $v_j^{max}$  determinam a resolução, ou capacidade, para procurar regiões entre a posição atual e a posição de destino. Se  $v_j^{max}$  é muito alta, as partículas podem voar passando por boas soluções. Se  $v_j^{max}$  é muito baixa, as partículas não podem explorar suficientemente além de soluções locais (SINGH *et al.*, 2013).

As constantes  $C_1$  e  $C_2$  representam a ponderação dos termos de aceleração estocásticos que puxam cada partícula em direção ao  $P_{ij}^r$ ,  $G_{jr}$ . Baixos valores permitem que as partículas se desloquem para longe da região de destino antes de serem atraídas de volta. Por outro lado, valores elevados resultam um movimento abrupto na direção ou passando das regiões-alvo. (SINGH *et al.*, 2013).

A equação generalizada (5.24) pode ser atualizada, a fim de encontrar um novo valor de velocidade, considerando a melhor posição global e melhor partícula, como descrito na Eq. (5.27).

$$v_{ij}^{new} = W \times v_{ij} + C_1 \times R_1 \times (P_{ij}^{best} - P_{ij}) + (C_2 \times R_2 \times (G_j^{best} - P_{ij})) \quad (5.27)$$

Agora, as novas posições Eq. (5.27) são atualizadas usando como na Eq. (5.28).

$$P_{ij}^{new} = P_{ij} + v_{ij}^{new} \quad (5.28)$$

$$(i = 1, 2, \dots, NP; j = 1, 2, \dots, NG)$$

Na estratégia de PSO, a melhor posição da partícula  $P_{ij}^{best}$ , e a melhor posição global  $G_j^{best}$  são os principais fatores. A melhor posição  $P_{ij}^{best}$  para fora de tudo é tomada como  $G_j^{best}$ . Seleções adequadas de peso e de inércia em Eq. (5.29) proporcionam um equilíbrio entre explorações globais e locais exigindo, menos iterações, em média, para encontrar uma solução suficientemente ideal. Como originalmente desenvolvido,  $W$  muitas vezes diminuir linearmente sobre 0,9 para 0,4 durante uma execução. Em geral o peso  $W$  de inércia é definido de acordo com a seguinte equação Eq. (5.29) (SINGH *et al.*, 2013).

$$W = W^{max} - \frac{W^{max} - W^{min}}{IT^{max}} \times IT \quad (5.29)$$

onde:  $IT^{max}$  é o número máximo de iterações (gerações) e  $IT$  é o número corrente de iterações.

PSO é um dos algoritmos heurísticos modernos, adequados para resolver problemas de otimização não-convexo de grande escala. É um algoritmo de busca de base populacional e pesquisa em paralelo utilizando um grupo de partículas (PARK *et al.*, 2010).

A ideia principal do PSO é que “partículas” (soluções) se movem através do espaço de busca com velocidades que são ajustados dinamicamente de acordo com o seu comportamento histórico. Por conseguinte, as partículas têm uma tendência para se moverem para uma melhor área de pesquisa ao longo do processo de pesquisa (IDOUMGHAR *et al.*, 2013).

### 5.3.6 Algoritmo Colônia de Abelhas Artificial (ABC)

O algoritmo de colônia de abelhas artificial (ABC) (KARABOGA, 2005), é um algoritmo proposto para a otimização de parâmetros reais, onde simula o comportamento inteligente de alimentação de um enxame de abelhas, é uma das técnicas de otimização baseadas em enxame mais recentemente introduzidas (AYDIN *et al.*, 2014).

Neste modelo inteligente de busca coletiva, as abelhas são classificadas como operárias, espectadoras e exploradoras (BEHERA *et al.*, 2015).

O Algoritmo ABC consiste basicamente em quatro fases: iniciação, abelhas operárias, abelhas espectadoras e a etapa das abelhas exploradoras. Na etapa de inicialização do algoritmo, a população é gerada e outros parâmetros sobre o algoritmo são inicializados. Após a inicialização, o algoritmo tenta resolver os problemas de otimização dentro do ciclo que é constituído por três outros passos. As principais etapas básicas da Metaheurística ABC são explicadas em detalhes a seguir (AYDIN *et al.*, 2014):

#### a. Inicialização

Nesta etapa, os números de fontes de alimentos  $SN$  são colocados aleatoriamente no  $D$ -dimensional espaço do problema, Eq. (5.30):

$$X_{ij} = X_{ij}^{min} + rand[0,1](X_{ij}^{max} - X_{ij}^{min}) \quad (5.30)$$

onde  $X_{ij}^{min}$  e  $X_{ij}^{max}$  refere-se a intervalos mínimos e máximos da  $i_{th}$  fonte de alimento na  $j$  dimensão, respectivamente. No ABC, cada local de alimentação apresenta uma solução para o problema, e a quantidade de néctar em cada fonte de alimento é assumida como o valor de *fitness* do local de alimentação. O tamanho da população da colônia de abelhas é considerado para ser o dobro do número de fontes de alimentos. Metade delas são as abelhas empregadas e a outra metade é constituída por abelhas espectadoras. Além disso, um valor de parâmetro limite também é inicializado para cada fonte de alimento. Isto contribui para a colônia determinar quando uma fonte de alimento deve ser abandonada (AYDIN *et al.*, 2014).

#### b. Passo Abelhas Operárias

Neste passo, cada abelha operária visita sucessivamente uma fonte de alimento. Cada abelha pesquisa na vizinhança da fonte de alimento selecionada (referência), para encontrar melhores localizações. Para encontrar um novo local candidato de alimentação,  $v_i$ , a seguinte equação de busca é utilizada tirando aleatoriamente vantagem da localização das fontes de alimentos (AYDIN *et al.*, 2014):

$$v_{ij} = X_{ij} + \Phi_{ij}(X_{ij} - X_{kj}), i \neq k \quad (5.31)$$

onde  $k \in \{1, 2, \dots, SN\}$ ,  $j \in \{1, 2, \dots, D\}$  ( $D$  denota a dimensão do problema),  $\Phi_{ij}$  é um número aleatório uniforme entre  $[-1, 1]$ ,  $X_{ij}$ , e  $X_{kj}$  são os locais de referência da  $i$ th fonte de alimentação e a fonte de alimento selecionado aleatoriamente na dimensão  $j$ , respectivamente. Quando a fonte de alimento candidata é encontrada pela Eq. (5.31),  $v_{ij}$ , for melhor do que a da referência ( $X_{ij}$ ), a fonte de alimento de referência é substituída pela fonte de alimento candidata.

### c. Passo Abelhas Espectadoras

As abelhas selecionam fontes de alimento para visitar e procuram os novos locais de origem alimentar utilizando a Eq. (5.31) como fazem as abelhas operárias. Mas, ao contrário das abelhas operárias, as abelhas espectadoras tomam uma quantidade de néctar nas fontes de alimento enquanto selecionam a fonte de alimento para visitar. A maior quantidade de néctar, ou melhor, valor de *fitness*, tem a maior probabilidade de ser eleita por uma abelha espectadora. A probabilidade de seleção de uma fonte de alimento  $i$ ,  $p_i$  é calculado como se segue (AYDIN *et al.*, 2014):

$$p_i = \frac{fitness_i}{\sum_{k=1}^{SN} fitness_k} \quad (5.32)$$

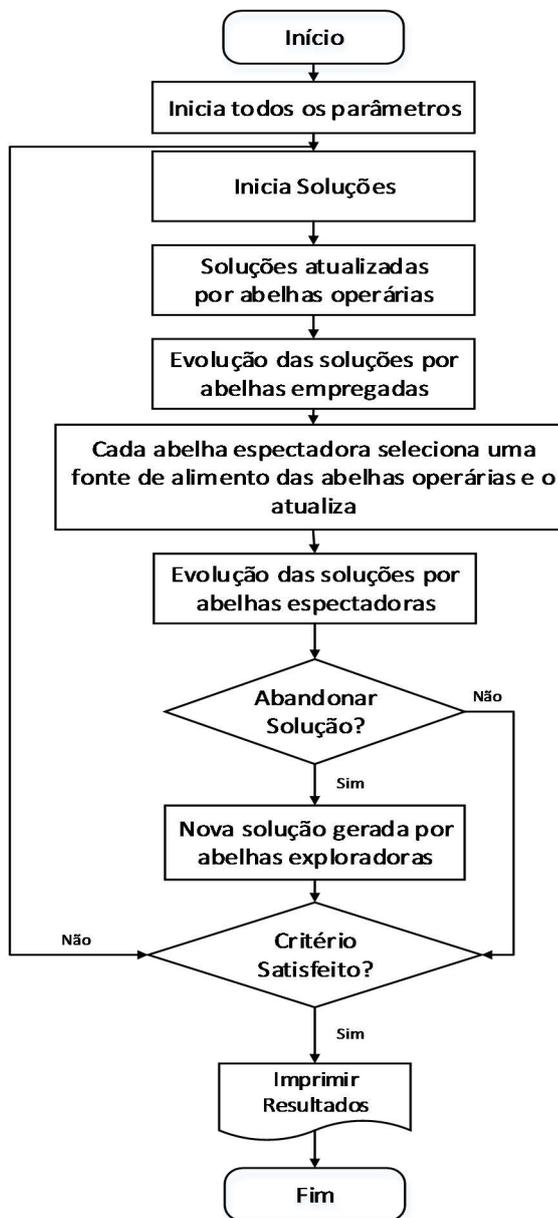
Na Eq. (5.32),  $fitness_i$  é o valor de aptidão da fonte de alimento  $i$ th sendo necessário um valor inversamente proporcional ao seu valor objetivo em função de problemas de minimização. Graças a esta regra de seleção probabilística, abelhas espectadoras costumam visitar melhores fontes de alimento e tentam encontrar novos locais de alimentação candidatos em torno de boas fontes de alimento. O Passo abelhas espectadoras desempenha um papel importante na intensificação do comportamento do algoritmo (AYDIN *et al.*, 2014).

### d. Passo Abelhas Exploradoras

Se várias vezes abelhas espectadoras e operárias não poderem melhorar a localização de uma fonte de alimento, a fonte de alimento atinge seu limite de visita. Estes tipos de fontes de alimentos são considerados ruins o suficiente para procura no entorno, de modo que a colônia decide abandoná-lo, usando o parâmetro de limite de controle. Neste caso, as exploradoras tentam encontrar uma nova fonte de alimento em substituição da fonte de alimento abandonado. Um novo local de origem alimentar é determinado pela Eq. (5.30) como definido na inicialização. Estes mecanismos de abandono e exploração auxiliam o algoritmo para sair de ótimos locais.

O método sequencial do algoritmo ABC pode ser visualizado como na figura 5.9.

Figura 5.9 – Sequência do algoritmo ABC.



Fonte: Adaptado de (BANHARNSAKUN *et al.*, 2010).

O algoritmo ABC é uma abordagem metaheurística em que uma ABC coopera em encontrar boas soluções para problemas de otimização numérica. O ABC é amplamente adotado para uso em diversos domínios da solução de otimização (BANHARNSAKUN *et al.*, 2010).

Comparado com outros algoritmos de evolutivos, o ABC é um método simples e conveniente, com menos parâmetros de controle, o que demonstrou alta eficiência na resolução de problemas de otimização com características não lineares e não convexas (LU *et al.*, 2014).

### 5.3.7 Recozimento Simulado (RS)

O recozimento simulado (RS) (KIRKPATRICK *et al.*, 1983), é uma técnica poderosa de otimização que explora a semelhança entre um processo de minimização e o arrefecimento do metal fundido. O processo físico de recozimento é simulado na técnica RS para a determinação das melhores soluções globais ou quase globais para problemas de otimização. Neste algoritmo, é definido um parâmetro  $T$ , chamado de temperatura. A partir de uma temperatura elevada, de um metal fundido é arrefecido lentamente até que é solidificado a uma temperatura baixa. O número de iterações na técnica RS é semelhante ao nível de temperatura. Em cada iteração, uma solução candidata é gerada. Se esta solução é uma solução melhor, irá ser aceita e utilizada para gerar ainda outra solução candidata. Se for uma solução deteriorada, a solução será aceita quando a sua probabilidade de aceitação  $Pr(\Delta)$ , dada pela Eq. (5.33) for maior do que um número gerado aleatoriamente entre 0 e 1 (BASU, 2005).

$$Pr(\Delta) = \exp(-\Delta/T) \quad (5.33)$$

onde,  $\Delta$  é a quantidade de degradação entre a nova solução e as soluções atuais e  $T$  é a temperatura à qual a nova solução é gerada.

Aceitando soluções deterioradas, da maneira acima, permite que a solução RS “salte” para fora dos pontos de soluções ótimos locais e procure a melhor solução global. Na formação da nova solução, a atual é perturbada de acordo com a função de distribuição de probabilidade Gaussiana (GPDF). A média da GPDF é considerada como sendo a solução atual e o seu desvio padrão é dado pelo produto da temperatura e um fator de escala  $\sigma$ . O valor de  $\sigma < 1$ , e em conjunto com o valor da temperatura que regula o tamanho do espaço de vizinhança da solução atual e, conseqüentemente, a quantidade de perturbações. A nova solução é formada por adição da quantidade de perturbações para a solução atual. A quantidade de perturbações é dependente da temperatura, quando  $\sigma$  é mantido a um valor constante. Numa iteração, o procedimento para gerar e testar a solução candidato é repetido por um número especificado de tentativas. A última solução aceita como candidata é então tomada como a solução de partida para a geração de soluções candidatas na iteração seguinte. A redução da temperatura nas iterações sucessivas é regida pela seguinte função geométrica Eq. (5.34) (BASU, 2005).

$$T_v = r^{(v-1)}T_0 \quad (5.34)$$

Onde,  $v$  é o número de iteração e  $r$  é o fator de redução da temperatura.  $T_0$  é o valor da temperatura inicial, que pode ser definido arbitrariamente ou estimado. O processo iterativo é

terminado quando não há uma melhoria significativa na solução depois de um número pré-especificado de iterações. Ele também pode ser terminado quando o número máximo de iterações é alcançado (BASU, 2005).

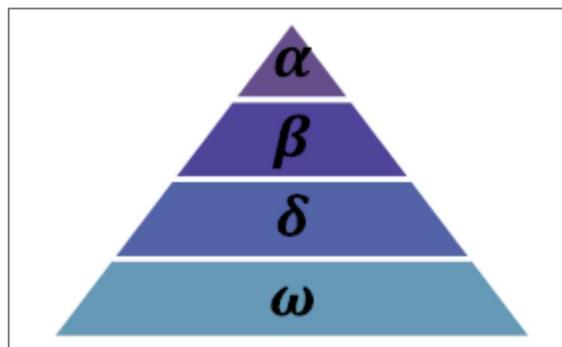
O método RS converge assintoticamente para a solução ótima global, com probabilidade um, desde que certas condições sobre a função de custo, os movimentos, bem como o calendário de recozimento estejam satisfeitos (BEHERA *et al.*, 2015).

### 5.3.8 Grey Wolf Optimizer (GWO)

A natureza sempre foi uma fonte de inspiração para os cientistas. Mirjalili, (2014), concebeu a ideia de imitar a hierarquia social de liderança e o comportamento de caça dos lobos cinzentos em problemas de otimização, designando a técnica resultante como otimização lobo cinzento (GWO) (SONG *et al.*, 2015).

Lobo cinzento (*Canis lupus*) pertence à família *Canidae*. Os lobos cinzentos são considerados predadores, o que significa que eles estão no topo da cadeia alimentar. Os lobos cinzentos em sua maioria preferem viver em um bando. O tamanho do grupo é, em média, 5 a 12 indivíduos. De particular interesse é que eles têm uma hierarquia social dominante muito estrita como mostra a figura 5.10 (MIRJALILI *et al.*, 2014).

Figura 5.10 - Hierarquia de caça dos lobos cinzentos.



Fonte: (MIRJALILI *et al.*, 2014).

GWO, é uma técnica recém-chegada entre os algoritmos de otimização por enxame inteligente de base populacional, é caracterizado por várias vantagens atraentes: simplicidade, flexibilidade, mecanismo livre de derivação e evita ótimos locais. Além disso, é de fácil implementação com menos parâmetros de controle para ajustar, e tem uma característica de convergência rápida (SONG *et al.*, 2015):

A simplicidade permite que cientistas da computação simulem conceitos naturais e desenvolvam o algoritmo de forma mais eficaz. Além disso, a simplicidade auxilia outros cientistas para aprender o algoritmo de forma rápida e aplica-lo a seus problemas.

A flexibilidade refere-se a aplicabilidade de GWO em diferentes problemas, sem quaisquer alterações especiais na estrutura do algoritmo, uma vez que assume os problemas como caixas pretas.

A GWO tem mecanismos de livre derivação. Em contraste com as abordagens de otimização baseado em gradiente, GWO otimiza problemas estocasticamente. Esta pode ser efetivamente usada para resolver os problemas para os quais as funções objetivo não são diferenciáveis, estocásticas, ou mesmo descontínuas. Finalmente, GWO tem habilidades superiores para evitar ótimos locais em comparação com técnicas de otimização convencionais. Isso faz com que GWO seja altamente adequado para resolver problemas de otimização de funções não lineares, multivariados, multimodais (SONG *et al.*, 2015).

Mirjalili (2014), recentemente testou GWO em unimodal, multimodal, multimodal de dimensão-fixa e em funções compostas para referenciar seu desempenho em termos de exploração, evitando a convergência de ótimos locais. Demonstrou-se que o algoritmo GWO é capaz de fornecer resultados muito competitivos em comparação com outras metaheurísticas bem conhecidas: (SONG *et al.*, 2015).

Os modelos matemáticos da hierarquia social do algoritmo GWO, são descritos a seguir (MIRJALILI *et al.*, 2014):

#### **a. Hierarquia social**

Para modelar matematicamente sua hierarquia social ao projetar o GWO, a solução mais apta é considerada como o alfa ( $\alpha$ ). Por conseguinte, a segunda e terceira melhores soluções são respectivamente nomeadas como beta ( $\beta$ ) e delta ( $\delta$ ). Assumindo o restante das soluções candidatas como sendo os ômegas ( $\omega$ ). No algoritmo GWO, a caçada (otimização) é guiada por  $\alpha$ ,  $\beta$ , e  $\delta$ . Os lobos  $\omega$  seguem estes três lobos (MIRJALILI *et al.*, 2014).

## b. Cercando a presa

Além da hierarquia descrita anteriormente, cercar a presa durante a caçada é outro comportamento social interessante dos lobos cinzentos.

A fim de modelar matematicamente o comportamento de cercar a presa, as seguintes equações são propostas (MIRJALILI *et al.*, 2014):

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (5.35)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (5.36)$$

onde  $t$  indica a iteração corrente;  $\vec{A}$  e  $\vec{C}$  são vetores de coeficientes;  $\vec{X}_p$  é o vetor de posição da presa; e  $\vec{X}$  indica o vetor de posição de um lobo (MIRJALILI *et al.*, 2014).

Os vetores  $\vec{A}$  e  $\vec{C}$  são calculados como se segue:

$$\vec{A} = \vec{a} \cdot (2\vec{r}_1 - 1) \quad (5.37)$$

$$\vec{C} = 2\vec{r}_2 \quad (5.38)$$

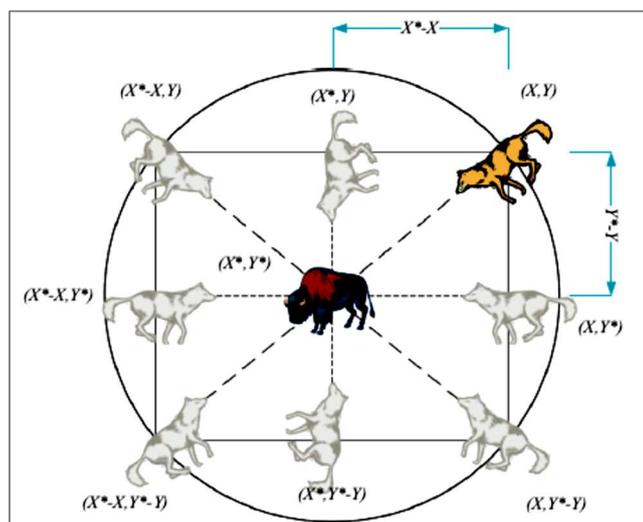
onde:

$\vec{a}$  é linearmente decrementado de 2 para 0 ao longo das iterações;

$r_1, r_2$  são valores aleatórios no intervalo de  $[0,1]$ .

Para verificar os efeitos das Eqs. (5.35) e (5.36), um vetor de posição bidimensional e alguns dos possíveis vizinhos estão ilustrados na figura 5.11.

Figura 5.11 - Vetor de posicionamento bidimensional e alguns dos possíveis vizinhos.

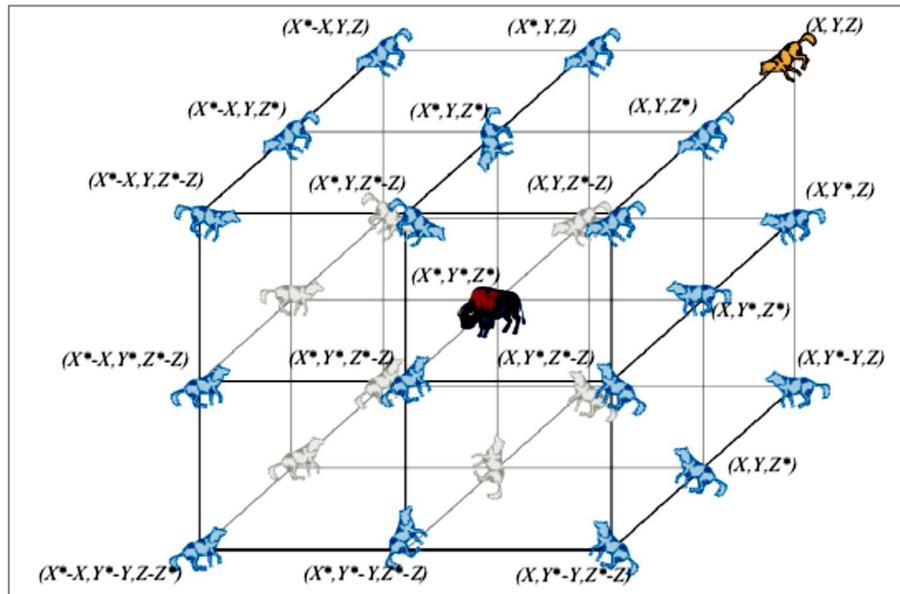


Fonte: (MIRJALILI *et al.*, 2014).

Como pode ser visto na figura 5.11, um lobo cinzento na posição de  $(X, Y)$  pode atualizar a sua posição de acordo com a posição da presa  $(X^*, Y^*)$ . Diferentes locais em torno do melhor agente podem ser alcançados no que diz respeito à posição atual, ajustando o valor dos vetores  $\vec{A}$  e  $\vec{C}$  (MIRJALILI *et al.*, 2014).

As possíveis posições atualizadas de um lobo cinzento no espaço 3D estão representadas na figura 5.12.

Figura 5.12 - Possíveis posições no espaço 3D.



Fonte: (MIRJALILI *et al.*, 2014).

Note que os vetores aleatórios de lobos  $r_1$  e  $r_2$  permitem chegar a qualquer posição entre os pontos ilustrados na figura 5.12. Então, um lobo cinzento pode atualizar sua posição dentro do espaço ao redor da presa em qualquer local aleatório usando Eqs. (5.42) e (5.43) (MIRJALILI *et al.*, 2014).

### c. Caçando

Os lobos cinzentos têm a capacidade de reconhecer a localização da presa e cercá-la. A caçada é geralmente guiada pelo alfa. O beta e delta pode também participar na caçada ocasionalmente. No entanto, em um espaço de busca abstrato não se tem ideia sobre a localização do ótimo (presa). Para simular matematicamente o comportamento de caça dos lobos cinzentos, supõe-se que o alfa (melhor solução candidato), beta e delta têm melhor conhecimento sobre a localização potencial da presa. Por isso, as primeiras três melhores soluções obtidas até agora são salvas e obriga-se os outros agentes de pesquisa (incluindo os

ômeegas) a atualizarem suas posições, de acordo com a posição dos melhores agentes de pesquisa. As Eqs. (5.39, 5.40 e 5.41) são propostas.

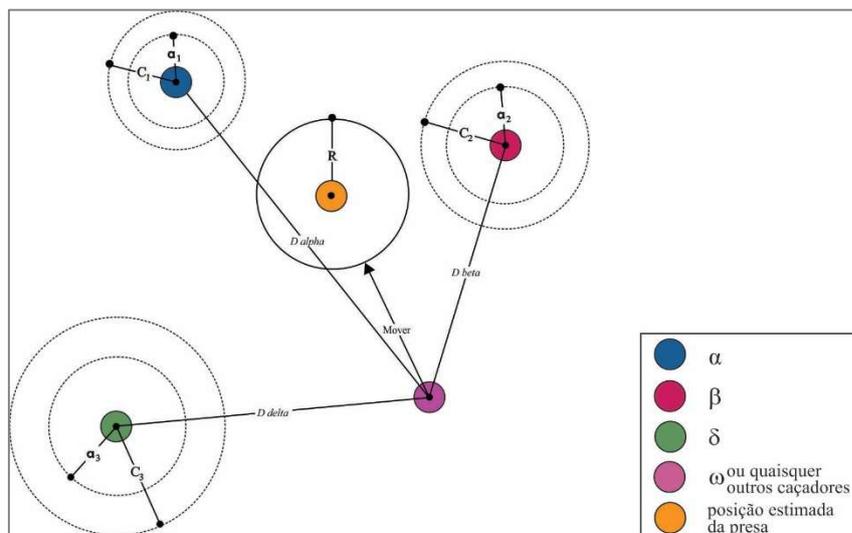
$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (5.39)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (5.40)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (5.41)$$

A figura 5.13, mostra como um agente de pesquisa atualiza sua posição de acordo com alfa, beta e delta num espaço de busca 2D. Pode-se observar que a posição final seria em um lugar aleatório dentro de um círculo que é definido pelas posições de alfa, beta e delta no espaço de busca. Em outras palavras alfa, beta e delta, estimam a posição da presa, e os outros lobos atualizam suas posições aleatoriamente ao redor da presa (MIRJALILI *et al.*, 2014).

Figura 5.13 - Posição atualização em GWO.

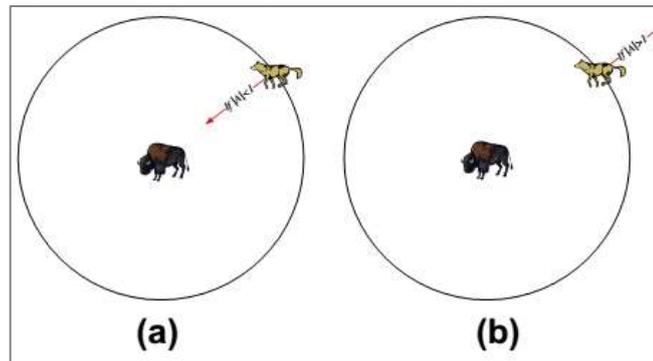


Fonte: Adaptado de (MIRJALILI *et al.*, 2014).

#### d. Atacar presas (*exploitation*)

Como mencionado acima, os lobos cinzentos terminam a caça ao atacar a presa quando ela para de se mover. Para modelar matematicamente a aproximação da presa, diminui-se o valor de  $\vec{a}$ . Note-se que o intervalo de flutuação de  $\vec{A}$  é também diminuído por  $\vec{a}$ . Em outras palavras  $\vec{A}$  é um valor aleatório no intervalo  $[-2a, 2a]$  onde  $\vec{a}$  é diminuído de 2 a 0 ao longo das iterações. Quando os valores aleatórios de  $\vec{A}$  estão em  $[-1, 1]$ , a próxima posição de um agente de busca pode estar em qualquer posição entre a sua posição atual e a posição da presa. A figura 5.14 (a) mostra que  $|A| < 1$  obriga os lobos ao ataque em direção à presa (MIRJALILI *et al.*, 2014).

Figura 5.14 - Atacando presas versus à procura de presas.



Fonte: (MIRJALILI *et al.*, 2014).

Com os operadores propostos até agora, o algoritmo GWO permite aos seus agentes de busca atualizar a sua posição com base na localização do alfa, beta e do delta, e atacam a presa. Contudo, o algoritmo GWO é propenso a estagnação em soluções locais com estes operadores. É verdade que o mecanismo de cerco proposto mostra exploração até certo ponto, mas o GWO necessita de mais operadores para enfatizar a exploração (numa área mais abrangente).

#### e. Busca por presas (*exploration*)

Os lobos cinzentos principalmente pesquisam de acordo com a posição do alfa, beta e do delta. Eles divergem entre si para procurar presas e convergem para atacar a presa. A fim de modelar matematicamente essa divergência, é utilizado  $\vec{A}$  com valores aleatórios maiores que 1 ou menor que -1 para obrigar o agente busca a divergir da presa. Isso enfatiza a busca fora da vizinhança e permite ao algoritmo procurar globalmente. A figura 5.14 (b) mostra também que  $|A| > 1$  força os lobos cinzentos a divergir da presa para encontrar esperançosamente uma presa mais simples (MIRJALILI *et al.*, 2014).

Outro componente do GWO que favorece a exploração é  $\vec{C}$ . Como pode ser visto na Eq. (5.43), o vetor  $\vec{C}$  contém valores aleatórios no intervalo  $[0, 2]$ . Este componente fornece pesos aleatórios para a presa, a fim de estocasticamente enfatizar ( $C > 1$ ) ou desenfatar ( $C < 1$ ) o efeito de presa na definição da distância Eq. (5.42). Isto ajuda o GWO a mostrar um comportamento mais aleatório durante toda a otimização, favorecendo a exploração e evitar ótimos locais (MIRJALILI *et al.*, 2014).

O GWO é poderoso em termos de prospecção, exploração, evitar ótimos locais, e de convergência que motivam o uso deste algoritmo para problemas de otimização (SHARMA e SAIKIA, 2015).

O GWO foi provado ser competitivo comparado com os outros algoritmos de otimização que inclui algoritmo de busca gravitacional (GSA), evolução diferencial (DE) e muitos outros (SULAIMAN *et al.*, 2015).

### 5.3.9 Multiobjetivo NSGA-III (NSGA-III)

A estrutura básica da proposta do Multiobjetivo NSGA-II (ou NSGA-III) é semelhante ao algoritmo NSGA-II, com mudanças significativas no seu operador de seleção. Mas, ao contrário de NSGA-II, a manutenção da diversidade entre os membros da população em NSGA-III é auxiliada pelo fornecimento e adaptação de um número atualizado de pontos de referência de forma bem distribuída. Em NSGA-III, foi substituído o operador de distância de aglomeração com as seguintes abordagens (DEB e JAIN, 2014):

#### a. Classificação da População em níveis Não-dominados

Em NSGA-III, o procedimento para identificar frentes não-dominadas é o habitual princípio de domínio (GITIZADEH e AGHAEI, 2013). Todos os membros da população a partir do nível da frente não-dominada 1 para o nível  $l$  são primeiro incluídos no  $S_t$ . E se  $|S_t| = N$ ; operações adicionais não serão necessárias e a próxima geração é iniciada com  $P_{t+1} = S_t$ . Para  $|S_t| > N$ , Membros das frentes de um a  $l - 1$  já estão selecionados, ou seja,  $P_{t+1} = \cup_{i=1}^{l-1} F_i$ , e o restante dos membros da população é escolhido a partir da última frente  $F_l$  (DEB e JAIN, 2014).

#### b. Determinação de Pontos de Referência em um Hyper-Plane

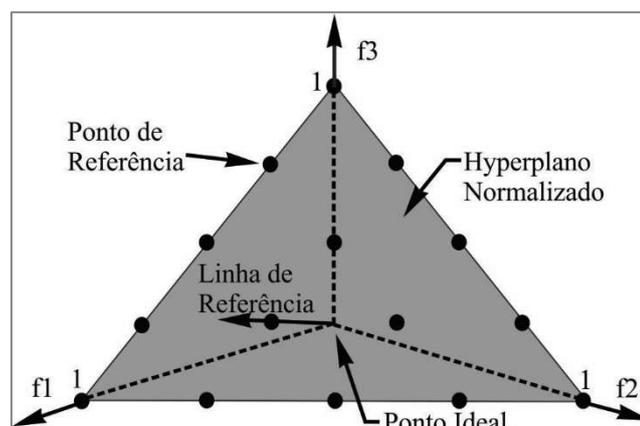
O NSGA-III utiliza um conjunto predefinido de pontos de referência para assegurar a diversidade em soluções obtidas. Os pontos de referência escolhidos podem ser predefinidos de forma estruturada ou fornecida preferencialmente pelo usuário. Na ausência de qualquer informação preferencial, qualquer colocação estruturada de pontos de referência predefinidos pode ser adotada. Abordagem sistemática que coloca pontos num normalizado *hyper-plane* de  $(M - 1)$  unidade dimensional simples, que é igualmente inclinado a todos os eixos objetivo e tem uma intercepção de um em cada eixo. Se  $p$  divisões são consideradas ao longo de cada objetivo, o número total de pontos de referência ( $H$ ) num problema  $M$ -objetivo é dado pela Eq. (5.42) (DEB e JAIN, 2014).

$$H = \binom{M+p-1}{p} \quad (5.42)$$

Por exemplo, num problema de três objetivos  $M = 3$ , os pontos de referência são criados em um triângulo com o vértice em  $(1, 0, 0)$ ,  $(0, 1, 0)$  e  $(0, 0, 1)$ . Se quatro divisões ( $p = 4$ ) são

escolhidas para cada eixo objetivo  $H = \binom{3+4-1}{4}$  ou 15 pontos de referência serão criados. Para esclarecer, estes pontos de referência estão apresentados na figura 5.13. Na proposta do NSGA-III, para além de soluções enfatizando a não-dominância, é enfatizado os membros da população que estão, de alguma forma associada a cada um desses pontos de referência. Uma vez que os pontos de referência acima são criados, normalizados e amplamente distribuídos em todo o *hyper-plane*, as soluções obtidas também são suscetíveis de ser amplamente distribuídas em ou perto da frente de Pareto. No caso de um conjunto de pontos de referência preferenciais fornecido pelo usuário, o ideal é que o usuário possa marcar pontos sobre o *hyper-plane* normalizado ou indicar qualquer  $H$ , vetores de  $M$ -dimensões para o efeito. O algoritmo proposto é suscetível de encontrar soluções perto do ótimo de Pareto correspondentes aos pontos de referência fornecidos, permitindo assim que este método seja utilizado mais para uma aplicação combinada de tomada de decisão e de otimização de muitos objetivos (DEB e JAIN, 2014).

Figura 5.15 - Quinze pontos de referência estruturados em um plano de referência normalizado para um problema de três objetivos com  $p = 4$ .



Fonte: Adaptado de (DEB e JAIN, 2014).

### c. Normalização Adaptativa dos Membros da População

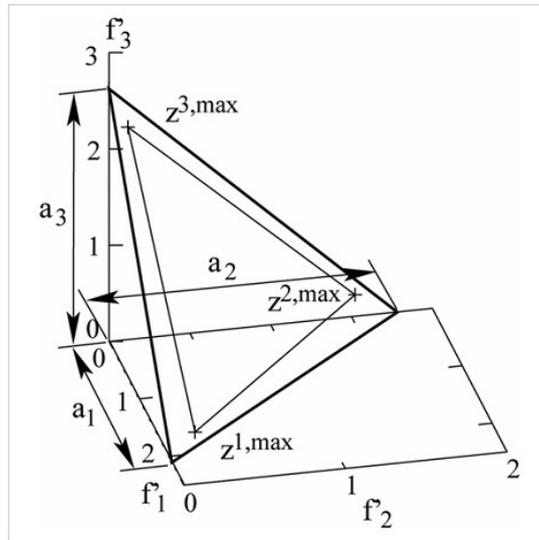
Em primeiro lugar, o ponto de ideal da população  $S_t$  é determinado através da identificação do valor mínimo  $z_i^{min}$  para cada função objetivo  $i = 1, 2, \dots, M$  dentro de  $\cup_{T=0}^t S_t$  e construindo o ponto ideal  $\bar{z} = (z_1^{min}, z_2^{min}, \dots, z_M^{min})$ . Cada valor objetivo de  $S_t$  é então traduzido por subtração do objetivo  $f_i$  por  $z_i^{min}$  de modo que o ponto ideal da tradução  $S_t$  torne-se um vetor zero. Denota-se este objetivo traduzido como  $f'_i(x) = f_i(x) - z_i^{min}$ . Depois disso, o ponto extremo  $z_i^{max}$  em cada ( $i_{th}$ ) eixo objetivo é identificado por encontrar a solução ( $x \in S_t$ ) que faz a correspondente realização da função de escalarização (formada com  $f'_i(x)$  e um vetor de peso perto eixo objetivo  $i_{th}$ ) mínima. Estes vetores extremos  $M$  são então utilizados para

constituir uma  $M$ -dimensão *hyper-plane*. A intercepção do eixo objetivo  $i_{th}$  e a linear *hyper-plane* pode então ser calculada (ver figura 5.16). Um cuidado especial é tomado para lidar com casos degenerados e interceptos não negativos. As funções objetivo podem então ser normalizadas como (DEB e JAIN, 2014):

$$f_i^n(x) = \frac{f_i'(x)}{a_i}, \text{ para } i = 1, 2, \dots, M \quad (5.43)$$

Note-se que a intercepção em cada eixo objetivo normalizado está agora em  $f_i^n = 1$ , e um *hyper-plane* construído com esses pontos de intercepção fará  $\sum_{i=1}^M f_i^n = 1$ .

Figura 5.16 - Procedimento para calcular intercepto e, em seguida, formar a *hyper-plane* de pontos extremos, para um problema de três objetivos.



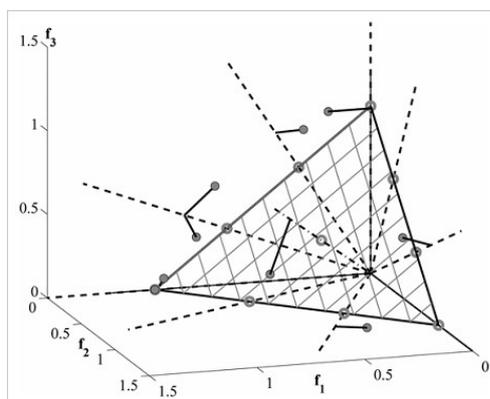
Fonte: (DEB e JAIN, 2014).

#### d. Operação de Associação

Após a normalização de cada objetivo adaptativamente com base na extensão de membros de  $S_t$  no espaço de objetivos, precisa-se associar cada membro da população com um ponto de referência. Para este fim, define-se uma linha de referência correspondente a cada ponto de referência sobre a *hyper-plane*, unindo o ponto de referência com a origem. Em seguida, calcula-se a distância na perpendicular de cada um dos membros da população  $S_t$  a partir de cada uma das linhas de referência.

O ponto de referência cuja linha de referência está mais próxima de um membro da população no espaço objetivo normalizado é considerado para ser associado ao membro de população. Isto é ilustrado na figura 5.17 (DEB e JAIN, 2014).

Figura 5.17 - Associação dos membros da população com pontos de referência.



Fonte: (DEB e JAIN, 2014).

### e. Operação Nicho-Preservação

Vale a pena notar que um ponto de referência pode ter um ou mais membros da população associados ou não precisa ter qualquer membro da população associado a ele. Conta-se o número de membros da população de  $P_{t+1} = S_t/F_l$  que estão associados com cada ponto de referência. Denota-se essa contagem de nicho como  $p_j$  para o ponto de referência  $i_{th}$ . Elaborar-se uma nova operação de preservação de nicho como segue. Em primeiro lugar, identificar o conjunto de pontos de referência  $J_{mim} = \{j: argmin_j p_j$  tendo mínimo  $p_j$ . No caso de vários desses pontos de referência, um  $\bar{j} \in J_{mim}$  é escolhido aleatoriamente (DEB e JAIN, 2014).

Se  $p_j = 0$  (significa que não há nenhum membro  $P_{t+1}$  associado para o ponto de referência), Pode haver dois cenários com  $\bar{j}$  em conjunto com  $F_l$ . Em primeiro lugar, existe um ou mais membros na frente  $F_l$  que estão associados com o ponto de referência  $\bar{j}$ . Neste caso, o que tem a menor distância perpendicular a partir da linha de referência é adicionado para  $P_{t+1}$ . A contagem  $p_j$  para o ponto de referência  $\bar{j}$  é então incrementada em um. Em segundo lugar, a frente  $F_l$  não tem qualquer membro relacionado com o ponto de referência  $\bar{j}$ . Neste caso, o ponto de referência é excluído de considerações adicionais para a geração atual.

No evento de  $p_j > 1$  (significa que já existe um membro associado com o ponto de referência no  $S_t/F_l$ ), um membro escolhido aleatoriamente, se existe, da frente  $F_l$  que está associado com o ponto de referência  $\bar{j}$  é adicionado para  $P_{t+1}$ . A contagem  $p_j$  é então incrementada em um. Depois de atualizadas as contagens de nicho, o procedimento é repetido para um total de  $K$  vezes para preencher todos os slots vagos da população  $P_{t+1}$  (DEB e JAIN, 2014).

#### **f. Operações genéticas para criar População Descendente (Offspring)**

Depois de formado  $P_{t+1}$ , que é então utilizado para criar uma nova população descendente  $Q_{t+1}$ , através da aplicação de operadores genéticos habituais. Em NSGA-III, que já executou uma cuidadosa seleção elitista de soluções e tentou manter a diversidade entre as soluções, enfatizando soluções mais próximas à linha de referência de cada ponto de referência. Além disso, por um procedimento computacionalmente rápido, tem-se um conjunto  $N$  quase igual  $H$ , Esperando, assim, evoluir um membro da população perto da frente de Pareto correspondente a cada ponto de referência. Por todas estas razões, não se emprega qualquer operação de reprodução explícita com NSGA-III para o tratamento de problemas com únicas restrições de caixa. A população  $Q_{t+1}$  é construída através da aplicação dos operadores de cruzamento e mutação habituais, escolhendo aleatoriamente os pais de  $P_{t+1}$ . No entanto, para criar soluções descendentes mais perto das soluções-mãe (DEB e JAIN, 2014).

#### **g. Propriedade de menos parâmetros do NSGA-III**

Como em NSGA-II, o algoritmo NSGA-III não exige a criação de qualquer novo parâmetro para além dos parâmetros dos AGs habituais, tais como o tamanho da população, o parâmetro de termino, *crossover* e probabilidades de mutação, e seus parâmetros associados. O número de pontos de referência  $H$  não é um parâmetro algorítmico, pois isso está diretamente relacionado com o número desejado de pontos de *trade-off*. O tamanho da população  $N$  é dependente em  $H$ , Como  $N \approx H$ . A localização dos pontos de referência é igualmente dependente da informação preferência que o usuário está interessado em alcançar em soluções obtidas (DEB e JAIN, 2014).

### **5.4 Conclusões do capítulo**

No presente capítulo foram descritos vários métodos Determinísticos e Heurísticos utilizados nesta tese para a otimização dos problemas do DE e do DEA, os quais serão testados no capítulo seguinte de resultados. Diversos outros métodos heurísticos podem ser adotados para resolver o problema de otimização do DE/DEA, como por exemplo: *Tabu Search* (KOCHENBERGER *et al.*, 2013); *Novel Bat Algorithm* (MENG *et al.*, 2015); *Cuckoo search algorithm* (NGUYEN *et al.*, 2016); *Kinetic gas molecule* (BASU, 2016); *Ant lion optimization* (DUBEY *et al.*, 2016) e etc..

---

## CAPÍTULO VI

---

### METODOLOGIA PARA NOVA SOLUÇÃO DE OTIMIZAÇÃO DO DE/DEA

#### 6.1 Introdução

A nova solução proposta para o problema de otimização do DE e do DEA, contempla o desligamento dos geradores com maior custo de combustível no momento da otimização para determinada demanda de potência. Nesta solução é considerado o custo incremental de combustível e as perdas de potência.

O estudo foi realizado no setor de geração de energia elétrica com dados de uma usina termoeletrica do Polo Industrial de Manaus (PIM).

Para o tratamento e análise dos dados, foi utilizada a ferramenta computacional MATLAB versão r2014b, micro-computador ASUS, processador Intel i7, com 8 GB de RAM, para a implementação dos diversos métodos computacionais tratados (MN, PQ, MIL Algoritmos Genéticos, Enxame de Partículas, Otimização por Lobo Cinzento, Evolução Diferencial, Recozimento Simulado, Colônias de Abelhas, NSGA-II e NSGA-III) para convalidar a metodologia proposta.

A presente pesquisa foi aplicada a um sistema térmico com motores a combustão interna, comparando com um sistema teste.

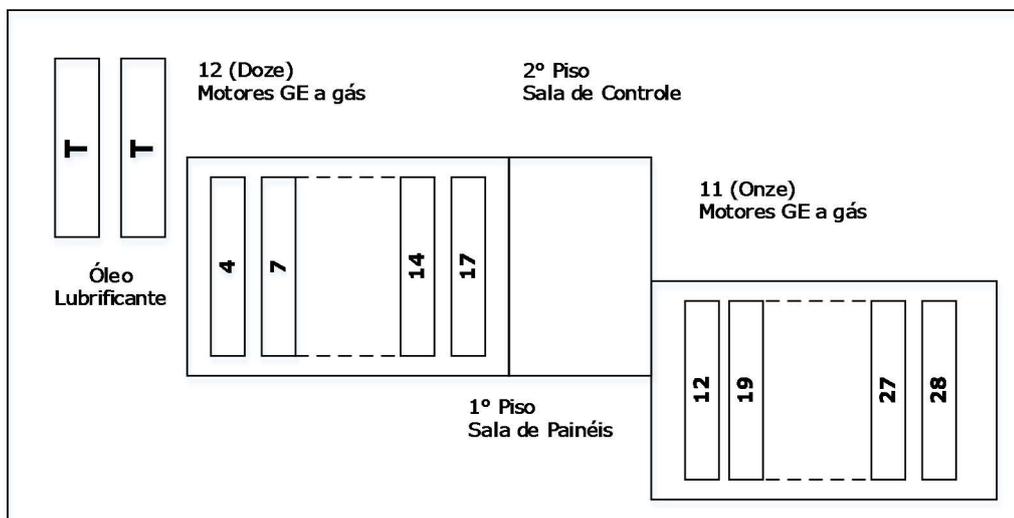
Este capítulo apresenta os parâmetros necessários para a comparação entre a solução tradicional e a nova solução que contempla o desligamento dos geradores de maior consumo de combustível.

#### 6.2 Características da Usina Termoeletrica (UTE) para o Estudo de Caso

A usina tem uma capacidade instalada de **155,778 MW**, sendo **62,741 MW** a óleo combustível, **17,56 MW** a óleo combustível e a gás natural (bicomcombustível) e **75,477 MW** a gás natural. Na UTE (estudo de caso) contém grupos geradores, auxiliares dos grupos, painéis elétricos de média e de baixa tensão, painéis de supervisão, controle e proteção, transformadores de serviços auxiliares, equipamentos principais do sistema de condicionamento de óleo combustível, óleo diesel e óleo lubrificante, equipamentos de tratamento de água, equipamentos de geração de vapor.

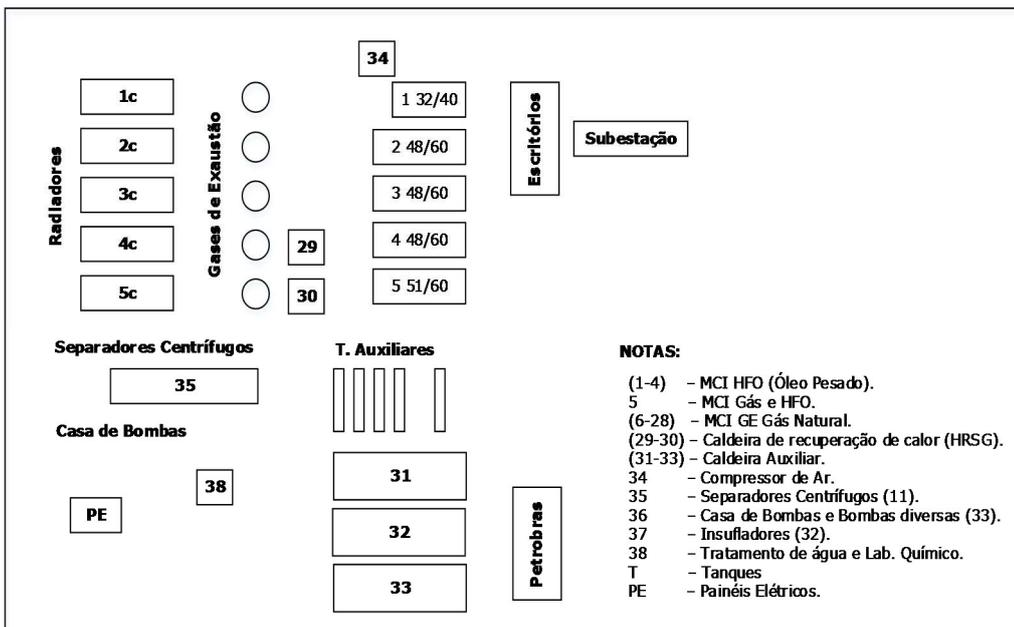
A Usina opera no ciclo OTTO a Gás Natural, sendo equipada com 23 (vinte e três) motores do tipo J620F111, configuração V60, com 20 cilindros com potência mecânica de saída de 3.431 kW e potência elétrica de saída de 3.293 kW e, fabricação GE Jenbacher (GEJ), acoplados aos geradores do tipo DIG 142 d/4 de fabricação AVK com potência nominal de 4.102 kVA, fator de potência 0,8, 13,8 kV, 60 Hz, 1800 rpm. O conjunto terá a capacidade de geração de 3.282 kW/4.102kVA em 13.800V com fator de potência 0,8. O seu diagrama unifilar geral pode ser visto no projeto BCO-TBQDE- ELE-003-UNIF da empresa Breitener, como mostra as Figuras 6.1, 6.2 e 6.3 (AZEVEDO, 2015).

Figura 6.1 - Diagrama Geral da Usina (a).



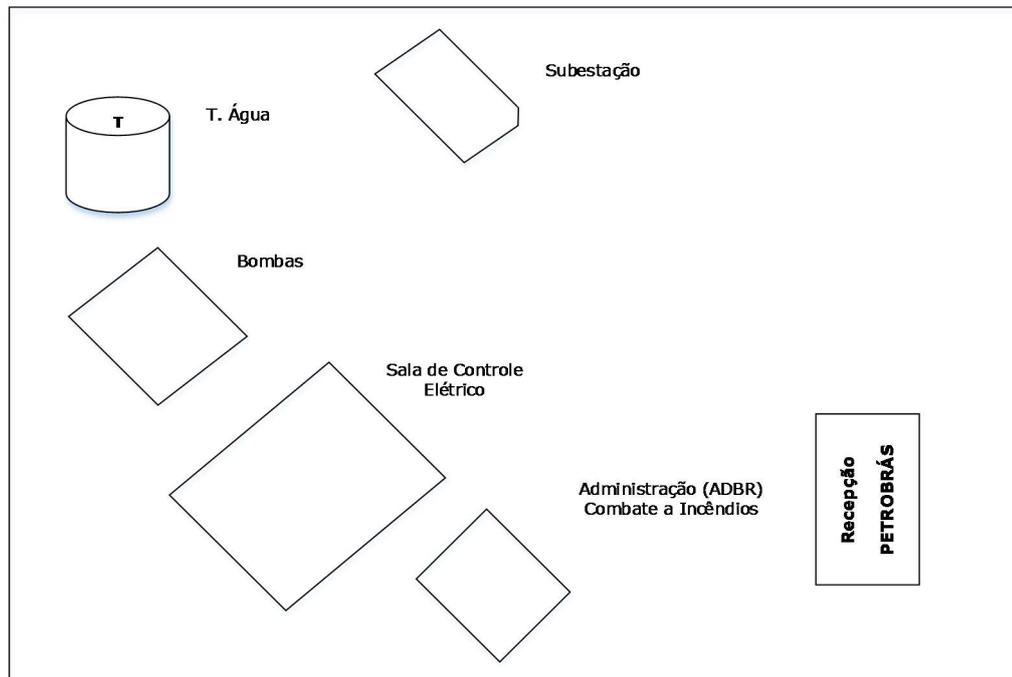
Fonte:(AZEVEDO, 2015).

Figura 6.2 - Diagrama Geral da Usina (b).



Fonte: (AZEVEDO, 2015).

Figura 6.3 - Diagrama Geral da Usina (c)



Fonte: (AZEVEDO, 2015).

A seguir, são listados os principais componentes desta instalação na Tabela 6.1:

Tabela 6.1 - Principais componentes.

Número	Descrição
1-4	Grupos geradores com Motores de Combustão Interna HFO
5	Grupo gerador com Motores de Combustão Interna Gás/HFO
6-28	Grupo gerador com Motores de Combustão Interna GE Gás
29,30	Caldeiras de recuperação de calor (HRSG)
31-33	Caldeiras auxiliares
34	Compressores de ar
35	Separadores centrifuga (11)
36	Casa de bombas e bombas diversas (33)
37	Insufladores (32)
38	Tratamento de água e laboratório químico
T	Tanque
PE	Sala de painéis elétricos
AS	Sala de controle

Fonte: O Autor, (2016).

### 6.2.1 Parâmetros de funcionamento da UTE – Estudo de Caso

Em particular, a UTE (estudo de caso), trabalha com uma demanda fixa de potência a ser gerada, a qual é menor do que sua capacidade máxima de geração, permitindo o desligamento dos geradores com maior consumo de combustível sem comprometer seu funcionamento. A planta de referência selecionada para o estudo de caso é composta por 10 geradores, denominados como (UGG1 à UGG10), como apresentado na tabela 6.2. Na primeira coluna, é mostrado o número das unidades geradoras, na segunda, na terceira e quarta estão os

coeficientes  $a_i$ ,  $b_i$ , e  $c_i$  e nas duas últimas, são mostrados a potência mínima e máxima de cada unidade geradora, ou seja:

1. Geradores
2. Coeficiente  $a_i$  (\$/MW<sup>2</sup>)
3. Coeficiente  $b_i$  (\$/MW)
4. Coeficiente  $c_i$  (\$)
5. Limite inferior de potência em (MW)
6. Limite superior de potência em (MW)

O número de linhas é igual ao número de geradores ( $n$ ).

Tabela 6.2 - Dados característicos dos geradores da planta.

Gerador	$c_i$ (\$/MW <sup>2</sup> )	$b_i$ (\$/MW)	$a_i$ (\$)	$P_{min}$ (MW)	$P_{max}$ (MW)
<b>UGG1</b>	0.007	7	240	0.66	3.35
<b>UGG2</b>	0.0095	10	200	0.9	3.7
<b>UGG3</b>	0.009	8.5	220	0.8	3.6
<b>UGG4</b>	0.009	11	200	0.66	3.35
<b>UGG5</b>	0.008	10.5	220	0.72	3.45
<b>UGG6</b>	0.0075	12	120	0.66	2.97
<b>UGG7</b>	0.0075	14	130	0.88	3.5
<b>UGG8</b>	0.0075	14	130	0.754	3.33
<b>UGG9</b>	0.0075	14	130	0.9	3.9
<b>UGG10</b>	0.0075	14	130	0.56	2.95

Fonte: (NASCIMENTO *et al.*, 2016).

Esses dados foram obtidos a partir das medições realizadas em campo (**Anexo I**), com o registro de consumo para diferentes percentuais de potência de cada gerador (60, 70, 80, 90 e 100%), e seus coeficientes especificados por meio de um método de regressão com auxílio do software *CurveExpert*.

Os coeficientes de perdas ( $B_i$ ) são dados por uma matriz quadrada de tamanho  $n \times n$ , descritos na Tabela 6.3, onde  $n$  é o número de geradores e todos os valores são multiplicados por  $10^{-4}$ .

Tabela 6.3 - Coeficientes de Perdas  $B_i$ .

n	1	2	3	4	5	6	7	8	9	10
<b>UGG1</b>	0.14	0.17	0.15	0.19	0.26	0.22	0.34	0.38	0.43	0.45
<b>UGG2</b>	0.17	0.6	0.13	0.16	0.15	0.2	0.23	0.56	0.23	0.51
<b>UGG3</b>	0.15	0.13	0.65	0.17	0.24	0.19	0.25	0.38	0.43	0.45
<b>UGG4</b>	0.19	0.16	0.17	0.71	0.3	0.25	0.43	0.56	0.23	0.51
<b>UGG5</b>	0.26	0.15	0.24	0.3	0.69	0.32	0.18	0.37	0.42	0.48
<b>UGG6</b>	0.22	0.2	0.19	0.25	0.32	0.85	0.97	0.55	0.27	0.58
<b>UGG7</b>	0.22	0.2	0.19	0.25	0.32	0.85	0.67	0.38	0.43	0.45
<b>UGG8</b>	0.19	0.7	0.13	0.18	0.16	0.21	0.28	0.56	0.23	0.51
<b>UGG9</b>	0.26	0.15	0.24	0.3	0.69	0.32	0.18	0.37	0.42	0.48
<b>UGG10</b>	0.15	0.13	0.65	0.17	0.24	0.19	0.25	0.38	0.43	0.45

Fonte: (NASCIMENTO *et al.*, 2016).

Os coeficiente de perdas ( $B_i$ ) foram obtidos através da utilização do método de Kron's (WANG e SINGH, 2007a).

Na tabela 6.4, são apresentados os coeficientes de emissões gerais. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de emissões  $\alpha_i$ ,  $\beta_i$  e  $\gamma_i$  de cada unidade geradora.

Tabela 6.4 – Coeficientes de Emissões Gerais - Estudo de Caso.

Gerador	$\alpha_i(g/m^3)$	$\beta_i(g/m^3)$	$\gamma_i(g/m^3)$
<b>UGG1</b>	4,59	-884,13	112047,21
<b>UGG2</b>	5,28	-871,68	105511,36
<b>UGG3</b>	3,41	-581,35	96795,36
<b>UGG4</b>	0,87	-263,50	86264,93
<b>UGG5</b>	0,23	-198,77	84132,86
<b>UGG6</b>	1,88	-444,28	92565,64
<b>UGG7</b>	0,87	-302,81	88329,64
<b>UGG8</b>	2,96	-654,92	102614,29
<b>UGG9</b>	3,44	-712,03	104626,14
<b>UGG10</b>	3,38	-716,90	104892,86

Fonte: O Autor, (2016).

Na tabela 6.5, são apresentados os coeficientes de emissões de  $NO_x$ . Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de emissões  $\alpha n_i$ ,  $\beta n_i$  e  $\gamma n_i$  de cada unidade geradora.

Tabela 6.5 – Coeficientes de Emissões de  $NO_x$  - Estudo de Caso.

Gerador	$\alpha n_i(g/m^3)$	$\beta n_i(g/m^3)$	$\gamma n_i(g/m^3)$
<b>UGG1</b>	0,05250	-8,08214	508,64286
<b>UGG2</b>	0,02833	-3,23810	269,92857
<b>UGG3</b>	0,01738	-2,41905	181,07143
<b>UGG4</b>	0,03702	-3,97976	314,92857
<b>UGG5</b>	0,01345	-2,33691	232,85714
<b>UGG6</b>	0,00108	-0,82679	173,15000
<b>UGG7</b>	0,04512	-6,02738	336,78571
<b>UGG8</b>	0,05738	-6,82619	342,85714
<b>UGG9</b>	0,06893	-9,14643	434,64286
<b>UGG10</b>	0,02405	-2,03095	193,00000

Fonte: O Autor, (2016).

Na tabela 6.6, são apresentados os coeficientes de emissões de  $CO_2$ . Na primeira coluna está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de emissões  $\alpha c_i$ ,  $\beta c_i$  e  $\gamma c_i$  de cada unidade geradora.

Tabela 6.6 – Coeficientes de Emissões de CO<sub>2</sub> - Estudo de Caso.

Gerador	$\alpha_i(g/m^3)$	$\beta c_i(g/m^3)$	$\gamma c_i(g/m^3)$
<b>UGG1</b>	4,53810	-876,04762	111538,57143
<b>UGG2</b>	5,29762	-875,59524	105542,85714
<b>UGG3</b>	3,39286	-578,92857	96614,28571
<b>UGG4</b>	0,83333	-259,52381	85950,00000
<b>UGG5</b>	0,83333	-259,52381	85950,00000
<b>UGG6</b>	1,86905	-443,45230	92392,85710
<b>UGG7</b>	0,82143	-296,78571	87992,85714
<b>UGG8</b>	2,90476	-648,09524	102271,42857
<b>UGG9</b>	3,44048	-712,73810	104528,57143
<b>UGG10</b>	3,44048	-712,73810	104528,57143

Fonte: O Autor, (2016).

Todos os valores foram obtidos a partir das medições realizadas em campo (**Anexo II**), com a utilização de um analisador de gases de emissões a diferentes percentuais de potências (60, 70, 80, 90 e 100%) e seus coeficientes especificados por meio de um método de regressão com auxílio do software *CurveExpert*.

### 6.2.2 Parâmetros de funcionamento da UTE – Sistema de Teste DE

Para validar a robustez da solução com a utilização das técnicas propostas neste trabalho, foi realizado um comparativo com um Sistema de Teste que contém 15 unidades geradoras termais, denominadas (PG1 à PG15), com as características apresentadas na Tabela 6.7 (ZWE-LEE, 2003).

Tabela 6.7 - Características dos geradores do Sistema de Teste DE.

Gerador	$c_i (\$/MW^2)$	$b_i (\$/MW)$	$a_i (\$/MW)$	$P_{min}(MW)$	$P_{max}(MW)$
<b>PG1</b>	0.000299	10.1	671	150	455
<b>PG2</b>	0.000183	10.2	574	150	455
<b>PG3</b>	0.001126	8.8	374	20	130
<b>PG4</b>	0.001126	8.8	374	20	130
<b>PG5</b>	0.000205	10.4	461	150	470
<b>PG6</b>	0.000301	10.1	630	135	460
<b>PG7</b>	0.000364	9.8	548	135	465
<b>PG8</b>	0.000338	11.2	227	60	300
<b>PG9</b>	0.000807	11.2	173	25	162
<b>PG10</b>	0.001203	10.7	175	25	160
<b>PG11</b>	0.003586	10.2	186	20	80
<b>PG12</b>	0.005513	9.9	230	20	80
<b>PG13</b>	0.000371	13.1	225	25	85
<b>PG14</b>	0.001929	12.1	309	15	55
<b>PG15</b>	0.004447	12.4	323	15	55

Fonte: (ZWE-LEE, 2003).

Os coeficientes de perdas  $B_m$  (**Anexo III**), são definidos por uma matriz quadrada de tamanho  $n \times n$ , onde  $n$  é o número de geradores adaptados de (ZWE-LEE, 2003).

### 6.2.3 Parâmetros de funcionamento da UTE Sistema de Teste – NSGA II

Para validar a robustez da solução com a utilização da técnica proposta nesta tese, foi realizado um comparativo com um Sistema de Teste (BASU, 2008) que contém 10 unidades geradoras termais, denominadas (PG1 à PG10), com as características apresentadas na Tabela 6.8. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira, na quarta, na quinta e na sexta estão os coeficientes de custos de combustível  $c_i$ ,  $b_i$ ,  $a_i$ ,  $d_i$  e  $e_i$  e nas duas últimas estão a potência mínima e máxima de cada unidade geradora.

Tabela 6.8 - Dados característicos dos geradores do Sistema de Teste - NSGA II.

Gerador	$c_i$ (\$/MW) <sup>2</sup> h	$b_i$ (\$/MWh)	$a_i$ (\$/h)	$d_i$ (\$/h)	$e_i$ (rad/MW)	$P_{min}$ (MW)	$P_{max}$ (MW)
<b>PG1</b>	0,1524	38,5397	786,7988	450	0,041	150	470
<b>PG2</b>	0,1058	46,1591	451,3251	600	0,036	135	470
<b>PG3</b>	0,028	40,3965	1.049,9977	320	0,028	73	340
<b>PG4</b>	0,0354	38,3055	1.243,5311	260	0,052	60	300
<b>PG5</b>	0,0211	36,3278	1.658,5696	280	0,063	73	243
<b>PG6</b>	0,0179	38,2704	1.356,6592	310	0,048	57	160
<b>PG7</b>	0,0121	36,5104	1.450,7045	300	0,086	20	130
<b>PG8</b>	0,0121	36,5104	1.450,7045	340	0,082	47	120
<b>PG9</b>	0,109	39,5804	1.455,6056	270	0,098	20	80
<b>PG10</b>	0,1295	40,5407	1.469,4026	380	0,094	10	55

Fonte: (BASU, 2008).

Na tabela 6.9, são apresentados os coeficientes de emissões gerais. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira, na quarta, na quinta e na sexta estão os coeficientes de emissões  $\alpha_i$ ,  $\beta_i$ ,  $\gamma_i$ ,  $\eta_i$  e  $\delta_i$  de cada unidade geradora.  $\alpha_i$ ,  $\beta_i$ ,  $\gamma_i$ ,  $\eta_i$ ,  $\delta_i$ .

Tabela 6.9 – Coeficientes de Emissões Gerais Sistema de Teste – NSGA II.

Gerador	$\alpha_i$ (lb/h)	$\beta_i$ (lb/Mwh)	$\gamma_i$ (lb/Mw) <sup>2</sup> h)	$\eta_i$ (lb/h)	$\delta_i$ (l/Mwh)
<b>PG1</b>	4,59	-884,13	112047,21	0,5035	0,0207
<b>PG2</b>	5,28	-871,68	105511,36	0,5035	0,0207
<b>PG3</b>	3,41	-581,35	96795,36	0,4968	0,0202
<b>PG4</b>	0,87	-263,50	86264,93	0,4968	0,0202
<b>PG5</b>	0,23	-198,77	84132,86	0,4972	0,0200
<b>PG6</b>	1,88	-444,28	92565,64	0,4972	0,0200
<b>PG7</b>	0,87	-302,81	88329,64	0,5163	0,0214
<b>PG8</b>	2,96	-654,92	102614,29	0,5163	0,0214
<b>PG9</b>	3,44	-712,03	104626,14	0,5475	0,0234
<b>PG10</b>	3,38	-716,90	104892,86	0,5475	0,0234

Fonte: (BASU, 2008).

Os coeficientes de perdas ( $B$ ) são dados por uma matriz quadrada de tamanho  $n \times n$ , multiplicados por  $10^{-4}$ , apresentados na Tabela 6.10, onde  $n$  é o número de geradores.

Tabela 6.10 – Coeficientes de Perdas Sistema de Teste – NSGA II.

n	1	2	3	4	5	6	7	8	9	10
<b>PG1</b>	0,49	0,14	0,15	0,15	0,16	0,17	0,17	0,18	0,19	0,20
<b>PG2</b>	0,14	0,45	0,16	0,16	0,17	0,15	0,15	0,16	0,18	0,18
<b>PG3</b>	0,15	0,16	0,39	0,10	0,12	0,12	0,14	0,14	0,16	0,16
<b>PG4</b>	0,15	0,16	0,10	0,40	0,14	0,10	0,11	0,12	0,14	0,15
<b>PG5</b>	0,16	0,17	0,12	0,14	0,35	0,11	0,13	0,13	0,15	0,16
<b>PG6</b>	0,17	0,15	0,12	0,10	0,11	0,36	0,12	0,12	0,14	0,15
<b>PG7</b>	0,17	0,15	0,14	0,11	0,13	0,12	0,38	0,16	0,16	0,18
<b>PG8</b>	0,18	0,16	0,14	0,12	0,13	0,12	0,16	0,40	0,15	0,16
<b>PG9</b>	0,19	0,18	0,16	0,14	0,15	0,14	0,16	0,15	0,42	0,19
<b>PG10</b>	0,20	0,18	0,16	0,15	0,16	0,15	0,18	0,16	0,19	0,44

Fonte: (BASU, 2008).

#### 6.2.4 Parâmetros de funcionamento da UTE Sistema de Teste – NSGA III

Para validar a robustez da solução com a utilização da técnica proposta neste trabalho, foi realizado um comparativo com um Sistema de Teste (DHILLON e JAIN, 2011), que contém 6 unidades geradoras termais, denominadas (PG1 à PG6), com as características apresentadas na Tabela 6.11. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de custos de combustível  $c_i$ ,  $b_i$ , e  $a_i$  e nas duas últimas estão a potência mínima e máxima de cada unidade geradora.

Tabela 6.11 - Dados característicos dos geradores do Sistema de Teste - NSGA III.

Gerador	$c_i$ (\$/MW) <sup>2</sup> h	$b_i$ (\$/MWh)	$a_i$ (\$/h)	$P_{min}$ (MW)	$P_{max}$ (MW)
<b>PG1</b>	0,002035	8,43205	85,6348	100	250,00
<b>PG2</b>	0,003866	6,41031	303,778	50	230,00
<b>PG3</b>	0,002182	7,4289	847,1484	200	500,00
<b>PG4</b>	0,001345	8,3154	274,2241	85	265,00
<b>PG5</b>	0,002162	7,42289	847,1484	200	500,00
<b>PG6</b>	0,005963	6,91559	202,0258	200	490,00

Fonte: (DHILLON e JAIN, 2011).

Na tabela 6.12, são apresentados os coeficientes de emissões de NO<sub>x</sub>. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de emissões  $a_{Ni}$ ,  $b_{Ni}$  e  $c_{Ni}$  de cada unidade geradora.

Tabela 6.12 – Coeficientes de Emissões de NO<sub>x</sub> Sistema de Teste – NSGA III.

Gerador	$c_{Ni}$	$b_{Ni}$	$a_{Ni}$
<b>PG1</b>	0,006323	-0,38128	80,9019
<b>PG2</b>	0,006483	-0,79027	28,8249
<b>PG3</b>	0,003174	-1,36061	324,1775
<b>PG4</b>	0,006732	-2,39928	610,2535
<b>PG5</b>	0,003174	-1,36061	324,1775
<b>PG6</b>	0,006181	-0,39077	50,3808

Fonte: (DHILLON e JAIN, 2011).

Na tabela 6.13, são apresentados os coeficientes de emissões de CO<sub>x</sub>. Na primeira coluna, está o número das unidades geradoras, na segunda, na terceira e na quarta estão os coeficientes de emissões  $a_{Ci}$ ,  $b_{Ci}$  e  $c_{Ci}$  de cada unidade geradora.

Tabela 6.13 – Coeficientes de Emissões de CO<sub>x</sub> Sistema de Teste – NSGA III.

Gerador	$c_{Ci}$	$b_{Ci}$	$a_{Ci}$
<b>PG1</b>	0,26511	-61,02	5080,148
<b>PG2</b>	0,140053	-29,95	3824,77
<b>PG3</b>	0,105929	-9,55	1342,851
<b>PG4</b>	0,106409	-12,74	1819,625
<b>PG5</b>	0,105929	-9,55	1342,851
<b>PG6</b>	0,403144	-121,98	11381,07

Fonte: (DHILLON e JAIN, 2011).

Os coeficientes de perdas ( $B$ ) são dados por uma matriz quadrada de tamanho  $n \times n$ , apresentados na Tabela 6.14, onde  $n$  é o número de geradores.

Tabela 6.14 – Coeficientes de Perdas Sistema de Teste – NSGA III.

n	1	2	3	4	5	6
<b>PG1</b>	0,00020	0,00001	0,00002	0,00001	0,00000	-0,00003
<b>PG2</b>	0,00001	0,00030	-0,00002	0,00000	0,00001	0,00001
<b>PG3</b>	0,00002	-0,00002	0,00010	-0,00001	0,00001	0,00001
<b>PG4</b>	0,00001	0,00000	-0,00001	0,00015	0,00001	0,00005
<b>PG5</b>	0,00000	0,00001	0,00001	0,00001	0,00025	0,00002
<b>PG6</b>	-0,00003	0,00001	0,00001	0,00005	0,00002	0,00021

Fonte: (DHILLON e JAIN, 2011).

### 6.2.5 Formulação Matemática para o Problema do DE

A formulação matemática clássica para a função do custo total de combustível é dada pela Eq. (6.1): (BARISAL e PRUSTY, 2015); (BEHERA *et al.*, 2015); (ELATTAR, 2015) (ARAGÓN *et al.*, 2015).

$$\text{Minimizar } TC = \sum_{i=1}^n F_i(P_i) \quad (6.1)$$

onde  $n$  é o número de unidades geradoras do sistema,  $P_i$  é a capacidade de potência de cada unidade geradora (em MW),  $F_i$  é o custo de combustível para cada unidade geradora (em R\$/h) e  $TC$  é o custo total de combustível (em R\$/h).

Neste trabalho, para o problema do DE, foi considerado uma função de custo simplificada, expressa como uma única função quadrática descrita na Eq. (6.2) (NASCIMENTO *et al.*, 2016):

$$F_i(P_i) = c_i P_i^2 + b_i P_i + a_i \quad (\$/h) \quad (6.2)$$

onde  $a_i$ ,  $b_i$  e  $c_i$  são os coeficientes de custo do consumo de combustível da  $i_{th}$  unidade.

Na programação foi considerado além da minimização do custo total de combustível, a satisfação das seguintes restrições de igualdade e desigualdade:

- Restrição do balanço de potência: o total da potência gerada  $P_i$  tem que ser igual à demanda de potência  $P_D$  necessária. Ela é definida como Eq.(6.3):

$$\sum_{i=1}^N P_i = P_D \quad (6.3)$$

- Restrições de limites de operação: unidades térmicas têm limites físicos sobre a potência máxima e mínima que pode gerar Eq. (6.4):

$$P_{mini} \leq P_i \leq P_{maxi} \quad (6.4)$$

onde  $P_{mini}$  e  $P_{maxi}$  são a potência mínima e máxima da  $i_{th}$  unidade, respectivamente.

- Balanço de Potência, com perda de transmissão: alguns sistemas de energia incluem a perda da rede de transmissão  $P_L$ , assim a Eq. (6.3) é substituída pela Eq. (6.5) (NASCIMENTO *et al.*, 2016):

$$\sum_{i=1}^N P_i = P_D + P_L \quad (6.5)$$

ou seja:

$$\sum_{i=1}^N P_i - P_D - P_L = 0 \quad (6.6)$$

onde  $P_L$  são as perdas de transmissão,  $P_D$  é a demanda de potência e  $P_i$  a potência de cada  $i_{th}$  unidade, respectivamente.

O valor  $P_L$  foi calculado como uma função de perdas de transmissão de cada unidade, que utiliza uma matriz de coeficientes de perdas B, um vetor B0 e um valor B00 Eq. (6.7) (NASCIMENTO *et al.*, 2016):

$$P_L = \sum_{i=1}^N \sum_{j=i}^N P_i B_{ij} P_j + \sum_{i=1}^N B0_i P_i + B00 \quad (6.7)$$

- Zonas Operacionais Proibidas: Restringem o funcionamento das unidades geradoras, devido à: vapor; condições de funcionamento da válvula; e vibrações no rolamento do eixo:

$$\begin{cases} P_{mini} \leq P_i \leq P_{i,1}^l \\ P_{i,j1}^u \leq P_i \leq P_{i,j}^l, & j = 2,3, \dots, nj \\ P_{i,nj}^u \leq P_i \leq P_{maxi} \end{cases} \quad (6.8)$$

onde  $nj$  é o número de zonas proibidas da  $i_{th}$  unidade,  $P_{i,j}^l$  e  $P_{i,j}^u$  são os limites inferiores e superiores da zona proibida.

- Restrição de desigualdade em termos de fornecimento de combustível.

Em cada intervalo, a quantidade de combustível fornecido a todas as unidades deve ser inferior ou igual ao combustível fornecido pelo vendedor, isto é, o combustível fornecido a cada unidade, em cada intervalo deve estar dentro de seu limite inferior  $F_i^{min}$  e seu limite superior  $F_i^{max}$ , de modo a (BASU, 2014a):

$$F_i^{min} \leq F_{im} \leq F_i^{max}, i \in N, m \in M \quad (6.9)$$

onde:  $F_{im}$  – Combustível fornecido ao gerador  $i$  no intervalo  $m$ ;  $F_i^{min}$  – quantidade mínima de combustível fornecido ao gerador  $i$ ;  $F_i^{max}$  – Quantidade máxima de combustível fornecido ao gerador  $i$ .

- Restrição de desigualdade em termos de limites de armazenamento de combustível.

O limite de armazenamento de combustível de cada unidade em cada intervalo deve estar dentro de seu limite inferior  $V_{min}$  e o limite superior  $V_{max}$ , de modo a (BASU, 2014a):

$$V_{min} \leq V_{im} \leq V_{max} \quad (6.10)$$

$$V_{im} = V_{(m-1)} + F_{im} - t_m[\eta_i + \delta_i P_i + \mu_i P_i^2] \quad i \in N, m \in M \quad (6.11)$$

onde  $\eta_i$ ,  $\delta_i$  e  $\mu_i$  são os coeficientes do consumo de combustível de cada unidade geradora e  $t_m$  a duração do subintervalo  $m$ .

- Restrição de desigualdade em termos de limites de Demanda de Potência.

$$\sum_{i=1}^n P_{min} \leq P^D \leq \sum_{i=1}^n P_{max} \quad (6.12)$$

- O Método do Custo Incremental de Combustível:

Por despacho ótimo, presume-se que o custo incremental para cada unidade seja descrito como (DIKE *et al.*, 2013):

$$\frac{\partial F_1}{\partial P_1} = \frac{\partial F_2}{\partial P_2} = \dots = \frac{\partial F_m}{\partial P_m} \quad (6.13)$$

$$\frac{\partial F_i}{\partial P_i} = \lambda \quad (6.14)$$

onde,  $\lambda$  é o custo incremental.

A condição ótima a partir de (6.14) se reduz a:

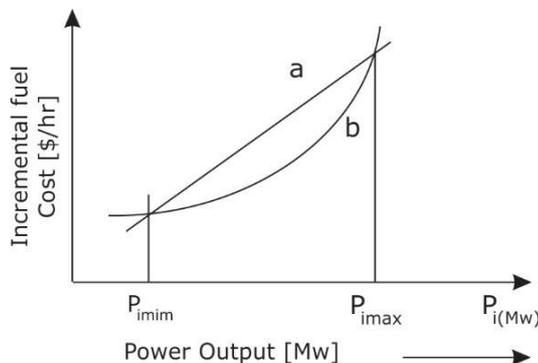
$$\frac{\partial F_i}{\partial P_i} = b_i + 2c_i P_i \quad (6.15)$$

$$\lambda = b_i + 2c_i P_i \quad (6.16)$$

onde  $\lambda$  é o custo incremental de combustível.

A curva de custo incremental do combustível é mostrada na Figura 6.4 a seguir:

Figura 6.4 - Curva de custo incremental de combustível.



Fonte: (NASCIMENTO *et al.*, 2016).

Onde **a** corresponde aos valores dos diferentes pontos da curva real dos custos incrementais e **b** são os valores dos pontos sobre a curva (linear) aproximada para o custo incremental.  $P_i$  é a geração total de potência (DHAMANDA *et al.*, 2013).

Para fins de despacho de carga o custo é geralmente aproximado a um ou mais segmentos quadráticos, então a curva de custo de combustível na geração de potência ativa, assume assim uma forma quadrática.

Da Eq. (6.16), a potência gerada na unidade pode ser obtido como (DIKE *et al.*, 2013):

$$P_i = \frac{\lambda - b_i}{2c_i} \quad (6.17)$$

Além disso, a condição ótima, Eq. (6.14), se torna:

$$\frac{\partial F_i}{\partial P_i} + \lambda \frac{\partial P_L}{\partial P_i} = \lambda \quad (6.18)$$

$$\frac{\partial P_L}{\partial P_i} = 2 \sum_{j=1}^n B_{ij} P_j + B_{0i} \quad (6.19)$$

Onde  $\frac{\partial P_L}{\partial P_i}$  é a perda incremental da unidade geradora  $i$ .

Inserindo as Eqs. (6.15) e (6.19) na Eq. (6.18), é obtido (DIKE *et al.*, 2013):

$$b_i + 2c_i P_i + 2\lambda \sum_{j=1}^n B_{ij} P_j + B_{0i} \lambda = \lambda \quad (6.20)$$

Da Eq. (6.20), a potência gerada na unidade  $i$  pode ser descrita como:

$$P_i = \frac{\lambda(1-B_{0i})-b_i-2\lambda\sum_{j=1}^n B_{ij}P_j}{2(c_i+\lambda B_{ii})} \quad (6.21)$$

Podendo ser simplificado como na Eq. (6.22):

$$P_i = \frac{\lambda-b_i}{2(c_i+B_{ii})} \quad (6.22)$$

### 6.2.6 Formulação Matemática para o Problema do DEA – Estudo de Caso

Além da formulação matemática descrita na seção 6.2.5, são consideradas as seguintes equações de Emissões:

Para o cálculo dos níveis de Emissões Gerais, foi utilizado a equação quadrática (Eq. 6.23), a partir da análise dos dados de medições (**Anexo II**), e seus coeficientes especificados por meio de um método de regressão com auxílio do software *CurveExpert*.

$$Eg_i(P_i) = \sum_{i=1}^n \alpha_i P_i^2 + \beta_i P_i + \gamma_i \quad (gm^3/h) \quad (6.23)$$

onde  $\alpha_i$ ,  $\beta_i$  e  $\gamma_i$  são os coeficientes de emissões gerais;  $n$  é o número de unidades geradoras do sistema;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $Eg_i(P_i)$  é o total de emissões (em  $gm^3/h$ ).

Para o cálculo dos níveis de Emissões de  $NO_X$ , foi utilizado a equação quadrática (Eq. 6.24), a partir da análise dos dados de medições (**Anexo II**), e seus coeficientes especificados por meio de um método de regressão com auxílio do software *CurveExpert*.

$$NOx_i(P_i) = \sum_{i=1}^n \alpha n_i P_i^2 + \beta n_i P_i + \gamma n_i \quad (gm^3/h) \quad (6.24)$$

onde  $\alpha n_i$ ,  $\beta n_i$  e  $\gamma n_i$  são os coeficientes de emissões de  $NO_X$ ;  $n$  é o número de unidades geradoras do sistema;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $NOx_i(P_i)$  é o total de emissões de  $NO_X$  (em  $gm^3/h$ ).

Para o cálculo dos níveis de Emissões de  $CO_2$ , foi utilizado a equação quadrática (Eq. 6.25), a partir da análise dos dados de medições (**Anexo II**), e seus coeficientes especificados por meio de um método de regressão com auxílio do software *CurveExpert*.

$$CO_{2i}(P_i) = \sum_{i=1}^n \alpha c_i P_i^2 + \beta c_i P_i + \gamma c_i \quad (gm^3/h) \quad (6.25)$$

onde  $\alpha c_i$ ,  $\beta c_i$  e  $\gamma c_i$  são os coeficientes de emissões de  $CO_2$ ;  $n$  é o número de unidades geradoras do sistema;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $CO_{2i}(P_i)$  é o total de emissões de  $CO_2$  (em  $gm^3/h$ ).

### 6.2.7 Formulação Matemática para o DEA – Sistema de Teste – NSGA II

A formulação matemática adotada para a função do custo total de combustível, considerando o efeito de *valve-point*, é dada pela Eq. (6.26) (BASU, 2008).

$$f_1 = \sum_{i=1}^n [a_i + b_i P_i + c_i P_i^2 |d_i \sin\{e_i (P_{i.min} - P_i)\}|] \quad (6.26)$$

onde:  $a_i, b_i, c_i, d_i$  e  $e_i$  são os coeficientes de consumo de combustível;  $n$  é o número de unidades geradoras do sistema de teste para o NSGA II;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $f_1$  é o custo total (em \$/h).

Para as emissões gerais de poluentes na atmosfera, considerando as emissões de Óxido de Enxofre (SO<sub>x</sub>), Óxido de Nitrogênio (NO<sub>x</sub>) e Dióxido de Carbono (CO<sub>2</sub>), é considerada uma equação quadrática e uma função exponencial dada pela Eq. (6.27) (BASU, 2008).

$$f_2 = \sum_{i=1}^n [\alpha_i + \beta_i P_i + \gamma_i P_i^2 + \eta_i \exp(\delta_i P_i)] \quad \text{lb/h} \quad (6.27)$$

onde:  $\alpha_i, \beta_i, \gamma_i, \eta_i$  e  $\delta_i$  são os coeficientes de emissões;  $n$  é o número de unidades geradoras do sistema de teste para o NSGA II;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $f_2$  é o total de emissões (em lb/h).

Além das restrições descritas na seção 6.2.5.

### 6.2.8 Formulação Matemática para o DEA – Sistema de Teste – NSGA III

A formulação matemática adotada para a função do custo total de combustível, é dada pela Eq. (6.28) (DHILLON e JAIN, 2011).

$$F_{FC} = \min \sum_{i=1}^n (a_i + b_i P_i + c_i P_i^2) \quad \$/h \quad (6.28)$$

onde:  $a_i, b_i$  e  $c_i$  são os coeficientes de consumo de combustível;  $n$  é o número de unidades geradoras do sistema de teste para o NSGA III;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $F_{FC}$  é o custo total de combustível (em \$/h).

Para o cálculo das emissões de poluentes NO<sub>x</sub> na atmosfera, é considerada uma equação quadrática dada pela Eq. (6.29) (DHILLON e JAIN, 2011).

$$F_{NX} = \min \sum_{i=1}^n (a_{Ni} + b_{Ni} P_i + c_{Ni} P_i^2) \quad \text{Kg/h} \quad (6.29)$$

onde:  $a_{ni}, b_{ni}$  e  $c_{ni}$  são os coeficientes de emissões de NO<sub>x</sub>;  $n$  é o número de unidades geradoras do sistema de teste para o NSGA III;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $F_{NX}$  é o total de emissões de NO<sub>x</sub> (em Kg/h).

Para o cálculo das emissões de poluentes  $CO_x$  na atmosfera, é considerada uma equação quadrática dada pela Eq. (6.30) (DHILLON e JAIN, 2011).

$$F_{CX} = \min \sum_{i=1}^n (a_{ci} + b_{ci}P_i + c_{ci}P_i^2) \quad \text{Kg/hr} \quad (6.30)$$

onde  $a_{ci}$ ,  $b_{ci}$  e  $c_{ci}$  são os coeficientes de emissões de  $CO_x$ ;  $n$  é o número de unidades geradoras do sistema de teste para o NSGA III;  $P_i$  é a capacidade de potência de cada unidade geradora (em MW) e  $F_{CX}$  é o total de emissões de  $CO_x$  (em Kg/h).

### 6.3 Implementação dos Métodos Determinísticos

Nesta seção serão demonstradas as implementações dos métodos determinísticos, descritos no capítulo 5, tendo como referência os parâmetros de funcionamento e a formulação matemática descrita na seção 6.2. Considerando a solução clássica e a nova solução proposta.

#### 6.3.1 Aplicação do MIL – Estudo de Caso

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.1.

#### 6.3.2 Aplicação do MIL – Sistema de Teste

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630\text{ MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.1.

### ***6.3.3 Aplicação do MN – Estudo de Caso***

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.3.

### ***6.3.4 Aplicação do MN – Sistema de Teste***

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores - Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630\text{ MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.3.

### ***6.3.5 Aplicação do Método da PQ – Estudo de Caso***

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.2.

### ***6.3.6 Aplicação do Método da PQ – Sistema de Teste***

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Executar o fluxo descritos na seção 5.2.2.

#### **6.4 Implementação dos Métodos Heurísticos Mono-objetivo**

Nesta seção serão demonstradas as implementações dos métodos Heurísticos, descritos no capítulo 5, tendo como referência os parâmetros de funcionamento e a formulação matemática descrita na seção 6.2. Considerando a solução clássica e a nova solução proposta.

##### **6.4.1 Otimização do DE por Algoritmo Genético (AG) – Estudo de caso**

O processo de implementação do AG é detalhado nos passos seguintes: Adaptado de (I.G. DAMOUSIS, 2003); (GOPALAKRISHNAN e KRISHNAN, 2012).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 500;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 500 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,022764 e coeficiente de variação de Pearson de 0,1135%.

**Passo 5:** População Inicial:

Na solução de AG, as saídas das  $(n - 1)$  unidades geradoras são escolhidas arbitrariamente dentro dos limites da Eq. (6.4), enquanto que a saída da unidade de referência é limitada pela equação do balanço de energia do sistema Eq. (6.6).

Um número Real representa a saída de cada gerador. As saídas dos geradores são concatenadas para formar uma cadeia consolidada de  $(n - 1)$  soluções. Esses números são chamados de genótipo ou cromossomo. Uma população inicial de  $m$  genótipos é gerada aleatoriamente. O tamanho da população  $m$  é um importante parâmetro do GA e é selecionado após experimentação com o problema específico. A população inicial é desenvolvida através de uma avaliação cromossômica num processo evolutivo descrito a seguir:

**Passo 6:** Avaliação do cromossomo: Dado um cromossomo, a sua função de *fitness* é calculada nas seguintes etapas:

**Sub-Passo 1:** Decomposição do Cromossomo.

A partir da definição do genótipo, descrita anteriormente, é evidente que o genótipo coincida com o reduzido vetor  $\tilde{P}$  de unidade de saída de energia, que contém as saídas das unidades. Dado  $\tilde{P}$ , a saída da unidade de referência é calculado usando Eq. (6.4).

**Sub-Passo 2:** O custo operacional total é calculado como a soma dos custos unitários de cada unidade geradora Eq. (6.1).

**Sub-Passo 3:** Para controlar as violações dos limites de referência (Eq. (6.4)) dos valores de potência de saída de cada unidade geradora, o custo operacional total é aumentado por um termo de penalidade não negativo  $w_p$ , penalizando as violações de restrição. Assim, a função de custo aumentada é formada pela Eq. (6.31).

$$\sum_{i=1}^n F_i(P_i) + w_p = \sum_{i=1}^n (c_i P_i^2 + b_i P_i + a_i) + w_p \quad (6.31)$$

O termo de penalização  $w_p$  é proporcional às violações correspondentes e nulo em caso de não violação Eq. (6.32).

$$w_p = \begin{cases} \bar{F} \cdot \frac{(P_{min.i} - P_i)}{P_{min.i}}, & \text{if } P_{min.i} > P_i \\ 0, & \text{if } P_{min.i} \leq P_i \leq P_{max.i} \\ \bar{F} \cdot \frac{(P_{max.i} - P_i)}{P_{max.i}}, & \text{if } P_i > P_{max.i} \end{cases} \quad (6.32)$$

onde

$$\bar{F} = \sum_{i=1}^n F_i(P_{max.i}) \quad (6.33)$$

**Sub-Passo 4:** A função de *fitness* GA é calculada como o inverso da função de custo aumentado, Eq. (6.34).

$$\frac{k}{\sum_{i=1}^n F_i(P_i) + w_P} \quad (6.34)$$

onde  $k = 10^6$ .

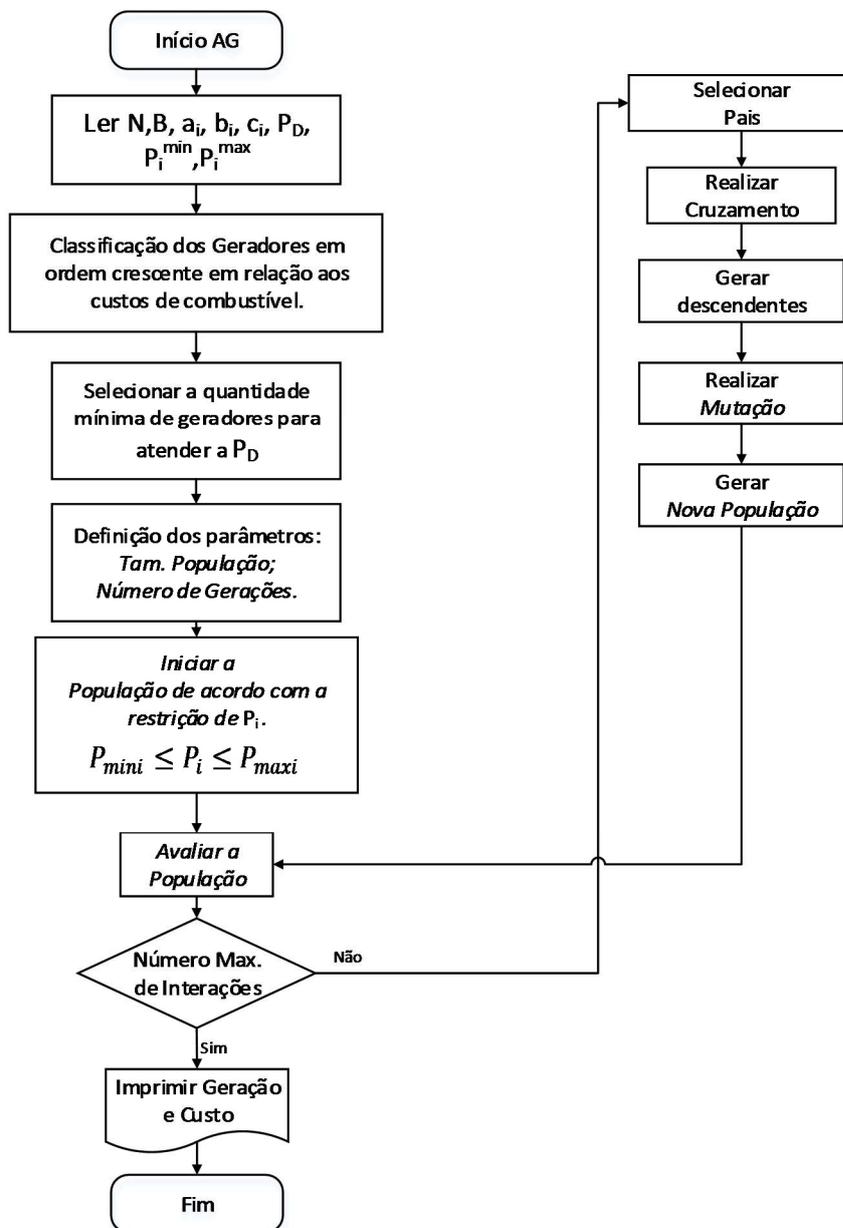
A constante  $k$  é utilizada a fim de impedir que a função de *fitness* obtenha valores muito pequenos, garantindo que a magnitude seja da ordem do custo máximo de funcionamento do sistema.

### **Passo 7: Evolução da População**

A evolução da população ocorre seguindo os princípios gerais do GA através da seleção, do cruzamento e da Mutação. Sendo assim, repete-se todo o processo até que o número máximo de gerações seja alcançado e finalize o programa.

Na figura 6.5, é mostrado o fluxograma de execução do Algoritmo Genético para a solução do problema do DE.

Figura 6.5 - Fluxograma de execução do Algoritmo Genético para Resolução do DE.



Fonte: O Autor, (2016).

No Anexo IV, segue o código do AG para a nova solução proposta implementado no Matlab.

#### 6.4.2 GA comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 500; Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 500 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,09191 e coeficiente de variação de Pearson de 0,00354%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.1.

#### **6.4.3 Otimização do DE por Enxame de Partículas (PSO) – Estudo de caso.**

O processo de implementação é detalhado nos passos seguintes: Adaptado de (ARYA *et al.*, 2009).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 400;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 400 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,006422 e coeficiente de variação de Pearson de 0,0321%.

**Passo 5:** Geração da população inicial.

Uma partícula na população consiste em  $NP$  componentes como variáveis de controle de potência ativa. Cada variável de controle de potência ativa de uma partícula é selecionada a

partir de uma distribuição uniforme entre  $P_{min.i}$  e  $P_{max.i}$ , satisfazendo a restrição de desigualdade Eq. (6.4). Estas ' $M$ ' soluções iniciais são viáveis. Estas partículas ' $M$ ' são indicadas como se segue.

$$P_i = [P_{i1}, P_{i2}, P_{i3}, \dots, P_{iNG}], \quad i = 1, 2, \dots, M$$

O procedimento a seguir é adotado para a inicialização de um agente:

- a. Fazendo  $j = 1$ .
- b. Selecione um elemento, ou seja, uma variável de controle  $P_j$  de um indivíduo aleatoriamente.
- c. Criar aleatoriamente o valor de  $P_j$  satisfazendo a restrição de desigualdade Eq. (6.4).
- d. Se  $j < NP$  então, vá para o passo (e) caso contrário, faça  $j = j + 1$  e repita a partir de (b).
- e. Pare a inicialização.

**Passo 6:** Velocidade inicial da partícula.

A velocidade inicial de cada partícula também é criada usando dígitos aleatórios. A velocidade do elemento ' $j$ ' de uma partícula é gerada de forma aleatória no intervalo dado como se segue:

$$P_j^{min} - P_{ij}^0 \leq v_{ij}^0 \leq P_i^{max} - P_{ij}^0$$

Então o vetor de velocidade para a partícula é selecionado como:

$$v_i = [v_{i1}, v_{i2}, v_{i3}, \dots, v_{iNP}]$$

**Passo 7:** Cada partícula individual da função objetivo ( $J$ ) como dado na relação Eq. (6.1) é avaliada e a melhor solução é definida como o valor inicial da  $i$ th partícula  $Pb_{ij}^k$  e o melhor grupo  $G_{jk}$  inicial é determinado como a posição de um indivíduo com um valor máximo da função objetivo através da utilização da relação Eq. (6.1).

**Passo 8:** Relações de velocidade e posição de cada indivíduo são atualizadas usando Eqs. ((6.35) e (6.36)).

$$v_{ij}^{r+1} = w \times v_{ij}^r + C_1 \times R_1 \times (Pb_{ij}^r - P_{ij}^r) + C_2 \times R_2 \times (G_{jr} - P_{ij}^r) \quad (i = 1, 2, \dots, NP; j = 1, 2, \dots, NG) \quad (6.35)$$

$$P_{ij}^{r+1} = P_{ij}^r + v_{ij}^{r+1} \quad (i = 1, 2, \dots, NP; j = 1, 2, \dots, NG) \quad (6.36)$$

**Passo 9:** Mecanismo de *fly-back*.

A posição de cada partícula modificada na etapa anterior pode não satisfazer a restrição de desigualdade. A ideia intuitiva é para garantir uma população viável e para uma partícula

voltar para sua posição anterior, quando esta estiver fora da região viável. Este tem sido denominado como mecanismo de *fly-back*. Como a população é inicializada na região viável, voltar a uma posição anterior garantirá que a solução será viável (ARYA *et al.*, 2009).

**Passo 10:** Atualizando o  $Pb_{ij}^k$  e  $G_{jk}$

$Pb_{ij}^k$  é atualizado em  $(k+1)_{th}$  iterações da seguinte forma:

$$Pb_{ij}^{k+1} = \begin{cases} P_i^{k+1} & \text{se } j(P_i^{k+1}) > j(Pb_{ij}^k) \\ Pb_{ij}^k & \text{caso contrário} \end{cases}$$

onde ' $j$ ' é a função objetivo descrita na Eq. (6.1).  $G_{jk+1}$ , a cada iteração é definido como o melhor valor em termos de função objetivo dentre  $Pb_{ij}^{k+1}$ .

**Passo 11:** Estratégia de redução de espaço.

É introduzida numa fase, quando a melhora da função objetivo não tenha ocorrido durante um pré-determinado período de iterações. Em tal situação, o espaço de busca é dinamicamente reduzido, de acordo com a seguinte relação:

$$\left. \begin{aligned} P_{j,max}^{k+1} &= P_{j,max}^k - (P_{j,max}^k - G_{jk})x\Delta \\ P_{j,min}^{k+1} &= P_{j,min}^k + (P_{j,min}^k - G_{jk})x\Delta \end{aligned} \right\} \quad (6.37)$$

onde  $\Delta$  é conhecido como tamanho do passo, sendo o valor padrão selecionado igual a 0,12.

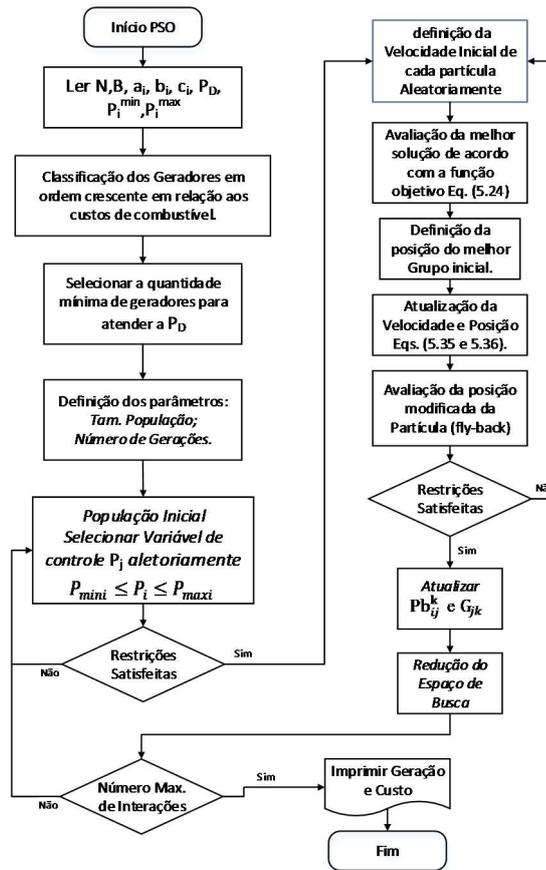
**Passo 12:** O algoritmo é finalizado, se o número máximo de iterações tenha sido executado.

PSO é um procedimento de busca heurística e, como tal, não existe critério de convergência analítica, exceto que o algoritmo PSO é encerrado quando um número pré-definido de iterações são executadas.

O número máximo de iterações pode ser especificado com base na experiência computacional no sistema (ARYA *et al.*, 2009).

Na figura 6.6, é mostrado o fluxograma de execução do PSO para a solução do problema do DE.

Figura 6.6 - Fluxograma de execução do PSO para Resolução do DE.



Fonte: O Autor, (2016).

#### 6.4.4 PSO comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 450;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 450 indivíduos foi a que apresentou o

menor custo total de combustível, com um desvio padrão de 0,050507 e coeficiente de variação de Pearson de 0,002%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.3.

#### 6.4.5 Otimização do DE por Evolução Diferencial (ED) – Estudo de caso.

O processo de implementação é detalhado nos passos seguintes: Adaptado de (BASU, 2011).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 500;

Número máximo de Gerações – 1500.

Fator de Escala –  $F = 0,5$ ;

Constante de *Crossover* = 0,8;

Estratégia = *DE/rand/1/bin*.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 500 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,004752802 e coeficiente de variação de Pearson de 0,0237%.

**Passo 5:** Inicialização:

Deixar  $p_k = [P_1, P_2, \dots, P_i, \dots, P_N]$  ser a  $k^{\text{th}}$  população pai a ser evoluída e  $k = 1, 2, \dots, N_p$ . Os elementos da  $p_k$  são as potências reais de saída das  $N$  unidades geradoras comprometidas. A potência real de saída de cada  $i^{\text{th}}$  unidade é determinada através da configuração  $P_i \sim U(P_{\min.i}, P_{\max.i})$ , onde  $i = 1, 2, \dots, N$ .  $U(P_{\min.i}, P_{\max.i})$  denota uma variável aleatória uniforme no intervalo  $[P_{\min.i}, P_{\max.i}]$ . Cada população deve satisfazer as restrições dadas pelas Eqs. (6.4) e (6.6). Avaliar o valor de TC (Eq. (6.1)) a cada população (BASU, 2011).

**Passo 6:** Mutaç o:

Para cada popula o alvo, uma perturba o na popula o   gerada por adi o do vetor de diferen a ponderada entre dois membros da popula o original a um terceiro membro. Para cada popula o-alvo  $p_k^g$  na  $g$ th gera o a perturba o da popula o  $p_k^{/g}$    obtida pela Eq. (6.38).

$$p_k^{/g} = p_{r_1}^g + F(p_{r_2}^g - p_{r_3}^g), \quad k \in N_p \quad (6.38)$$

onde  $p_{r_1}^g$ ,  $p_{r_2}^g$  e  $p_{r_3}^g$  s o selecionados aleatoriamente a partir de  $N_p$  popula es na  $g$ th gera o e  $r_1 \neq r_2 \neq r_3 \neq k$ . A perturba o da popula o deve satisfazer as restri es dadas por Eqs. (6.4) e (6.6). Calcular o valor de TC (Eq. (6.1)) a cada perturba o da popula o (BASU, 2011).

**Passo 7:** Crossover:

Executar o crossover para cada popula o alvo  $p_k^g$  com sua perturba o na popula o  $p_k^{/g}$  e criar uma popula o de julgamento  $p_k^{//g}$  de tal modo que (BASU, 2011):

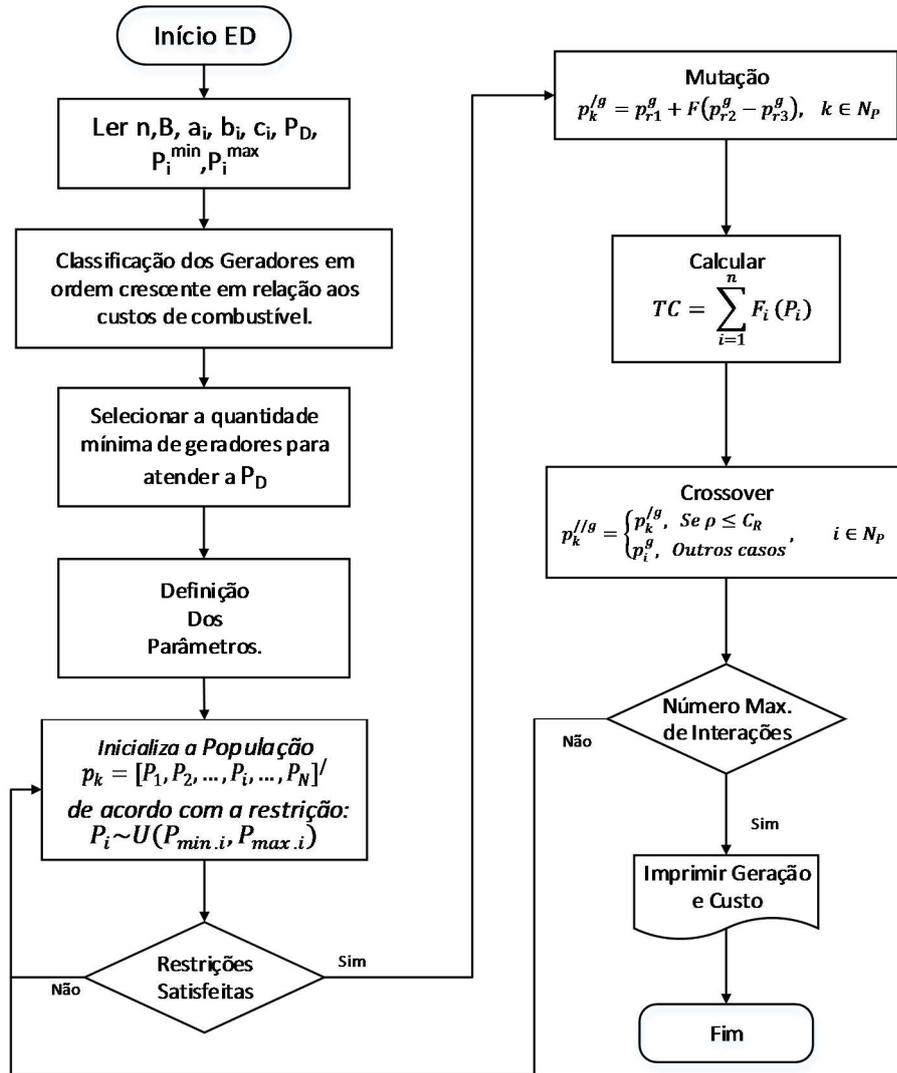
$$p_k^{//g} = \begin{cases} p_k^{/g}, & \text{Se } \rho \leq C_R \\ p_i^g, & \text{Outros casos} \end{cases}, \quad i \in N_p \quad (6.39)$$

onde  $\rho$    um n mero aleat rio uniformemente distribu do dentro do intervalo de  $[0, 1]$ .

Se n mero da gera o   igual ao n mero m ximo de gera es pare o algoritmo. Se n o, copiar a melhor popula o  $N_p$  e v  para o passo 6.

Na figura 6.7, o Fluxograma de execu o do ED para a solu o do problema do DE.

Figura 6.7 - Fluxograma de execução do ED para Resolução do DE.



Fonte: O Autor, (2016).

#### 6.4.6 ED comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 450;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 450 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,21914 e coeficiente de variação de Pearson de 0,008%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.5.

#### **6.4.7 Otimização do DE por Lobo Cinzento (GWO) – Estudo de caso.**

O processo de implementação é detalhado nos passos seguintes: Adaptado de (SULAIMAN *et al.*, 2015).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 350;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 350 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,003992 e coeficiente de variação de Pearson de 0,0199%.

O mecanismo de busca do GWO, ao contrário dos algoritmos clássicos de AI, cria uma área de busca radial resultante da utilização de três referências, em vez de uma. O raio de pesquisa varia de acordo com o parâmetro o qual decai linearmente (Eq. (6.40)) de 2 a 0 durante as iterações.

$$\text{decrécimo linear} = 2 - 1\left(\frac{2}{MI}\right) \quad (6.40)$$

O algoritmo GW quando tentar otimizar, para usar os geradores, com mais eficiência, vai para cada uma das restrições para analisar se foram cumpridas. Se as restrições forem satisfeitas,

então o valor pode ser usado, logo o algoritmo obtém um novo valor. O algoritmo analisa cada valor, e se qualquer valor violar a restrição (Eq. (6.4)) o algoritmo gera um novo valor aleatório e testa novamente. Se o novo valor não violar as restrições o algoritmo usa o novo valor, caso contrário, repete a geração aleatória para localizar valores que não violem as restrições.

O uso de GWO para resolver o problema DE inclui a descoberta dos valores ótimos das variáveis de controle para minimizar a função objetivo Eq. (6.1) ao cumprir todas as restrições mencionadas anteriormente.

Inicialmente, o número de agentes de busca (lobos cinzentos) e a iteração máxima está definido. O vetor da população pode ser expresso como se segue:

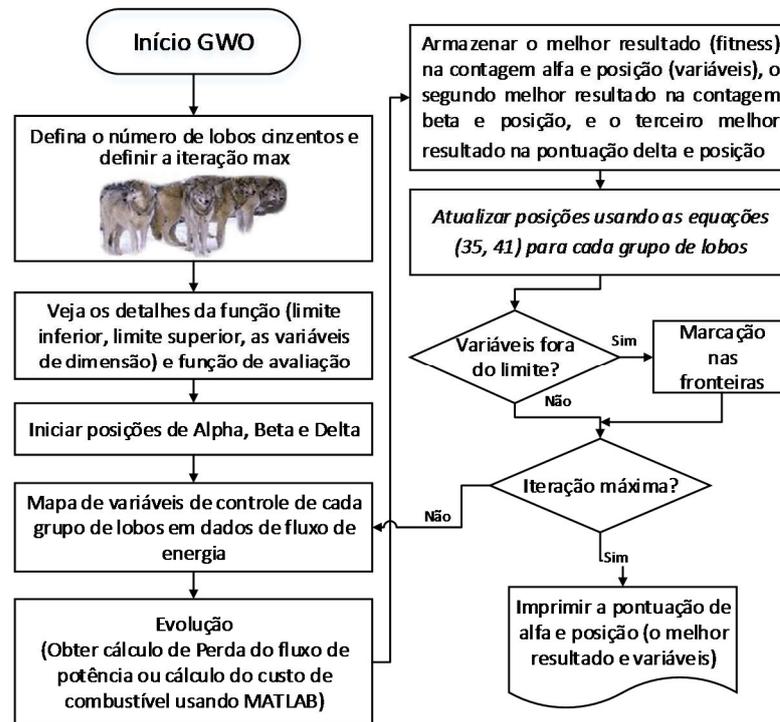
$$X = \begin{bmatrix} x_1^1 & \dots & x_n^1 \\ \vdots & & \vdots \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ x_1^p & \dots & x_n^p \end{bmatrix} \quad (6.41)$$

Onde  $n$  é o número de variáveis de controle ou posições dos lobos e o símbolo  $p$  representa o número da população (número de lobos cinzentos). A fim de minimizar a função objetivo (processo de avaliação), cada posição é mapeada no programa, desta forma, dados de fluxo de potência são executados para obter o custo do combustível.

O melhor *fitness* ou seja, variáveis de custo mínimo de combustível e posição são armazenados como pontuação e posição dos alfa's. O segundo melhor *fitness* é armazenado como pontuação e posição dos beta's. Em seguida, o terceiro melhor *fitness* é armazenado como pontuação e posição dos delta's. A simulação prossegue avaliando os processos GWO Eqs. (5.35, 5.36, 5.37, 5.38, 5.39, 5.40 e 5.41).

A simulação é repetida até alcançar o máximo de iterações. A implementação do GWO para resolver o problema do DE está representada na Fig. 6.8.

Figura 6.8 – Fluxo da proposta GWO para Resolução do DE.



Fonte: adaptado de (SULAIMAN *et al.*, 2015).

#### 6.4.8 GWO comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 500;

Número máximo de Gerações – 1500.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 500 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,42129264 e coeficiente de variação de Pearson de 0,0160%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.7.

#### 6.4.9 Otimização do DE por Recozimento Simulado (RS) – Estudo de caso.

O processo de implementação é detalhado nos passos seguintes: Adaptado de (BASU, 2005).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

O número máximo de tentativas dentro de uma temperatura = 1500;

Temperatura na qual parar =  $1e^{-10}$ ;

O número máximo de rejeições consecutivas = 1000;

A temperatura inicial = 300.

Os parâmetros foram selecionados após 150 simulações com diferentes Temperaturas Iniciais (populações). A simulação com 300 graus célsius de temperatura inicial foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,000031 e coeficiente de variação de Pearson de 0,0002%.

**Passo 5:** Inicialização.

- i. Entrada do vetor de pesos  $\underline{w}$  e do vetor de metas  $\underline{g}$ . O vetor  $\underline{g}$  é dado por decisão ou o vetor  $\underline{g}$  é gerado no sub-passo (5.ii.) e depois vá para o Passo 6.
- ii. De acordo com as restrições, conforme descrito pelas Eqs. ((6.4) e (6.6)) minimizar a função objetivo (Eq. (6.1)), utilizando o método de RS. Cada componente do vetor objetivo é atribuído ao seu correspondente valor da função objetivo minimizada.

**Passo 6:** Definir o contador de iteração ( $IC$ ) = 1 e o contador de teste ( $IT$ ) = 1.

**Passo 7:** Obter uma solução candidata inicial.

Iniciar um vetor de soluções viáveis, selecionadas aleatoriamente entre os limites ( $P_{min.i}, P_{max.i}$ ) de acordo com a Eq. (6.4).

**Passo 8:** Geração de soluções vizinhas.

- i. Gerar uma nova solução, utilizando uma técnica de perturbação, tal como descrito em (WONG e FUNG, 1993).
- ii. Verificar cada restrição (isto é, Eqs. ((6.4) e (6.6)). Se qualquer restrição for violada, então, ir para a sub-passo (8.i.), senão vai para o sub-passo (8.iii.).
- iii. Calcular a função objetivo.
- iv. Verificar para cada restrição objetivo se  $w_i = 0$ . Se  $w_i = 0$  e  $F_i > g_i$ , então, ir para a sub-passo (8.i.), senão vai para o sub-passo (8.v.).
- v. Para todos  $w_i \neq 0$ , procurar o valor de  $\lambda$  utilizando a Eq. (6.42).

$$\lambda = \max_i (F_i - g_i) / w_i \quad (6.42)$$

**Passo 9:** Verificação de aceitação e atualização da solução atual.

Calcular  $\Delta\lambda = \lambda_{new} - \lambda_{current}$ . Quando a nova solução é de menor valor (ou seja  $\Delta\lambda \leq 0$ ), então aceitá-la como a solução atual. Quando  $\Delta\lambda > 0$ , então, aceitar a nova solução como a solução atual com uma probabilidade de aceitação  $Pr(\Delta\lambda)$ , como dado pela Eq. (6.43).

$$Pr(\Delta) = \exp(-\Delta/T) \quad (6.43)$$

**Passo 10:** Teste para ensaios máximos.

Se  $(IT) = (IT)_{max}$ , então, vá para o Passo 11, se não, defina  $(IT) = (IT) + 1$  e vá para o passo 7.

**Passo 11:** Teste para iterações máximas.

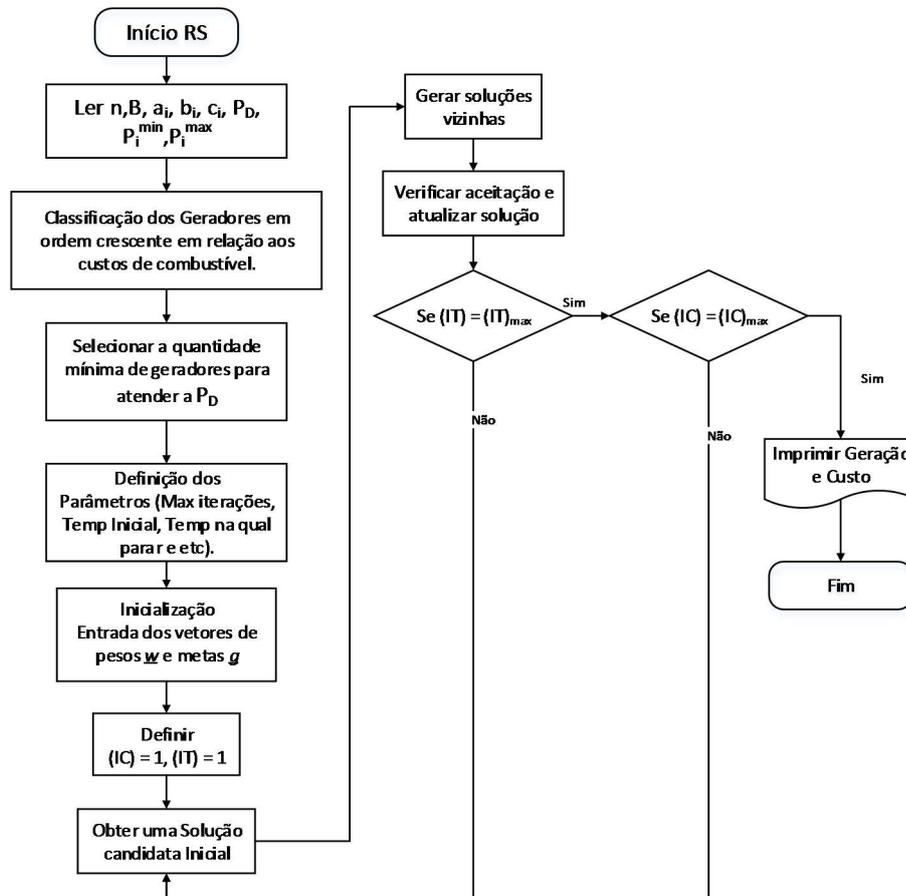
Se  $(IC) = (IC)_{max}$ , então, vá para o Passo 12, se não reduza a temperatura de acordo com a Eq. (6.44), faça  $(IC) = (IC) + 1$ , e depois vá para o passo 7.

$$T_v = r^{(v-1)} T_0 \quad (6.44)$$

**Passo 12:** Imprimir Geração e Custo de cada unidade geradora e Finalizar algoritmo.

A implementação do RS para resolver o problema do DE está representada na figura 6.9.

Figura 6.9 – Fluxo da proposta RS para Resolução do DE.



Fonte: O Autor, (2016).

#### 6.4.10 RS comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

O número máximo de tentativas dentro de uma temperatura = 1500;

Temperatura na qual parar =  $1e^{-10}$ ;

O número máximo de rejeições consecutivas = 1000;

A temperatura inicial = 500.

Os parâmetros foram selecionados após 150 simulações com diferentes Temperaturas Iniciais (populações). A simulação com 500 graus célsius de temperatura inicial foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,000820078 e coeficiente de variação de Pearson de 0,00003%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.9.

#### **6.4.11 Otimização do DE por Colônias de Abelhas Artificial (ABC) – Estudo de caso.**

O processo de implementação é detalhado nos passos seguintes: Adaptado (TANKASALA, 2012).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2 e 6.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

O número máximo de ciclos para a alimentação = 500;

Os parâmetros foram selecionados após 150 simulações com diferentes valores de ciclos de alimentação. A simulação com 500 ciclos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,000964336 e coeficiente de variação de Pearson de 0,0048%.

**Passo 5:** Gerar  $n$  soluções aleatórias de acordo com os limites do sistema.

$$P_i = P_{min.i} + rand[0,1] \times (P_{max.i} - P_{min.i}) \quad (6.45)$$

**Passo 6:** Calcular a função objetivo e a aptidão de cada solução.

**Passo 7:** Guardar o melhor ajuste como solução  $P_{best}$ .

**Passo 8:** Uma solução de mutação é formada usando um vizinho selecionado aleatoriamente, sendo:

$$P_{kmutante} = P_k(i) + (P_j(i) - P_k(i)) * (2 * rand[0,1] - 1)) \quad (6.46)$$

Onde  $j$  é o vizinho selecionado aleatoriamente e  $i$  é um parâmetro aleatório.

**Passo 9:** Substituir  $P_{kmutante}$  por  $P_k$ , se o mutante tem maior aptidão ou menor geração de custo de combustível.

**Passo 10:** Repetir o procedimento acima para todas as soluções.

**Passo 11:** A probabilidade de cada solução é calculada como:

$$Prob(i) = a * fitness(i) / \max(fitness) + b \quad (6.47)$$

onde  $\{a + b = 1\}$

**Passo 12:** A solução de  $P$  é selecionada se a probabilidade é maior do que um número aleatório

Se  $(rand[0,1] < Prob(i))$ , então a solução é aceita para a mutação.

Se não, ir para a próxima solução;

Contador é incrementado.

Enquanto  $(Contador = população / 2)$

**Passo 13:** Novamente o melhor  $P$  é determinado

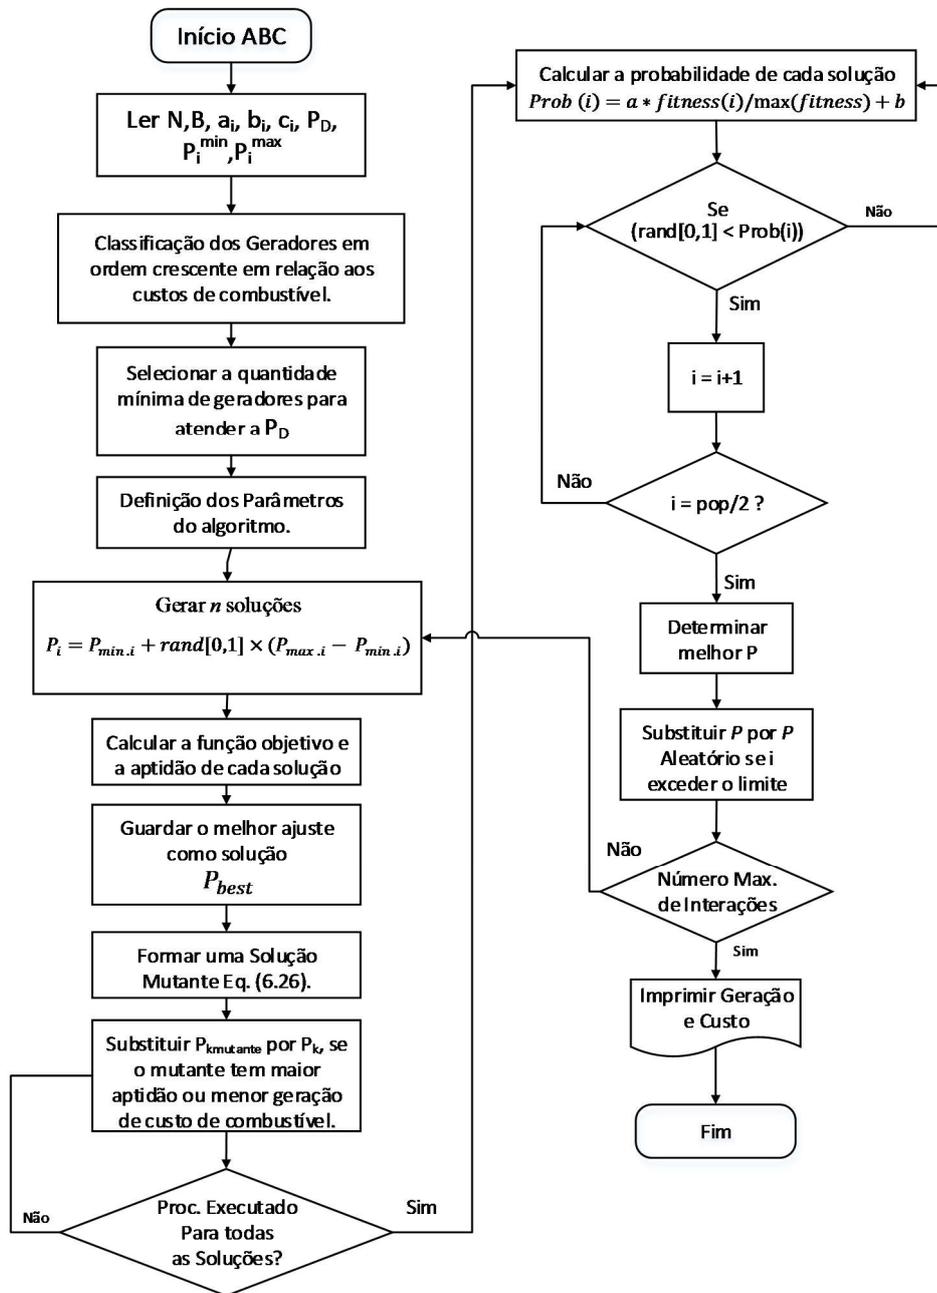
**Passo 14:** Substituir  $P$  por  $P$  aleatório se o seu contador de teste exceder o limite

**Passo 15:** Repita os passos acima para número máximo de iterações

**Passo 16:** Imprimir Geração e Custo de cada unidade geradora e Finalizar algoritmo.

A implementação do ABC, para resolver o problema DE está representada na figura 6.10.

Figura 6.10 – Fluxo da proposta ABC para Resolução do DE.



Fonte: O Autor, (2016).

#### 6.4.12 ABC comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.2), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 2630$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

O número máximo de ciclos para a alimentação = 500;

Os parâmetros foram selecionados após 150 simulações com diferentes valores de ciclos de alimentação. A simulação com 500 ciclos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,05731742 e coeficiente de variação de Pearson de 0,0022%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.4.11.

Todas as técnicas aplicadas neste trabalho para o problema de otimização do DE (mono-objetivo), podem ser convertidas para resolução de problemas de otimização DEA (multiobjetivo), utilizando a abordagem clássica, que atribui um peso  $w_i$  para cada função objetivo  $F_i$ , convertendo o problema de otimização em um único objetivo com uma função objetivo escalar de acordo com a Eq. (6.48).

$$\min f = w_1 F_1(x) + w_2 F_2(x) + \dots + w_n F_n(x) \quad (6.48)$$

Onde  $f$  é a função a ser otimizada.

Outra solução, é adotar uma função como função objetivo a ser otimizada e as outras funções objetivo como restrições do problema. Para este trabalho foram utilizados o NSGA II e o NSGA III, para resolução do problema de otimização do DEA como descrito na próxima seção.

### 6.5 Implementação dos Métodos Heurísticos Multiobjetivos

Nesta seção serão demonstradas as implementações dos métodos Heurísticos Multiobjetivo, descritos no capítulo 5, tendo como referência os parâmetros de funcionamento

e a formulação matemática descrita na seção 6.2. Considerando a solução clássica e a nova solução proposta.

### **6.5.1 Otimização do DEA por NSGA II – Estudo de caso.**

O processo de implementação é detalhado nos passos seguintes: Adaptado de (BASU, 2008).

**Passo 1:** Carregar os dados da Usina (características dos geradores - Tabelas 6.2, 6.3 e 6.32), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 20\text{MW}$ ).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores (Tabelas 6.2 e 6.3) de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 30;

Número máximo de Gerações – 150.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 30 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 1,37203 e coeficiente de variação de Pearson de 6,4218%.

**Passo 5:** Inicializar uma população pai aleatória de tamanho  $N_p$ .

**Passo 6:** Ordenar a população com base na não-dominação. Para cada população é atribuída uma classificação igual ao seu nível de não-dominação ou número frontal (1 é o melhor nível, 2 é o próximo melhor nível e assim por diante). Calcular a distância de aglomeração das populações em cada nível de não-dominação e classificar as populações em ordem decrescente de distância de aglomeração.

**Passo 7:** Selecionar dois indivíduos de forma aleatória. Comparar seu número frontal e de distância de aglomeração.

**Passo 8:** Calcular função de aptidão (*fitness*).

**Passo 9:** Realizar cruzamento e mutação, para criar a população descendente de tamanho  $N_p$ .

**Passo 10:** Combinar a população pai e população descendente. O tamanho da população combinada é de  $2 N_p$ .

**Passo 11:** Rápida seleção não-dominada na população combinada. Uma vez que todos os membros populacionais pais e descendentes estão incluídos, o elitismo é garantido.

**Passo 12:** Avaliar se é a população classificada. Se sim ir para o passo 13, se não, identificar indivíduos não-dominados, incrementar frente em 1 e voltar para o passo 11.

**Passo 13:** Atribuir distância de aglomeração.

**Passo 14:** Gerar população descendente (prole).

**Passo 15:** Verificar regra de parada: Neste trabalho, NSGA-II é executado por um número fixo de gerações. Verificar critério de parada. Se ele está satisfeito, então, vá para o Passo 16, se não, incrementar geração em 1 e voltar para o passo 8.

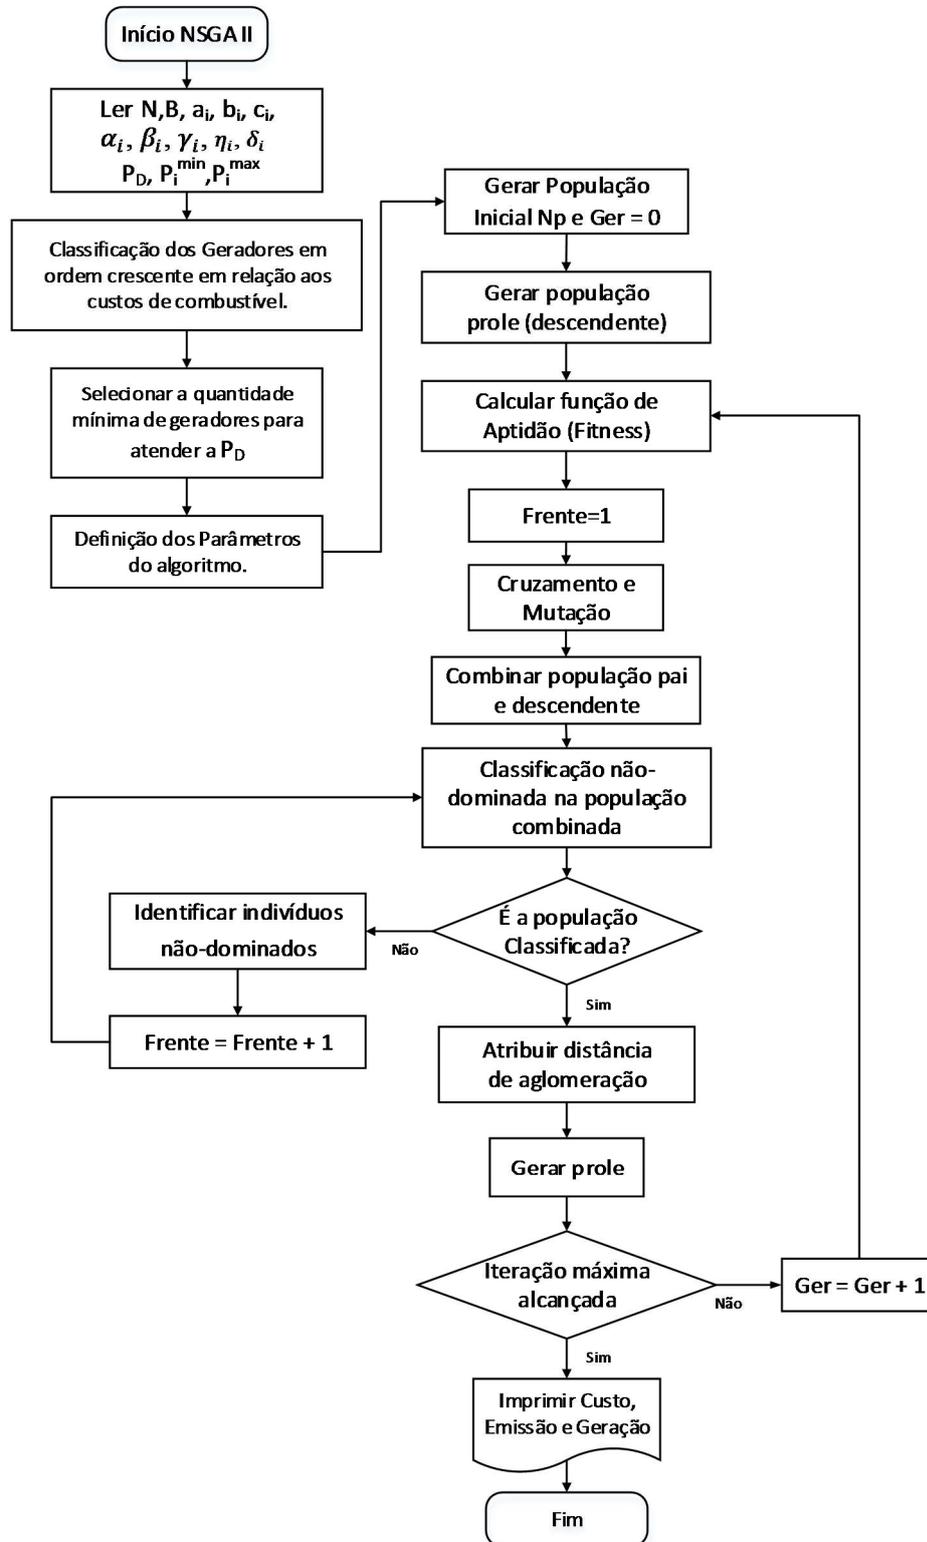
**Passo 16:** Selecione o primeiro membro da população da primeira frente.

**Passo 17:** Imprimir Custo, Emissão e Geração.

**Passo 18:** Fim.

A implementação do NSGA II, para resolver o problema do DEA está representada na figura 6.11.

Figura 6.11 – Fluxo da proposta NSGA II para Resolução do DEA.



Fonte: O Autor, (2016).

### 6.5.2 NSGA II comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.3), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 1036$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 40;

Número máximo de Gerações – 150.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 40 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 0,75277 e coeficiente de variação de Pearson de 7,8544%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.5.1.

### **6.5.3 Otimização do DEA por NSGA III – Estudo de caso.**

O processo de implementação é detalhado nos passos seguintes: Adaptado de (TAVANA *et al.*, 2016).

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.4), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 1036$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 40;

Número máximo de Gerações – 150.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 40 indivíduos foi a que apresentou o menor

custo total de combustível, com um desvio padrão de 0,75277 e coeficiente de variação de Pearson de 7,8544%.

**Passo 5:** algoritmo começa com a definição de  $N_{pop}$ , onde  $P_0$  denota a população inicial. Cada indivíduo (solução) na população  $P_0$ , bem como nas populações das próximas gerações, é representado por  $P_i$  para  $i = 1, \dots, N_{pop}$ . Nota-se que no presente estudo, os indivíduos da população inicial são gerados aleatoriamente, de tal modo que  $P_{imin} \leq P_i \leq P_{imax}$ , para  $1, \dots, N_{pop}$ , como se segue:

$$P_i = [P_{imin} + rand.(P_{imax} - P_{imin})] \quad (6.49)$$

onde  $P_{imin}$  e  $P_{imax}$  representam os limites inferiores e superiores para a variável  $P_i$ , respectivamente,  $rand$  é um número aleatório uniforme entre 0 e 1.

**Passo 6:** Gerar o descendente  $Q_t$ . Neste estudo, um operador de recombinação aritmética, é utilizado onde dois indivíduos  $P_i$  e  $P_r$  da população atual são selecionados aleatoriamente para gerar dois descendentes  $q_i$  e  $q_r$ , como se segue:

$$q_i = (\beta)P_i + (1 - \beta)P_r \quad (6.50)$$

$$q_r = (1 - \beta)P_i + (\beta)P_r \quad (6.51)$$

onde  $\beta$  é um número aleatório uniforme no intervalo  $[0,1]$ . Os descendentes  $q_i$  e  $q_r$  gerados são adicionados ao  $Q_t$ .

**Passo 7:** Operador de mutação. É utilizado um operador de mutação, que é aplicado para a nova geração. Cada solução (indivíduo) deve satisfazer as restrições do problema representado pelas Eqs. (6.4 e 6.6).

**Passo 8:** a população pai  $P_t$  e a descendente  $Q_t$  são combinadas como  $R_t$  com um tamanho de  $2 * N_{pop}$ . Em seguida, a rápida classificação não-dominada é aplicada a  $R_t$  para classificar em diferentes níveis de não-dominância, ou seja,  $F_1, F_2$ , e assim por diante.

**Passo 9:** Gerar a próxima geração  $P_{t+1}$  (com base na  $F_1, F_2, \dots$ ). A partir de  $F_1$ , os indivíduos nos níveis mais elevados de não-dominância são adicionados à  $P_t$  até o seu tamanho atingir ou exceder  $N_{pop}$  pela primeira vez, assumindo o nível de não-dominância  $l$ . Os indivíduos (soluções) em níveis superiores de não-dominância  $l$  são simplesmente descartados. Se o tamanho da próxima geração  $P_{t+1}$  é  $N_{pop}$ , o algoritmo repete a etapa anterior na iteração seguinte através da geração de novos descendentes (se a condição de parada do algoritmo não é atingida), caso contrário, o outro  $N_{pop} - |P_{t+1}|$  indivíduos (soluções) são escolhidos a partir

de  $F_l$  com base em pontos de referência. Uma vez que os objetivos podem basear-se em diferentes escalas, eles são normalizados e pontos de referência são gerados no espaço normalizada. Então, para cada solução (indivíduo) é atribuído um ponto de referência.

**Passo 10:** Normalizar cada objetivo  $F_1, F_2$  e  $F_3$

**Passo 11:** Gerar pontos de referência: A novidade do algoritmo NSGA-III é a utilização de pontos de referência para selecionar indivíduos e preservar a diversidade da população.

**Passo 12:** Nicho de preservação da Operação. Depois de gerar os pontos de referência, são calculados: o raio de cada indivíduo a partir da linha de referência, a linha que liga a origem do espaço dos objetivos normalizados para o ponto de referência. Em seguida, para cada indivíduo é atribuído o ponto de referência mais próximo.

**Passo 13:** Verificar regra de parada: Neste trabalho, NSGA-II é executado por um número fixo de gerações. Verificar critério de parada. Se ele está satisfeito, então, vá para o Passo 14, se não, incrementar geração em 1 e voltar para o passo 6.

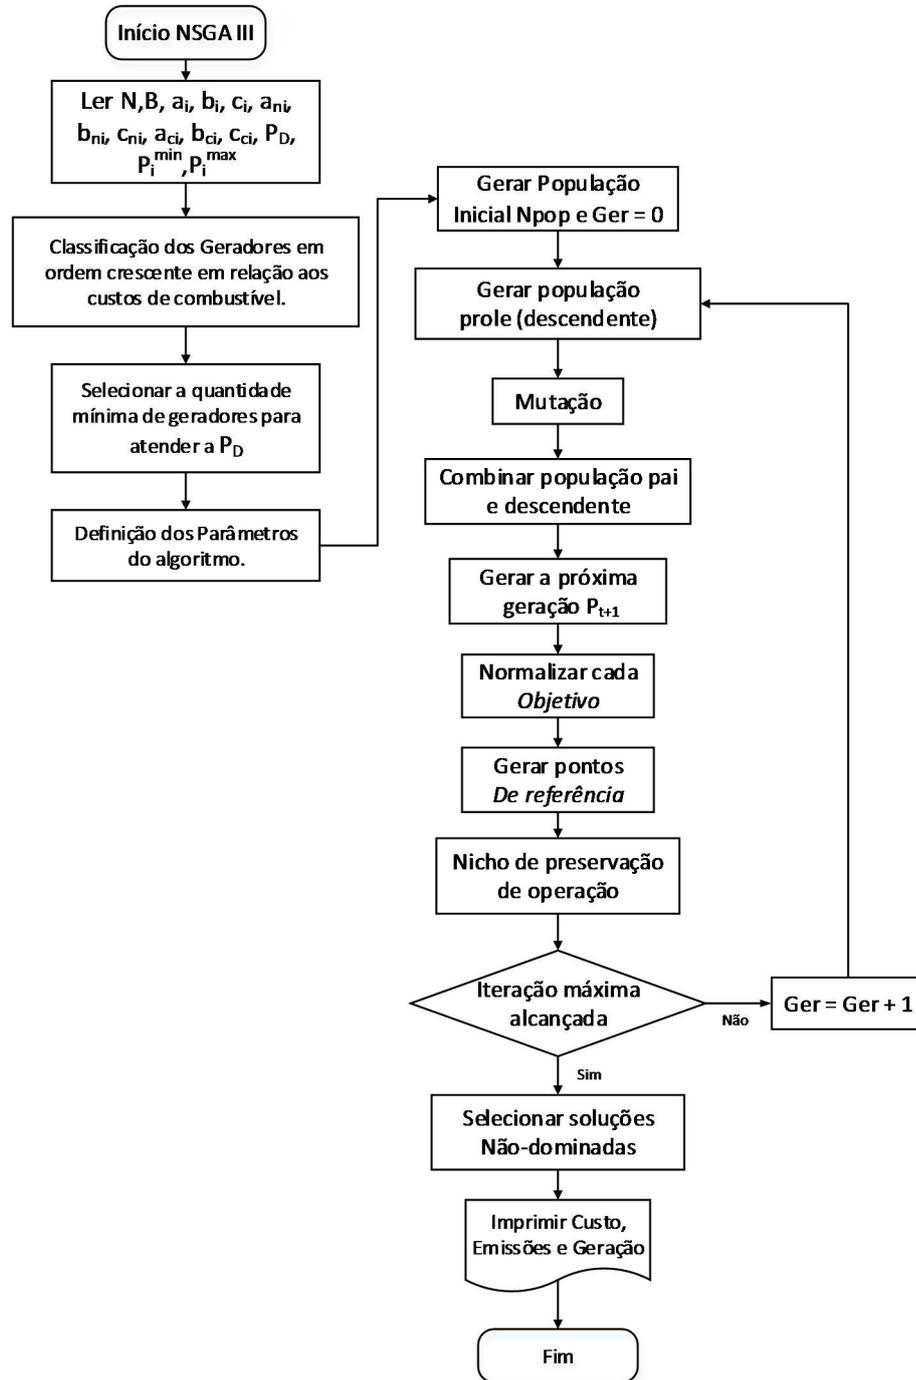
**Passo 14:** Selecionar as soluções não-dominadas na geração final (ótimo de Pareto).

**Passo 15:** Imprimir Custo, Emissão e Geração.

**Passo 16:** Fim.

A implementação do NSGA III, para resolver o problema do DEA está representada na figura 6.12.

Figura 6.12 – Fluxo da proposta NSGA III para Resolução do DEA.



Fonte: O Autor, (2016).

#### 6.5.4 NSGA III comparativo com o Sistema de Teste.

O processo de implementação é detalhado nos passos seguintes:

**Passo 1:** Carregar os dados da Usina (características dos geradores – Seção 6.2.4), o total de demanda de Potência Ativa a ser fornecida pela usina em MW - ( $P_D = 1500$  MW).

**Passo 2:** Ordenação dos coeficientes de custo dos geradores de acordo com o custo de combustível de cada gerador, em ordem decrescente.

**Passo 3:** Selecionar a quantidade mínima de geradores que atendam a demanda de potência ativa  $P_D$ ;

**Passo 4:** Definição dos parâmetros do algoritmo:

Tamanho da População – 50;

Número máximo de Gerações – 150.

Os parâmetros foram selecionados após 150 simulações de populações com diferentes tamanhos (número de indivíduos). A simulação com 50 indivíduos foi a que apresentou o menor custo total de combustível, com um desvio padrão de 16,51964 e coeficiente de variação de Pearson de 1,1005%.

**Passo 5:** A partir deste ponto, são executados os passos descritos na seção 6.5.3.

## 6.6 Conclusões do capítulo

Neste capítulo foram apresentados: as características de funcionamento da UTE (estudo de caso), os parâmetros de funcionamento das UTE's considerados para a otimização do DE/DEA para o estudo de caso e para o sistema de teste comparativo, a formulação matemática, a aplicação dos métodos determinísticos e heurísticos para resolução dos problemas (DE/DEA).

---

## CAPÍTULO VII

---

### APRESENTAÇÃO DOS RESULTADOS

#### 7.1 Introdução

Este capítulo apresenta os resultados da aplicação das técnicas, determinísticas e heurísticas, descritas no capítulo 6, fazendo uma comparação entre a solução tradicional e a nova solução proposta para o problema de otimização dos DE e do DEA, que contempla o desligamento dos geradores com maior custo de combustível no momento da otimização para determinada demanda de potência.

#### 7.2 Aplicação dos Métodos Determinísticos

Nesta seção serão apresentados os resultados da aplicação dos métodos de otimização determinísticos para resolução do DE, tendo como referência os parâmetros de funcionamento e a formulação matemática descrita na seção 6.2, comparando a solução clássica com a nova solução que contempla o desligamento dos geradores com o maior consumo de combustível.

##### 7.2.1 Aplicação do MIL – Estudo de Caso

Na Tabela 7.1, são apresentados os resultados após a execução do algoritmo do MIL, para o Estudo de Caso:

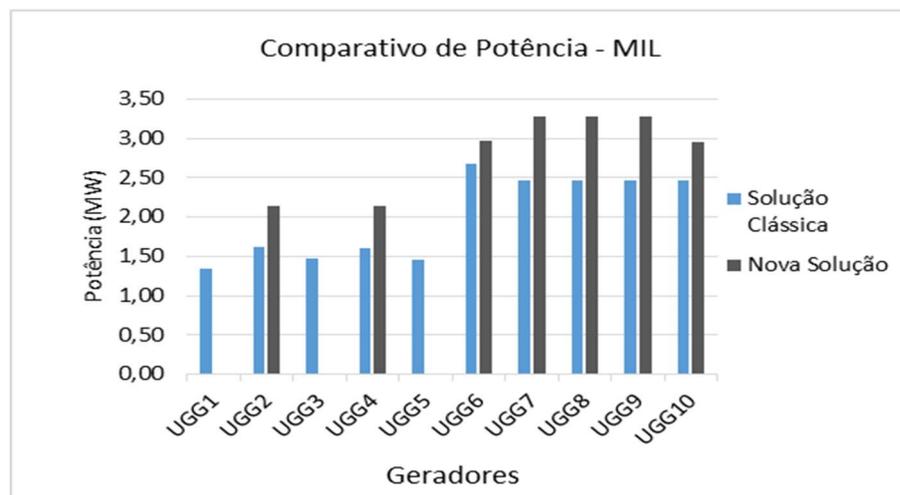
Tabela 7.1 - Relatório de saída do MIL – Estudo de Caso.

Parâmetros do DE usando MIL - SOLUÇÕES:	MIL -Solução Clássica	MIL - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,03 MW	0,05 MW		
Potência e Custo de saída dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
UGG1	1,35	249,46	0,00	0,000
UGG2	1,61	216,14	2,14	221,475
UGG3	1,47	232,50	0,00	0,000
UGG4	1,61	217,72	2,14	223,588
UGG5	1,46	235,39	0,00	0,000
UGG6	2,68	152,18	2,97	155,706
UGG7	2,46	164,54	3,28	176,024
UGG8	2,46	164,54	3,28	176,024
UGG9	2,46	164,54	3,28	176,024
UGG10	2,46	164,54	2,95	171,365
<b>Total</b>	<b>20,03</b>	<b>1961,52</b>	<b>20,05</b>	<b>1300,21</b>

Fonte: O Autor, (2016).

Tempo de Execução: 0,3443 segundos para solução clássica e 0,2629 segundos para a nova solução. O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização. Na figura 7.1, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

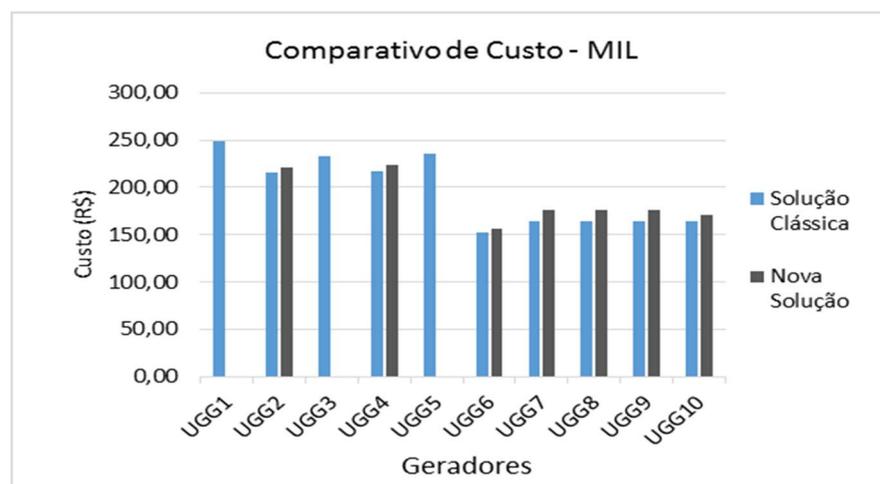
Figura 7.1 – Gráfico Comparativo de Potência MIL – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.2, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

Figura 7.2 – Gráfico Comparativo de Custo MIL – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o método de interação lambda, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, foram significativos obtendo uma redução de 33,71% no custo total de combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo. Ainda a nova solução possibilita ao especialista da UTE a possibilidade de realizar uma manutenção preditiva nos geradores que não estão sendo utilizadas no momento da otimização, a fim de melhorar a Eficiência, não só dos geradores, mas também do planejamento da geração da UTE.

### 7.2.2 Aplicação do MIL – Sistema de Teste

Na Tabela 7.2, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com maior custo, implementada com o MIL.

Tabela 7.2 - Comparação dos resultados de cada método com o MIL - Sistema de Teste.

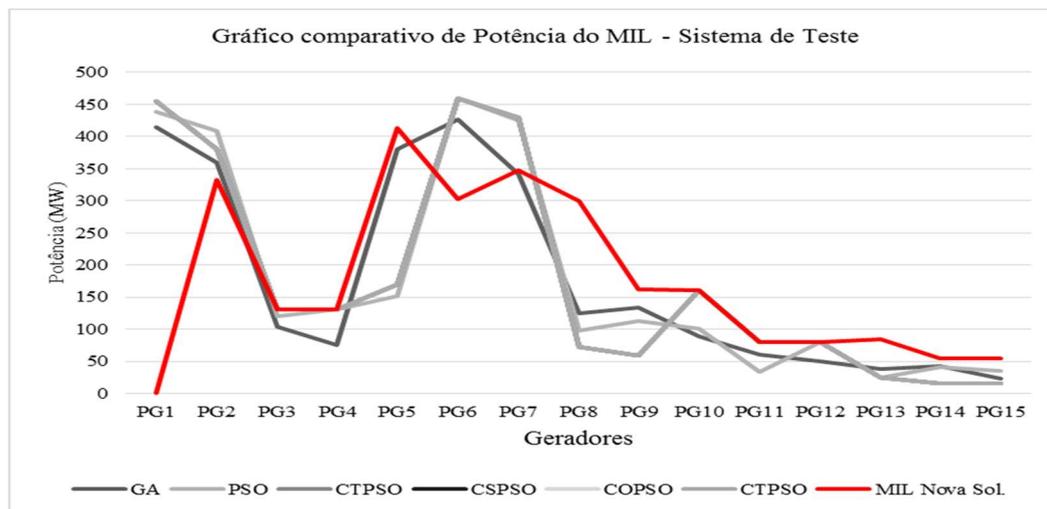
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	MIL nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	0,00
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	332,08
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	130,00
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	130,00
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	413,48
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	302,57
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	347,84
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	300,00
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	162,00
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	160,00
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	80,00
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	80,00
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	85,00
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	55,00
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	55,00
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2632,98</b>
P <sup>L</sup> (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>2,98</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.532,14</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 0,53% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.2, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com MIL.

Na figura 7.3, é visualizado o gráfico comparativo da Potência de saída de cada gerador com a nova solução proposta usando o MIL – Sistema de Teste.

Figura 7.3 - Gráfico Comparativo de Potência MIL vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.3, são apresentados os resultados após a execução do algoritmo do MIL, para o Sistema de Teste:

Tabela 7.3 - Relatório de saída do MIL – Sistema de Teste.

Parâmetros do DE usando MIL - SOLUÇÕES:	MIL -Solução Clássica	MIL - Nova solução desligando os Geradores
Total de $P^D$ :	2630 MW	2630 MW
Potência Mínima:	15 MW	15 MW
Potência Máxima:	470 MW	470 MW
Total de $P_L$ :	17,26 MW	2,98 MW

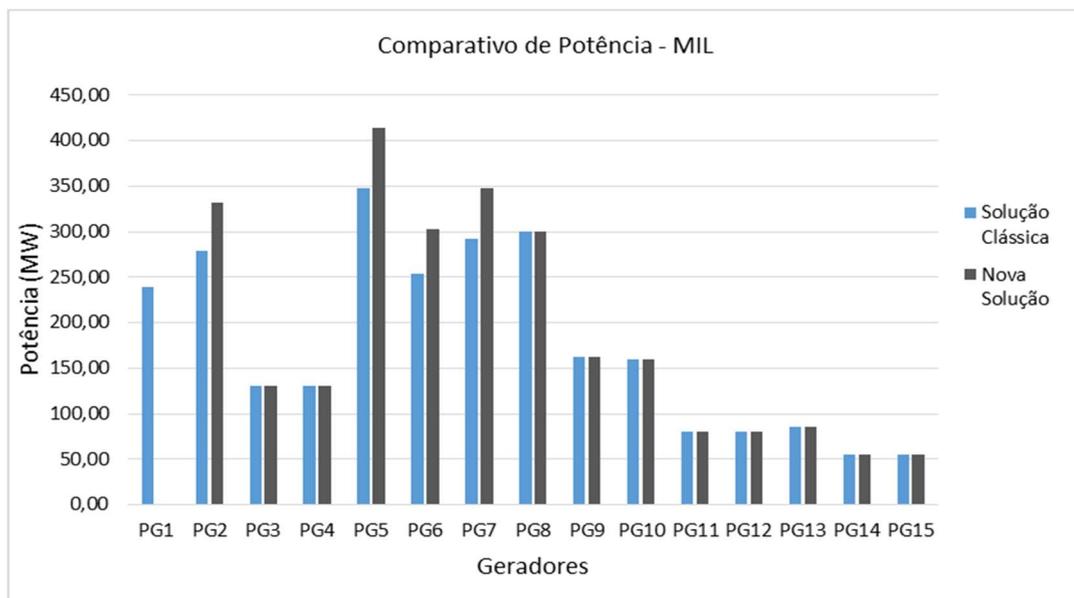
	Potência e Custo de saída dos Geradores:			
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>PG1</b>	238,46	3096,43	0,00	0,00
<b>PG2</b>	278,76	3431,53	332,08	3981,44
<b>PG3</b>	130,00	1537,03	130,00	1537,03
<b>PG4</b>	130,00	1537,03	130,00	1537,03
<b>PG5</b>	347,08	4095,37	413,48	4796,29
<b>PG6</b>	253,98	3214,59	302,57	3713,47
<b>PG7</b>	291,98	3440,45	347,84	4000,88
<b>PG8</b>	300,00	3617,42	300,00	3617,42
<b>PG9</b>	162,00	2008,58	162,00	2008,58
<b>PG10</b>	160,00	1917,80	160,00	1917,80
<b>PG11</b>	80,00	1024,95	80,00	1024,95
<b>PG12</b>	80,00	1057,28	80,00	1057,28
<b>PG13</b>	85,00	1341,18	85,00	1341,18
<b>PG14</b>	55,00	980,34	55,00	980,34
<b>PG15</b>	55,00	1018,45	55,00	1018,45
<b>Total</b>	<b>2647,26</b>	<b>33318,42</b>	<b>2632,98</b>	<b>32532,14</b>

Fonte: O Autor, (2016).

Tempo de Execução: 2,8172 segundos para solução clássica e 8,7930 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o menor custo (PG1) são desligados no momento da otimização. Na figura 7.4, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com MIL para o Sistema de Teste.

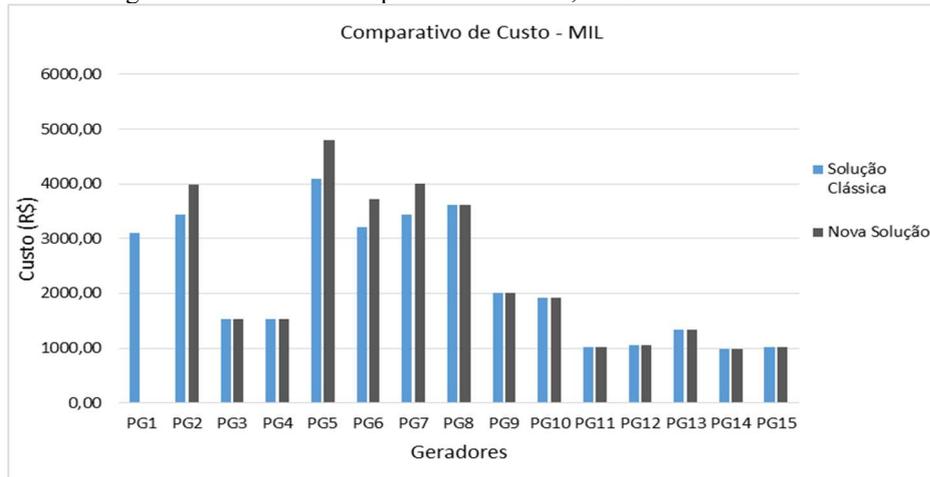
Figura 7.4 – Gráfico Comparativo de Potência, MIL - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.5, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementado com MIL para o Sistema de Teste.

Figura 7.5 – Gráfico Comparativo de Custo, MIL - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o método de interação lambda, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 2,36% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.2.3 Aplicação do MN – Estudo de Caso

Na Tabela 7.4, são apresentados os resultados após a execução do algoritmo do MN, para o Estudo de Caso:

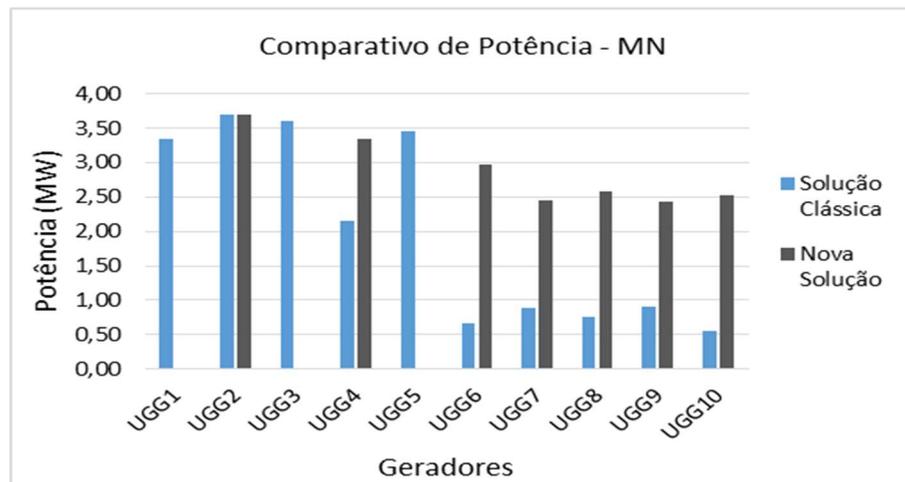
Tabela 7.4 - Relatório de saída do MN – Estudo de Caso.

Parâmetros do DE usando MN - SOLUÇÕES:	MN - Solução Clássica	MN - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,01 MW	0,01 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	3,3500	263,53	0,000	0,00
<b>UGG2</b>	3,7000	237,13	3,700	237,13
<b>UGG3</b>	3,6000	250,72	0,000	0,00
<b>UGG4</b>	2,1565	223,76	3,350	236,95
<b>UGG5</b>	3,4500	256,32	0,000	0,00
<b>UGG6</b>	0,6600	127,92	2,970	155,71
<b>UGG7</b>	0,8800	142,33	2,449	164,34
<b>UGG8</b>	0,7540	140,56	2,590	166,31
<b>UGG9</b>	0,9000	142,61	2,431	164,08
<b>UGG10</b>	0,5600	137,84	2,522	165,35
<b>Total</b>	<b>20,01</b>	<b>1922,72</b>	<b>20,01</b>	<b>1289,86</b>

Fonte: O Autor, (2016).

Tempo de Execução: 0,384180 segundos para solução clássica e 0,059871 segundos para a nova solução. O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização. Na figura 7.6, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

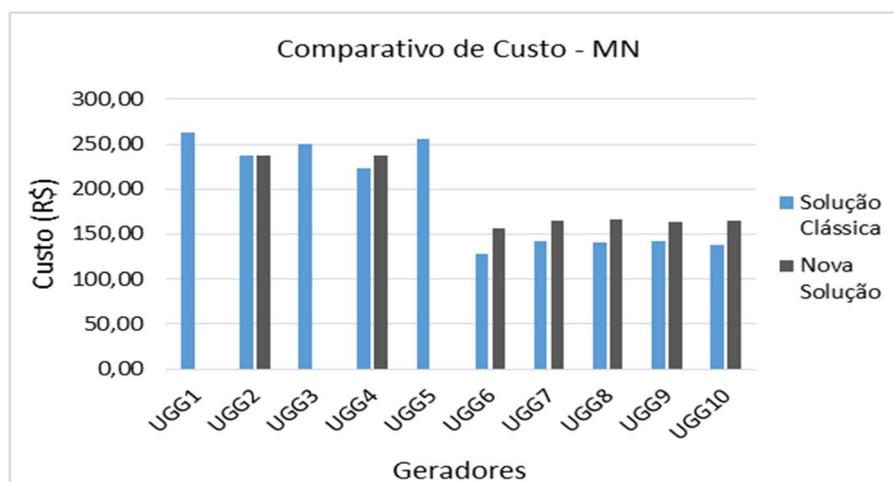
Figura 7.6 – Gráfico Comparativo de Potência MN – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.7, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

Figura 7.7 – Gráfico Comparativo de Custo MN – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o método Newton, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, foram significativos obtendo uma redução de 32,91% no custo total de combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível. Ainda a nova solução possibilita ao especialista da UTE a possibilidade de realizar uma manutenção preditiva nos geradores que não estão sendo utilizadas no momento da otimização, a fim de melhorar a Eficiência não só dos geradores, mas também do planejamento da geração da UTE.

#### 7.2.4 Aplicação do MN – Sistema de Teste

Na Tabela 7.5, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com maior custo de combustível implementada com o MN.

Tabela 7.5 - Comparação dos resultados de cada método com o MN - Sistema de Teste.

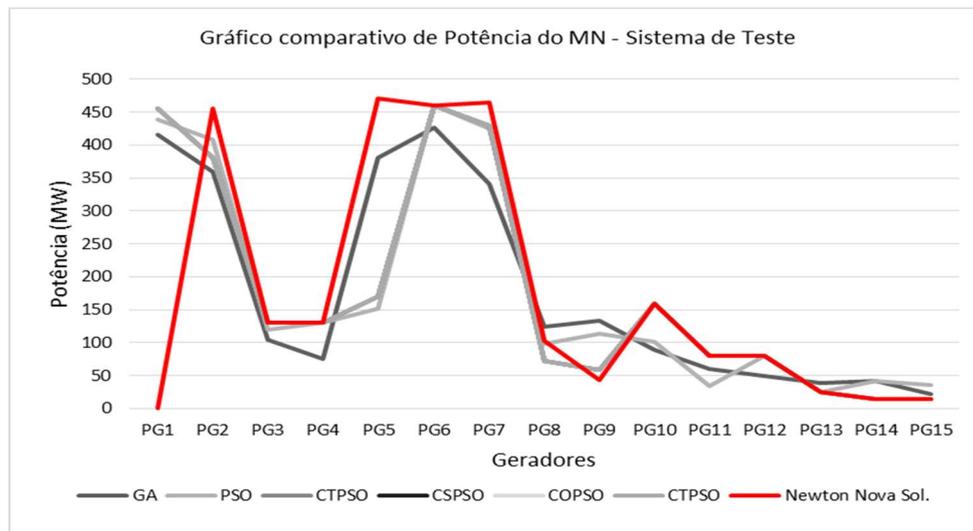
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	MN nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	0,00
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	455,00
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	130,00
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	130,00
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	470,00
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	460,00
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	465,00
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	102,67
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	43,14
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	160,00
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	80,00
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	80,00
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	25,00
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	15,00
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	15,00
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2630,81</b>
P <sup>L</sup> (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>0,81</b>
TC (R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>31.836,47</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 2,65% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.5, não levam em conta o valor adicional dos custos incrementais

considerados na nova solução implementada com MN. Na figura 7.8, é visualizado o gráfico comparativo da Potência de saída de cada gerador com a nova solução proposta usando o MN – Sistema de Teste.

Figura 7.8 - Gráfico Comparativo de Potência MN vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.6, são apresentados os resultados após a execução do algoritmo do MN, para o Sistema de Teste:

Tabela 7.6 - Relatório de saída do MN – Sistema de Teste.

Parâmetros do DE usando MN - SOLUÇÕES:	MN -Solução Clássica	MN - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	17,67 MW	0,81 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>PG1</b>	455,00	5328,40	0,00	0,00
<b>PG2</b>	455,00	5252,89	455,00	5252,89
<b>PG3</b>	130,00	1537,03	130,00	1537,03
<b>PG4</b>	130,00	1537,03	130,00	1537,03
<b>PG5</b>	232,82	2893,39	470,00	5394,28
<b>PG6</b>	460,00	5339,69	460,00	5339,69
<b>PG7</b>	465,00	5183,71	465,00	5183,71
<b>PG8</b>	60,00	900,22	102,67	1380,50
<b>PG9</b>	25,00	453,50	43,14	657,65
<b>PG10</b>	25,00	443,25	160,00	1917,80
<b>PG11</b>	74,85	969,59	80,00	1024,95
<b>PG12</b>	80,00	1057,28	80,00	1057,28
<b>PG13</b>	25,00	552,73	25,00	552,73
<b>PG14</b>	15,00	490,93	15,00	490,93
<b>PG15</b>	15,00	510,00	15,00	510,00
<b>Total</b>	<b>2647,67</b>	<b>32.449,65</b>	<b>2630,81</b>	<b>31836,47</b>

Fonte: O Autor, (2016).

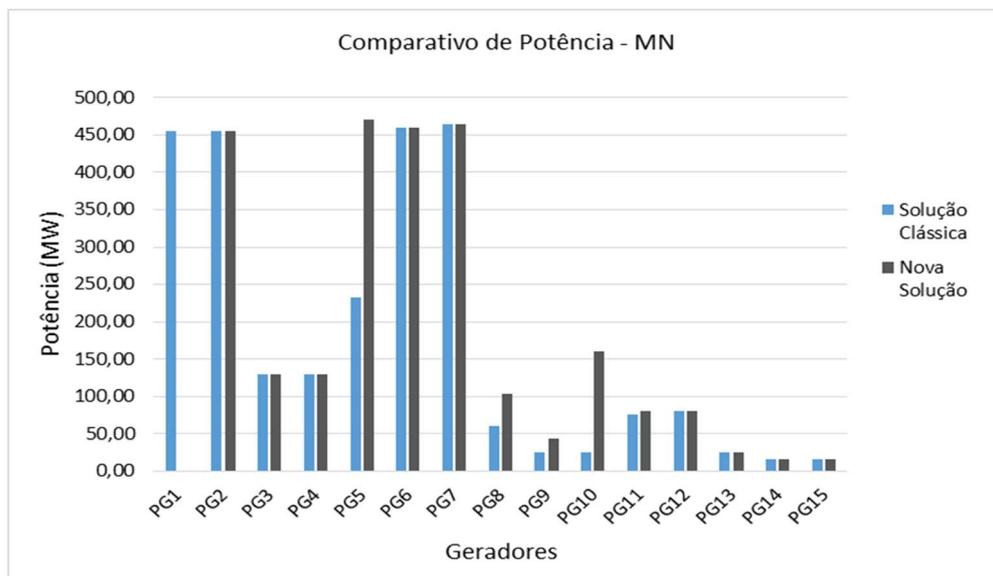
Tempo de Execução: 0,053604 segundos para solução clássica e 0,068119 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (PG1) são desligados no momento da otimização.

Na figura 7.9, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com MN para o Sistema de Teste.

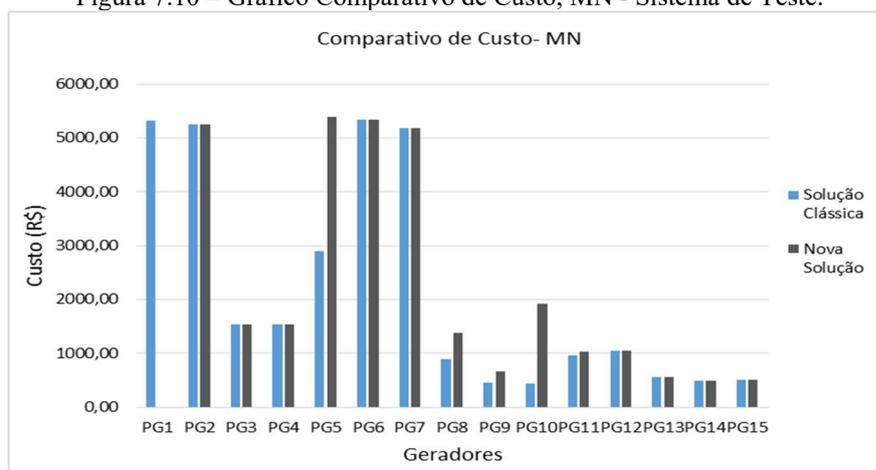
Figura 7.9 – Gráfico Comparativo de Potência, MN - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.10, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com MN para o Sistema de Teste.

Figura 7.10 – Gráfico Comparativo de Custo, MN - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o MN, contemplando o desligamento dos geradores com maior custo de combustível. Os resultados, com a nova solução, apresentaram uma redução de 1,89% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.2.5 Aplicação do Método da PQ – Estudo de Caso

Na Tabela 7.7, são apresentados os resultados após a execução do algoritmo do Método da PQ, para o Estudo de Caso:

Tabela 7.7 - Relatório de saída do MPQ – Estudo de Caso.

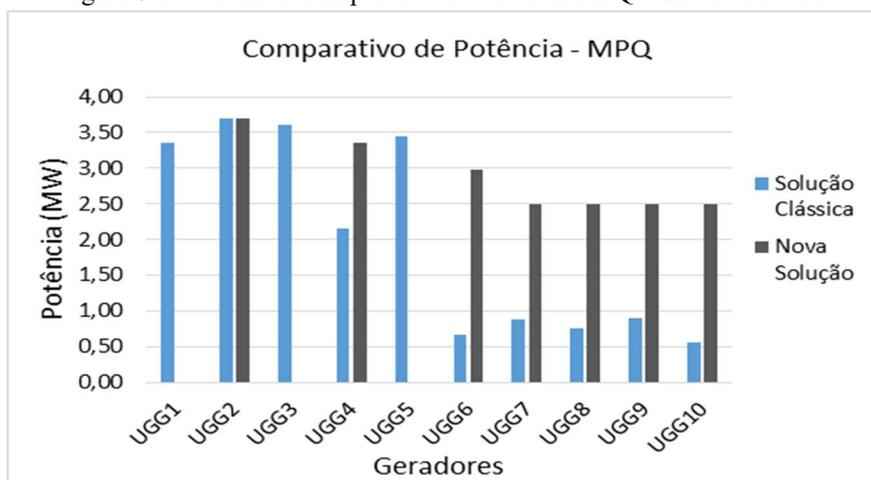
Parâmetros do DE usando MPQ - SOLUÇÕES:	MPQ - Solução Clássica	MPQ - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,01 MW	0,01 MW		
Potência e Custo de saída dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	3,35	263,53	0,00	0,00
<b>UGG2</b>	3,70	237,13	3,70	237,13
<b>UGG3</b>	3,60	250,72	0,00	0,00
<b>UGG4</b>	2,16	223,81	3,35	236,95
<b>UGG5</b>	3,45	256,32	0,00	0,00
<b>UGG6</b>	0,66	127,92	2,97	155,71
<b>UGG7</b>	0,88	142,33	2,50	165,03
<b>UGG8</b>	0,75	140,56	2,50	165,03
<b>UGG9</b>	0,90	142,61	2,50	165,03
<b>UGG10</b>	0,56	137,84	2,50	165,03
<b>Total</b>	<b>20,01</b>	<b>1922,76</b>	<b>20,01</b>	<b>1289,90</b>

Fonte: O Autor, (2016).

Tempo de Execução: 0,0436 segundos para solução clássica e 0,0312 segundos para a nova solução. O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização.

Na figura 7.11, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

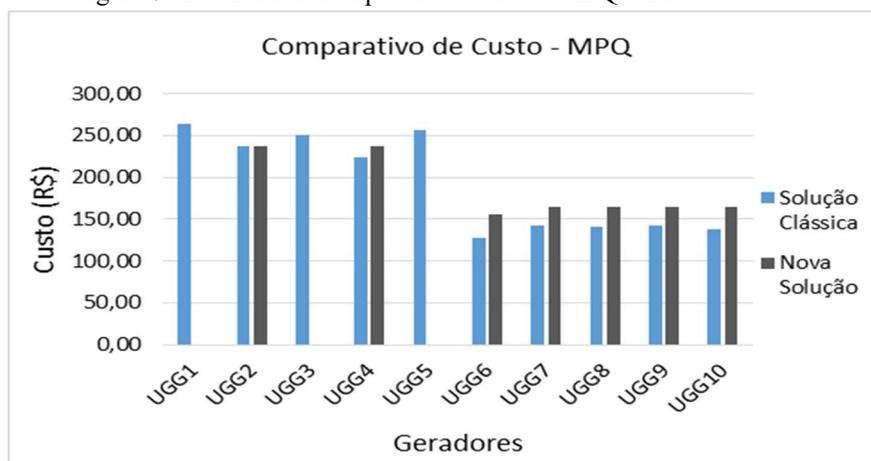
Figura 7.11 – Gráfico Comparativo de Potência MPQ – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.12, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta para o Estudo de Caso.

Figura 7.12 – Gráfico Comparativo de Custo MPQ – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o método da PQ, contemplando o desligamento dos geradores com o maior custo de combustível.

Os resultados, com a nova solução, foram significativos obtendo uma redução de 32,91% no custo total de combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

Ainda a nova solução possibilita ao especialista da UTE a possibilidade de realizar uma manutenção preditiva nos geradores que não estão sendo utilizadas no momento da otimização, a fim de melhorar a eficiência não só dos geradores, mas também do planejamento da geração da UTE.

### 7.2.6 Aplicação do Método da PQ – Sistema de Teste

Na Tabela 7.8, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com o maior custo de combustível implementada com o MPQ.

Tabela 7.8 - Comparação dos resultados de cada método com o MPQ - Sistema de Teste.

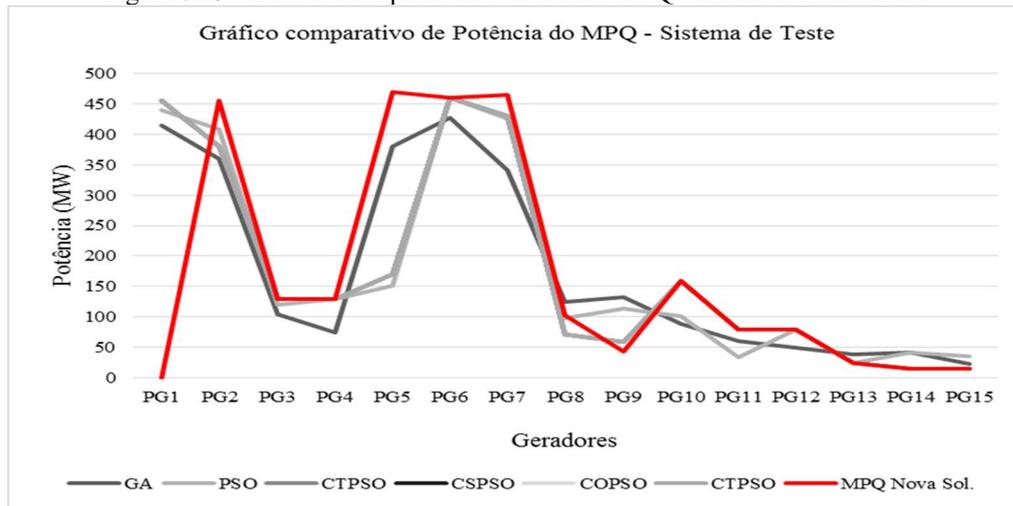
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	MPQ nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	0,00
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	455,00
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	130,00
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	130,00
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	470,00
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	460,00
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	465,00
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	102,77
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	43,04
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	160,00
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	80,00
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	80,00
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	25,00
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	15,00
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	15,00
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2630,81</b>
$P^L$ (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>0,81</b>
TC(MW)	33.113	32.858	32.704	32.704	32.704	32.704	<b>31836,50</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 2,65% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos

apresentados na tabela 7.8, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com MPQ. Na figura 7.13, é visualizado o gráfico comparativo da Potência de saída de cada gerador com a nova solução proposta usando o MPQ – Sistema de Teste.

Figura 7.13 - Gráfico Comparativo de Potência MPQ – Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.9, são apresentados os resultados após a execução do algoritmo do Método da PQ, para o Sistema de Teste:

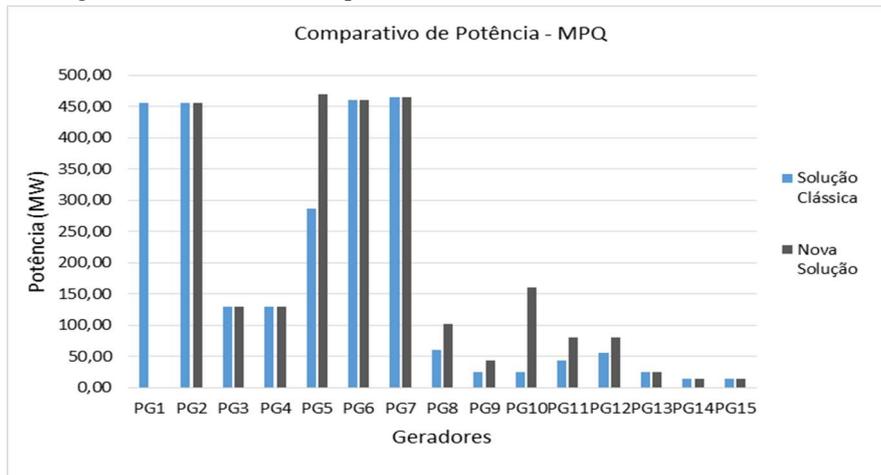
Tabela 7.9 - Relatório de saída do MPQ – Sistema de Teste.

Parâmetros do DE usando MPQ - SOLUÇÕES:	MPQ -Solução Clássica	MPQ - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	17,47 MW	0,81 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i (MW)$	Custo (R\$)	Potência $P_i (MW)$	Custo (R\$)
<b>PG1</b>	455,00	5328,40	0,00	0,00
<b>PG2</b>	455,00	5252,89	455,00	5252,89
<b>PG3</b>	130,00	1537,03	130,00	1537,03
<b>PG4</b>	130,00	1537,03	130,00	1537,03
<b>PG5</b>	287,14	3464,15	470,00	5394,28
<b>PG6</b>	460,00	5339,69	460,00	5339,69
<b>PG7</b>	465,00	5183,71	465,00	5183,71
<b>PG8</b>	60,00	900,22	102,77	1381,59
<b>PG9</b>	25,00	453,50	43,04	656,59
<b>PG10</b>	25,00	443,25	160,00	1917,80
<b>PG11</b>	44,30	644,91	80,00	1024,95
<b>PG12</b>	56,02	801,95	80,00	1057,28
<b>PG13</b>	25,00	552,73	25,00	552,73
<b>PG14</b>	15,00	490,93	15,00	490,93
<b>PG15</b>	15,00	510,00	15,00	510,00
<b>Total</b>	<b>2647,47</b>	<b>32.440,39</b>	<b>2630,81</b>	<b>31836,50</b>

Fonte: O Autor, (2016).

Tempo de Execução: 0,06718 segundos para solução clássica e 0,0519 segundos para a nova solução. O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo (PG1) são desligados no momento da otimização. Na figura 7.14, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com MPQ para o Sistema de Teste.

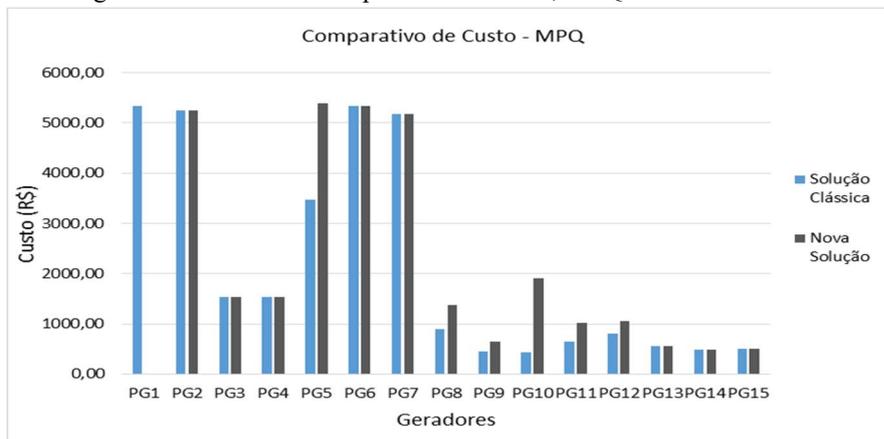
Figura 7.14 – Gráfico Comparativo de Potência, MPQ - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.15, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com MPQ para o Sistema de Teste.

Figura 7.15 – Gráfico Comparativo de Custo, MPQ - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o método da PQ, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 1,86% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3 Aplicação dos Métodos Heurísticos Mono-objetivo

Nesta seção serão apresentados os resultados da aplicação dos métodos de otimização Heurísticos Mono-objetivo para resolução do DE, tendo como referência os parâmetros de funcionamento e a formulação matemática descrita na seção 6.2, comparando a solução clássica com a nova solução que contempla o desligamento dos geradores com o maior consumo de combustível.

#### 7.3.1 Otimização do DE por Algoritmo Genético (AG) – Estudo de caso

Na Tabela 7.10, são apresentados os resultados após a execução do AG, para o Estudo de Caso.

Tabela 7.10 - Relatório de saída do AG – Estudo de Caso.

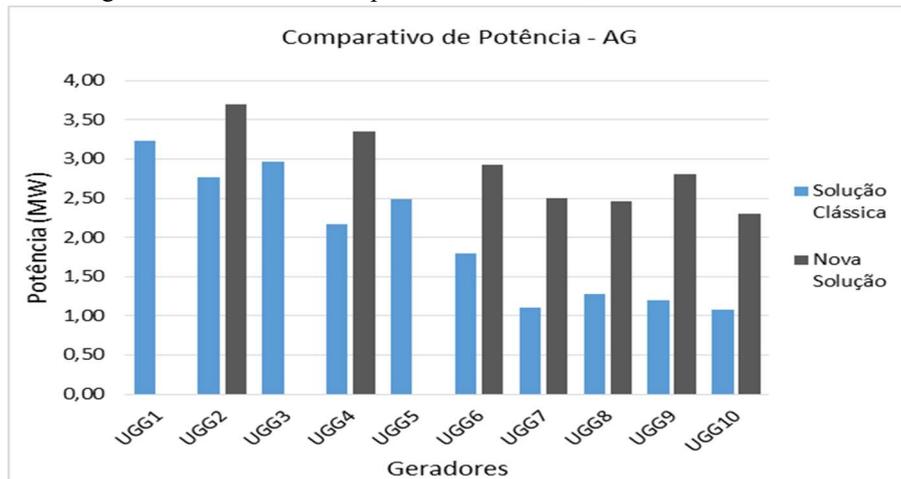
Parâmetros do DE usando AG - SOLUÇÕES:	AG - Solução Clássica	AG - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0749 MW	0,0493 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>UGG1</b>	3,23	262,65	Desl.	0,00
<b>UGG2</b>	2,77	227,77	3,70	237,12
<b>UGG3</b>	2,96	245,25	Desl.	0,00
<b>UGG4</b>	2,16	223,83	3,35	236,95
<b>UGG5</b>	2,49	246,21	Desl.	0,00
<b>UGG6</b>	1,80	141,64	2,92	155,13
<b>UGG7</b>	1,10	145,44	2,50	165,11
<b>UGG8</b>	1,27	147,85	2,47	164,59
<b>UGG9</b>	1,20	146,83	2,80	169,30
<b>UGG10</b>	1,085	145,198	2,304	162,294
<b>Total</b>	<b>20,0749</b>	<b>1932,67</b>	<b>20,0493</b>	<b>1290,49</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 6,6788 segundos para solução clássica e 4,6649 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo (UGG1, UGG3 e UGG5) são desligados no momento da otimização. Na figura 7.16, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com AG para o Estudo de Caso.

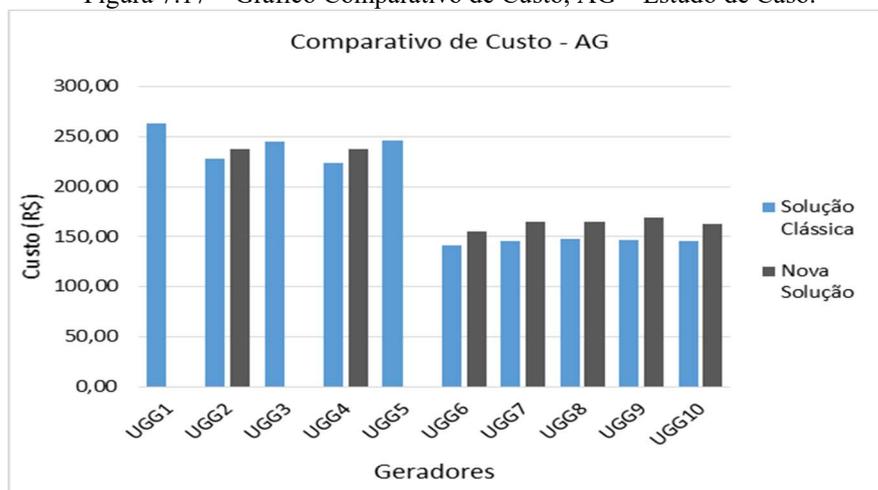
Figura 7.16 – Gráfico Comparativo de Potência, AG – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.17, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com AG para o Estudo de Caso.

Figura 7.17 – Gráfico Comparativo de Custo, AG – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o AG, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 33,23% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.2 GA comparativo com o Sistema de Teste.

Na Tabela 7.11, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com maior custo de combustível implementada com o AG.

Tabela 7.11 - Comparação dos resultados de cada método para o Sistema de Teste.

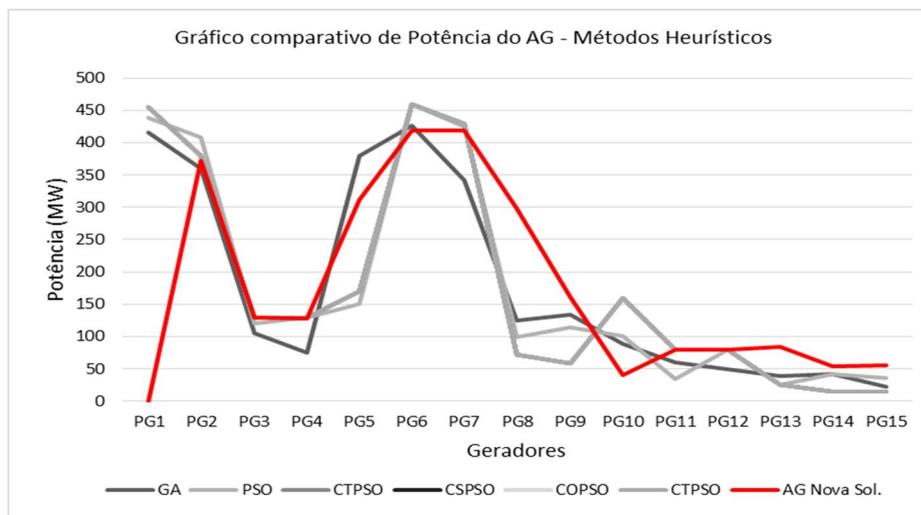
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	AG nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	347,23
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	129,55
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	128,15
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	369,72
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	411,04
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	391,80
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	299,40
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	161,21
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	40,08
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	80,00
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	80,00
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	83,69
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	54,67
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	54,734
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2.631,28</b>
P <sub>L</sub> (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>1,28</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.414,37</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 0,89% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.11, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com AG.

Na figura 7.18 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.18 - Gráfico Comparativo de Potência AG vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.12, são apresentados os resultados após a execução do AG, para o Sistema de Teste:

Tabela 7.12 - Relatório de saída do AG – Sistema de Teste.

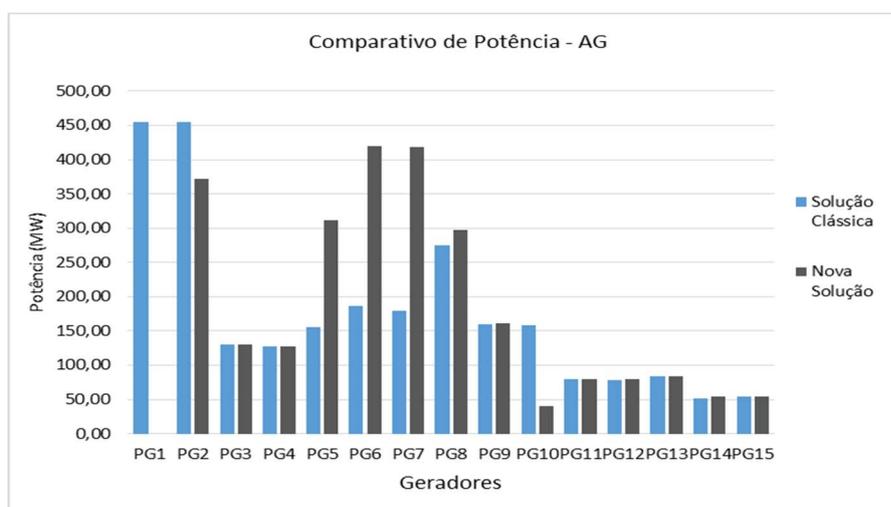
Parâmetros do DE usando AG - SOLUÇÕES:	AG - Solução Clássica	AG - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	1,15 MW	1,28 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>PG1</b>	455,00	5328,40	Desl.	0,00
<b>PG2</b>	455,00	5252,89	347,23	4137,82
<b>PG3</b>	130,00	1537,03	129,55	1532,90
<b>PG4</b>	127,41	1513,47	128,15	1520,25
<b>PG5</b>	156,01	2088,48	369,72	4334,09
<b>PG6</b>	187,05	2529,73	411,04	4832,40
<b>PG7</b>	179,50	2318,85	391,80	4443,47
<b>PG8</b>	274,61	3328,16	299,40	3610,62
<b>PG9</b>	160,35	1989,71	161,21	1999,57
<b>PG10</b>	158,35	1899,53	40,08	605,82
<b>PG11</b>	79,57	1020,33	80,00	1024,95
<b>PG12</b>	78,46	1040,66	80,00	1057,28
<b>PG13</b>	83,27	1318,43	83,69	1323,90
<b>PG14</b>	52,07	944,25	54,67	976,28
<b>PG15</b>	54,492	1011,909	54,734	1015,022
<b>Total</b>	<b>2631,15</b>	<b>33121,82</b>	<b>2631,28</b>	<b>32414,37</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 6,2769 segundos para solução clássica e 10,1626 segundos para a nova solução. O relatório de soluções apresenta: parâmetros de entrada para executar o AG; total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos

de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com a menor eficiência (PG1) são desligados no momento da otimização. Na figura 7.19, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com AG para o Sistema de Teste.

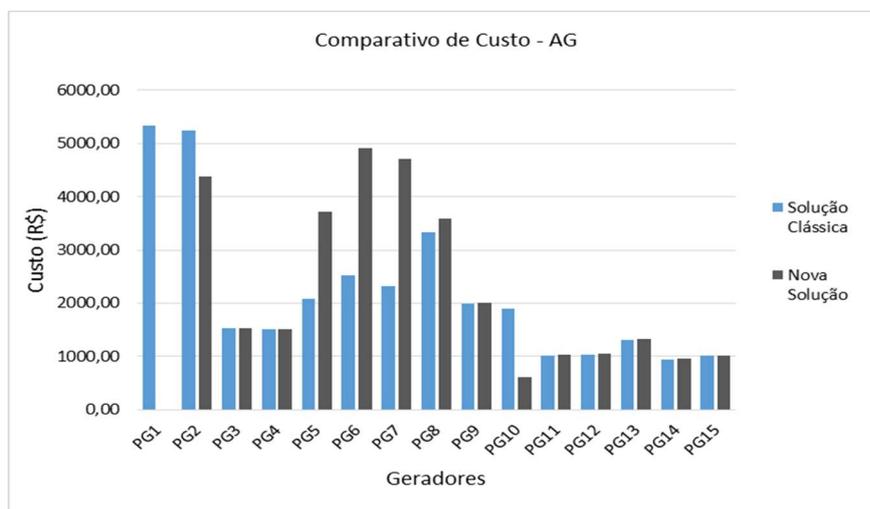
Figura 7.19 – Gráfico Comparativo de Potência, AG - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.20, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com AG para o Sistema de Teste.

Figura 7.20 – Gráfico Comparativo de Custo, AG - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o AG, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 2,20% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.3 Otimização do DE por Enxame de Partículas (PSO) – Estudo de caso.

Na Tabela 7.13, são apresentados os resultados após a execução do PSO, para o Estudo de Caso.

Tabela 7.13 - Relatório de saída do PSO – Estudo de Caso.

Parâmetros do DE usando PSO - SOLUÇÕES:	PSO - Solução Clássica	PSO - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0105 MW	0,0130 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	3,35	263,52	Desl.	0,00
<b>UGG2</b>	3,66	236,72	3,25	232,61
<b>UGG3</b>	3,60	250,71	Desl.	0,00
<b>UGG4</b>	2,33	225,69	2,84	231,28
<b>UGG5</b>	3,27	254,44	Desl.	0,00
<b>UGG6</b>	0,70	128,40	2,55	150,63
<b>UGG7</b>	0,88	142,33	2,87	170,22
<b>UGG8</b>	0,75	140,57	2,74	168,42
<b>UGG9</b>	0,90	142,62	3,35	176,97
<b>UGG10</b>	0,564	137,899	2,420	163,921
<b>Total</b>	<b>20,0105</b>	<b>1922,90</b>	<b>20,0130</b>	<b>1294,04</b>

Fonte: O Autor, (2016).

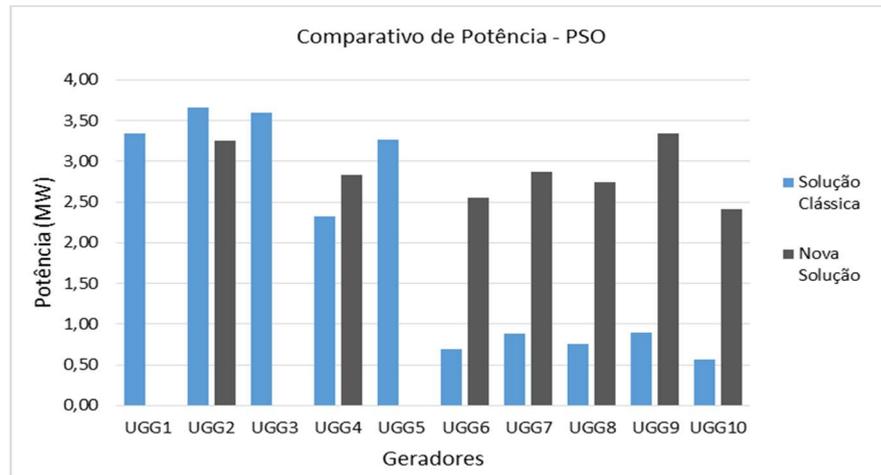
Tempo Médio de Execução: 5,4353 segundos para solução clássica e 3,7447 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo (UGG1, UGG3 e UGG5) são desligados no momento da otimização.

Na figura 7.21, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com PSO para o Estudo de Caso.

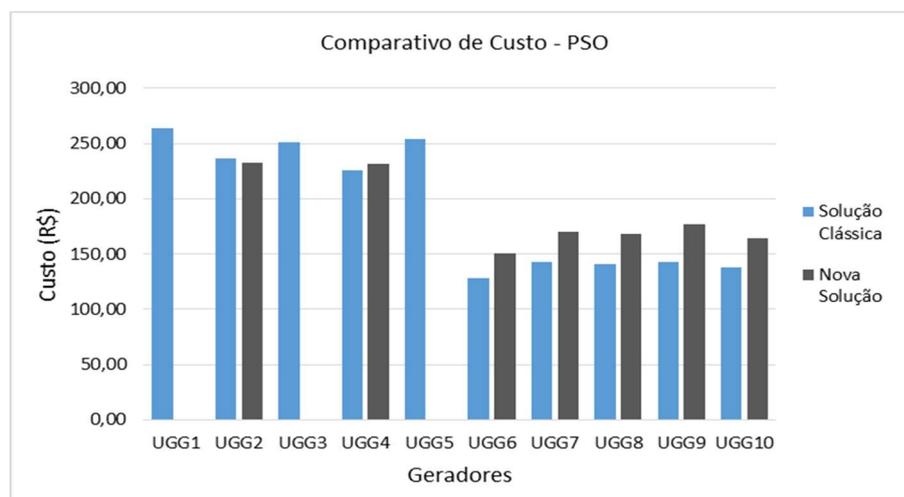
Figura 7.21 – Gráfico Comparativo de Potência, PSO – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.22, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com PSO para o Estudo de Caso.

Figura 7.22 – Gráfico Comparativo de Custo, PSO – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o PSO, contemplando o desligamento dos geradores com o maior custo.

Os resultados, com a nova solução, apresentaram uma redução de 32,70% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.4 PSO comparativo com o Sistema de Teste.

Na Tabela 7.14, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com o maior custo de combustível implementada com o PSO.

Tabela 7.14 - Comparação dos resultados de cada método para o Sistema de Teste.

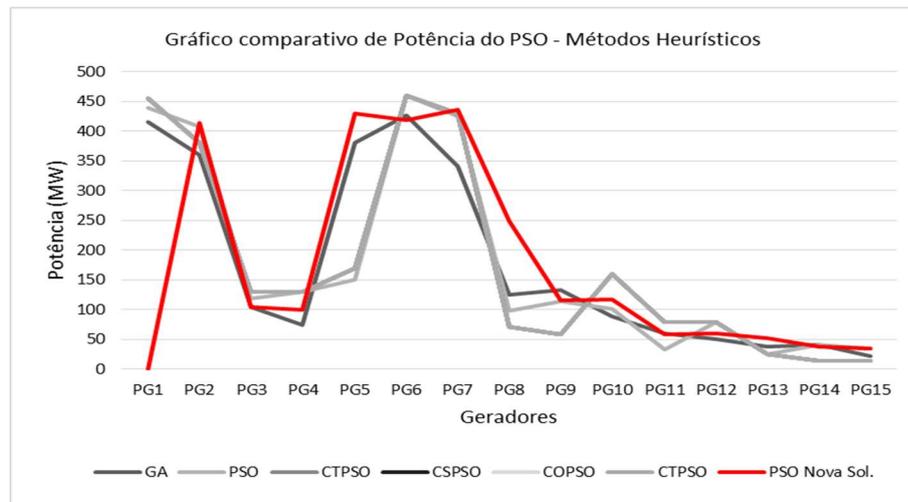
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	PSO nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	413,39
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	104,16
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	100,36
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	429,53
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	419,18
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	436,95
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	248,57
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	116,49
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	118,13
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	58,36
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	59,89
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	53,08
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	38,17
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	34,774
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	2631,03
$P_L$ (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>1,03</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.242,33</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 1,41% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.14, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com PSO.

Na figura 7.23 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.23 - Gráfico Comparativo de Potência PSO vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.15, são apresentados os resultados após a execução do PSO, para o Sistema de Teste:

Tabela 7.15 - Relatório de saída do PSO – Sistema de Teste.

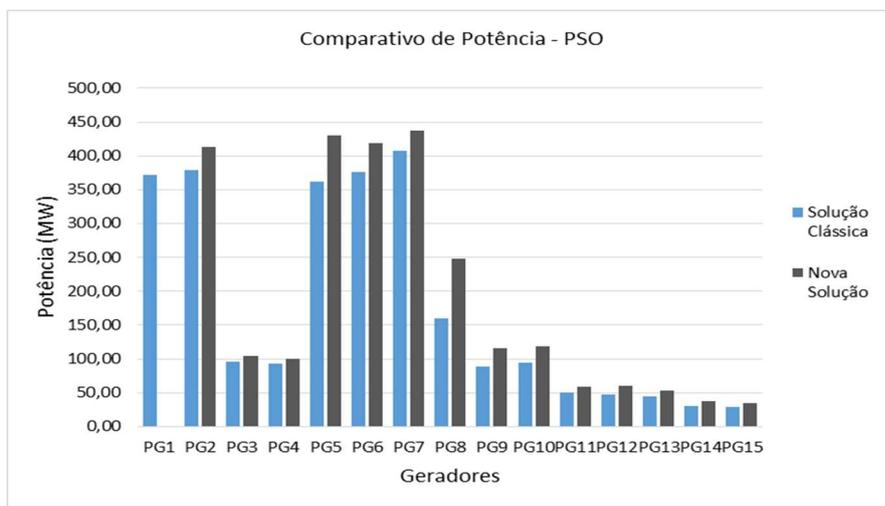
Parâmetros do DE usando PSO - SOLUÇÕES:	PSO -Solução Clássica	PSO - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	0,76 MW	1,03 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i (MW)$	Custo (R\$)	Potência $P_i (MW)$	Custo (R\$)
<b>PG1</b>	372,22	4471,81	Desl.	0,00
<b>PG2</b>	379,30	4469,24	413,39	4821,81
<b>PG3</b>	95,39	1223,72	104,16	1302,81
<b>PG4</b>	92,57	1198,27	100,36	1268,53
<b>PG5</b>	361,61	4248,55	429,53	4965,90
<b>PG6</b>	375,64	4466,47	419,18	4916,61
<b>PG7</b>	408,13	4608,27	436,95	4899,63
<b>PG8</b>	159,81	2025,53	248,57	3031,86
<b>PG9</b>	88,74	1173,22	116,49	1488,60
<b>PG10</b>	94,43	1196,17	118,13	1455,75
<b>PG11</b>	51,00	715,48	58,36	793,53
<b>PG12</b>	47,90	716,83	59,89	842,66
<b>PG13</b>	44,12	803,73	53,08	921,41
<b>PG14</b>	30,96	685,50	38,17	773,64
<b>PG15</b>	28,927	685,421	34,774	759,576
<b>Total</b>	<b>2630,76</b>	<b>32688,23</b>	<b>2631,03</b>	<b>32242,33</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 4,6827 segundos para solução clássica e 2,2206 segundos para a nova solução. O relatório de soluções apresenta: os parâmetros de entrada para executar o PSO; total de demanda de potência  $P^D$ ; capacidade mínima e máxima de potência da UTE;

custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (PG1) são desligados no momento da otimização. Na figura 7.24, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com PSO para o Sistema de Teste.

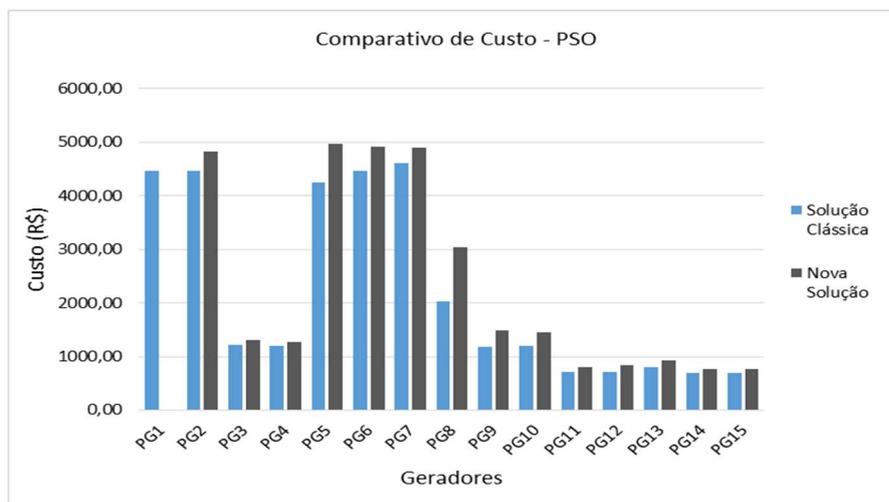
Figura 7.24 – Gráfico Comparativo de Potência, PSO - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.25, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com PSO para o Sistema de Teste.

Figura 7.25 – Gráfico Comparativo de Custo, PSO - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE foi resolvido considerando o custo incremental e implementado com o PSO, contemplando o desligamento dos geradores com o maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 1,36% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível.

### 7.3.5 Otimização do DE por Evolução Diferencial (ED) – Estudo de caso.

Na Tabela 7.16, são apresentados os resultados após a execução do ED, para o Estudo de Caso.

Tabela 7.16 - Relatório de saída do ED – Estudo de Caso.

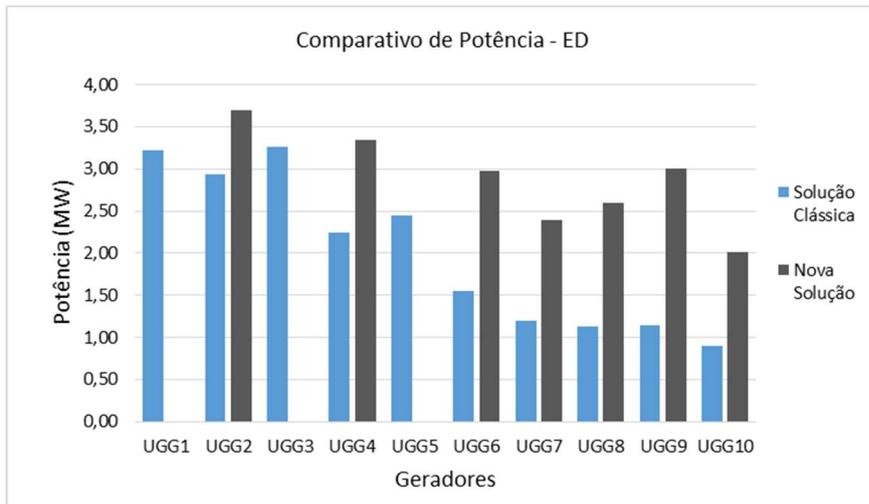
Parâmetros do DE usando ED - SOLUÇÕES:	ED - Solução Clássica	ED - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0143 MW	0,0238 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>UGG1</b>	3,35	263,53	Desl.	0,00
<b>UGG2</b>	3,70	237,13	3,70	237,13
<b>UGG3</b>	3,60	250,72	Desl.	0,00
<b>UGG4</b>	1,52	216,73	3,35	236,91
<b>UGG5</b>	1,34	234,11	Desl.	0,00
<b>UGG6</b>	1,23	134,78	2,97	155,71
<b>UGG7</b>	1,38	149,29	2,39	163,53
<b>UGG8</b>	1,33	148,69	2,59	166,35
<b>UGG9</b>	1,44	150,18	3,01	172,21
<b>UGG10</b>	1,121	145,705	2,013	158,210
<b>Total</b>	<b>20,0143</b>	<b>1930,86</b>	<b>20,0238</b>	<b>1290,04</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 81,9145 segundos para solução clássica e 83,8331 segundos para a nova solução. O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização. Na figura 7.26, é visualizado o

gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com ED para o Estudo de Caso.

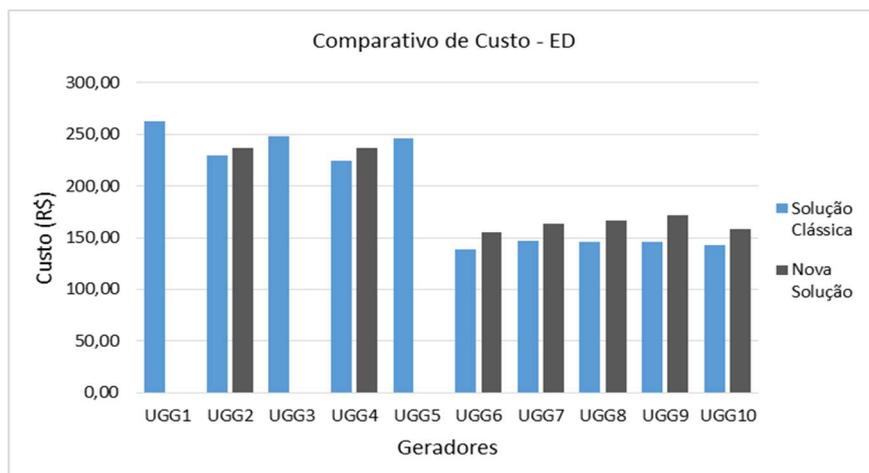
Figura 7.26 – Gráfico Comparativo de Potência, ED – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.27, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com ED para o Estudo de Caso.

Figura 7.27 – Gráfico Comparativo de Custo, ED – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o ED, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 33,16% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.6 ED comparativo com o Sistema de Teste.

Na Tabela 7.17, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com maior custo de combustível implementada com o ED.

Tabela 7.17 - Comparação dos resultados de cada método para o Sistema de Teste.

Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	ED nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	439,03
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	127,74
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	120,48
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	457,35
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	447,11
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	458,11
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	136,96
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	92,22
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	117,24
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	65,04
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	65,15
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	40,08
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	29,59
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	34,231
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2630,32</b>
$P_L$ (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>0,32</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>31.995,57</b>

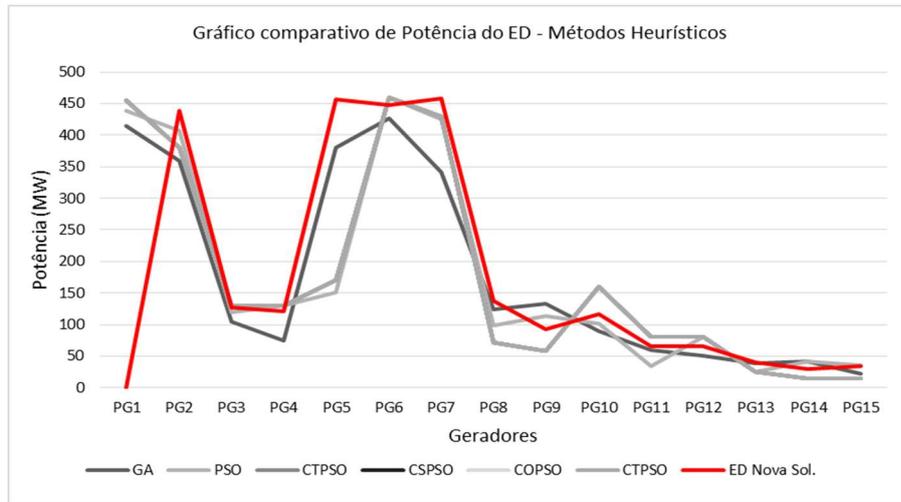
Fonte: O Autor, (2016).

A nova solução obtém uma economia de 2,17% em relação ao menor resultado encontrado por outros métodos.

É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.17, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com ED.

Na figura 7.28 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.28 - Gráfico Comparativo de Potência ED vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.18, são apresentados os resultados após a execução do ED, para o Sistema de Teste:

Tabela 7.18 - Relatório de saída do ED – Sistema de Teste.

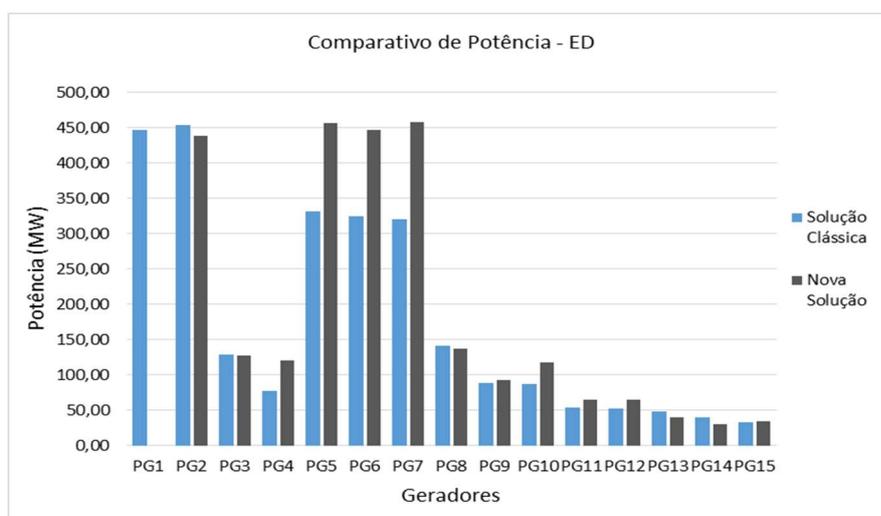
Parâmetros do DE usando ED - SOLUÇÕES:	ED - Solução Clássica	ED - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	0,84 MW	0,32 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>PG1</b>	447,58	5251,42	Desl.	0,00
<b>PG2</b>	454,40	5246,68	439,03	5087,33
<b>PG3</b>	129,13	1529,11	127,74	1516,45
<b>PG4</b>	77,15	1059,65	120,48	1450,58
<b>PG5</b>	331,81	3934,41	457,35	5260,31
<b>PG6</b>	324,71	3941,29	447,11	5205,97
<b>PG7</b>	320,46	3725,91	458,11	5113,91
<b>PG8</b>	141,06	1813,62	136,96	1767,26
<b>PG9</b>	88,84	1174,33	92,22	1212,72
<b>PG10</b>	86,86	1113,53	117,24	1446,05
<b>PG11</b>	54,46	752,12	65,04	864,52
<b>PG12</b>	53,01	770,31	65,15	898,35
<b>PG13</b>	48,36	859,36	40,08	750,65
<b>PG14</b>	39,73	792,74	29,59	668,78
<b>PG15</b>	33,281	740,613	34,231	752,670
<b>Total</b>	<b>2630,84</b>	<b>32705,09</b>	<b>2630,32</b>	<b>31995,57</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 55,5858 segundos para solução clássica e 108,5940 segundos para a nova solução. O relatório de soluções apresenta: os parâmetros de entrada para executar o ED; total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE;

custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo (PG1) são desligados no momento da otimização. Na figura 7.29, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com ED para o Sistema de Teste.

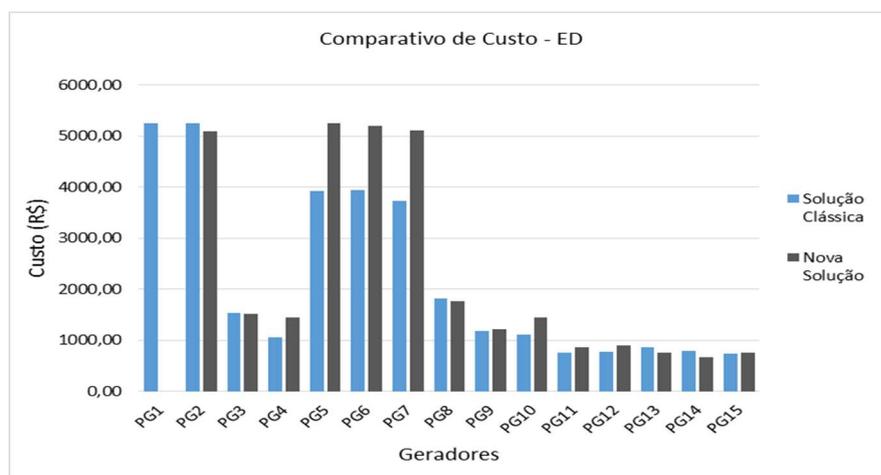
Figura 7.29 – Gráfico Comparativo de Potência, ED - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.30, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com ED para o Sistema de Teste.

Figura 7.30 – Gráfico Comparativo de Custo, ED - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE foi resolvido considerando o custo incremental e implementado com o ED, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 2,22% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.7 Otimização do DE por Lobo Cinzento (GWO) – Estudo de caso.

Na Tabela 7.19, são apresentados os resultados após a execução do GWO, para o Estudo de Caso.

Tabela 7.19 - Relatório de saída do GWO – Estudo de Caso.

Parâmetros do DE usando GWO - SOLUÇÕES:	GWO - Solução Clássica	GWO - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0202 MW	0,0194 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	2,02	254,17	Desl.	0,00
<b>UGG2</b>	2,54	225,47	3,22	232,32
<b>UGG3</b>	2,18	238,57	Desl.	0,00
<b>UGG4</b>	1,94	221,36	2,77	230,50
<b>UGG5</b>	2,03	241,35	Desl.	0,00
<b>UGG6</b>	1,77	141,29	2,90	154,92
<b>UGG7</b>	2,09	159,30	2,90	170,72
<b>UGG8</b>	1,86	156,05	2,70	167,88
<b>UGG9</b>	2,33	162,63	3,36	177,11
<b>UGG10</b>	1,262	147,684	2,162	160,298
<b>Total</b>	<b>20,0202</b>	<b>1947,86</b>	<b>20,0194</b>	<b>1293,74</b>

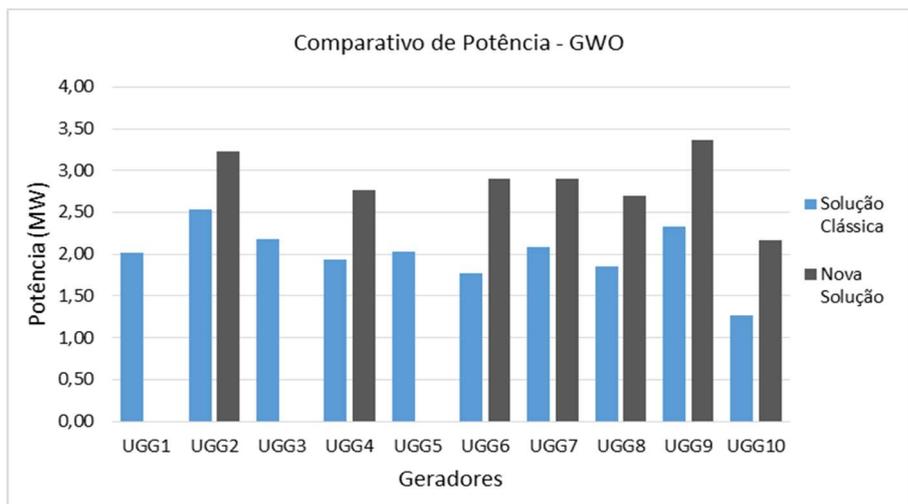
Fonte: O Autor, (2016).

Tempo Médio de Execução: 68,3052 segundos para solução clássica e 65,2970 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização. Na figura 7.31, é visualizado o gráfico

comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com GWO para o Estudo de Caso.

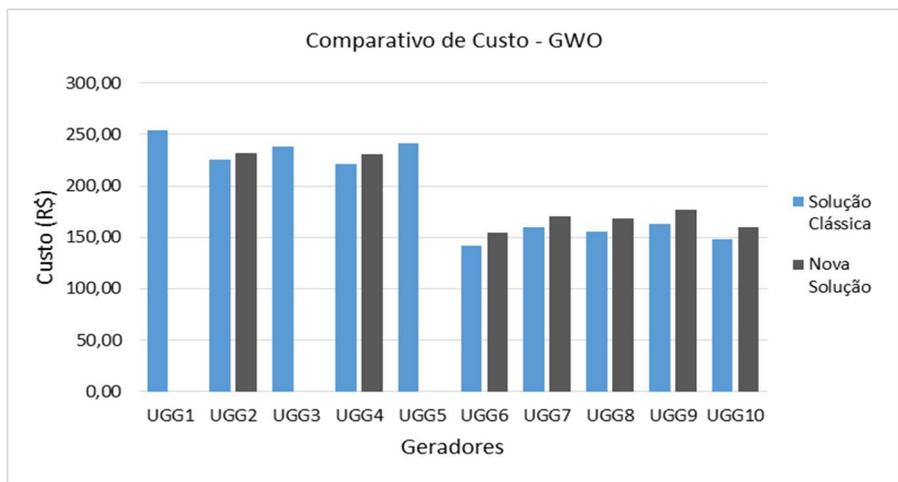
Figura 7.31 – Gráfico Comparativo de Potência, GWO – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.32, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com GWO para o Estudo de Caso.

Figura 7.32 – Gráfico Comparativo de Custo, GWO – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o GWO, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 33,58% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.8 GWO comparativo com o Sistema de Teste.

Na Tabela 7.20, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com o maior custo de combustível implementada com o GWO.

Tabela 7.20 - Comparação dos resultados de cada método para o Sistema de Teste.

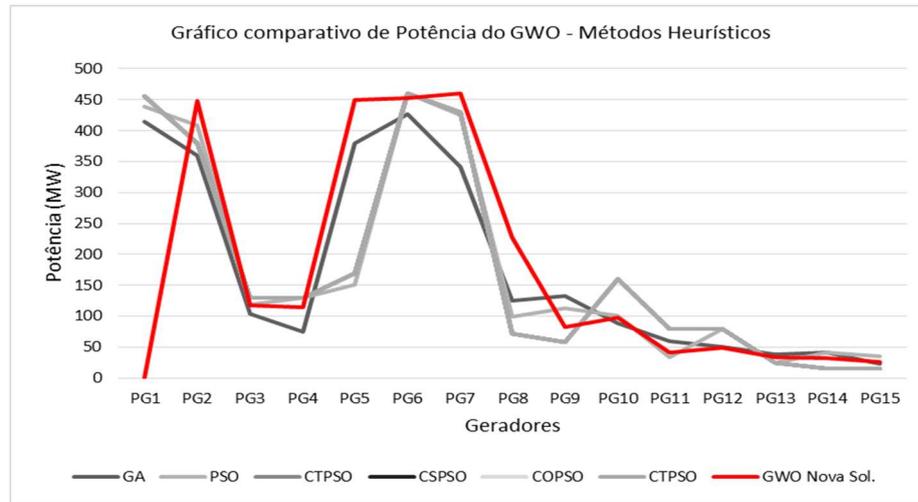
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	GWO nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	448,25
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	117,20
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	114,87
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	448,95
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	453,05
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	460,93
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	227,80
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	82,23
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	97,07
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	40,83
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	49,03
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	33,64
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	31,81
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	26,00
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2631,65</b>
$P_L$ (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>0,65</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.052,55</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 1,99% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.20, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com GWO.

Na figura 7.33 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.33 - Gráfico Comparativo de Potência GWO vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.21, são apresentados os resultados após a execução do GWO, para o Sistema de Teste:

Tabela 7.21 - Relatório de saída do GWO – Sistema de Teste.

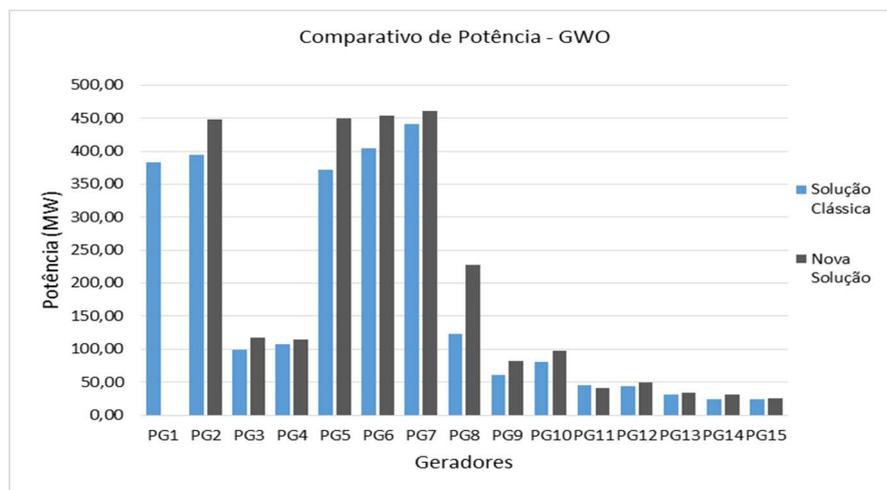
Parâmetros do DE usando GWO - SOLUÇÕES:	GWO - Solução Clássica	GWO - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	4,45 MW	1,65 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i (MW)$	Custo (R\$)	Potência $P_i (MW)$	Custo (R\$)
<b>PG1</b>	382,53	4578,28	Desl.	0,00
<b>PG2</b>	393,78	4618,94	448,25	5182,91
<b>PG3</b>	99,32	1259,14	117,20	1420,82
<b>PG4</b>	108,17	1339,10	114,87	1399,68
<b>PG5</b>	371,37	4351,47	448,95	5171,37
<b>PG6</b>	404,84	4768,24	453,05	5267,56
<b>PG7</b>	441,01	4940,72	460,93	5142,48
<b>PG8</b>	122,57	1604,86	227,80	2795,86
<b>PG9</b>	61,23	861,86	82,23	1099,39
<b>PG10</b>	80,09	1039,73	97,07	1224,98
<b>PG11</b>	45,77	660,41	40,83	608,50
<b>PG12</b>	43,42	670,28	49,03	728,62
<b>PG13</b>	31,75	641,33	33,64	666,10
<b>PG14</b>	24,63	608,24	31,81	695,84
<b>PG15</b>	23,940	622,404	26,004	648,459
<b>Total</b>	<b>2634,45</b>	<b>32565,01</b>	<b>2631,65</b>	<b>32052,55</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 104,9773 segundos para solução clássica e 130,5813 segundos para a nova solução. O relatório de soluções apresenta: os parâmetros de entrada para executar o GWO; total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima

da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ . É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (PG1) são desligados no momento da otimização. Na figura 7.34, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com GWO para o Sistema de Teste.

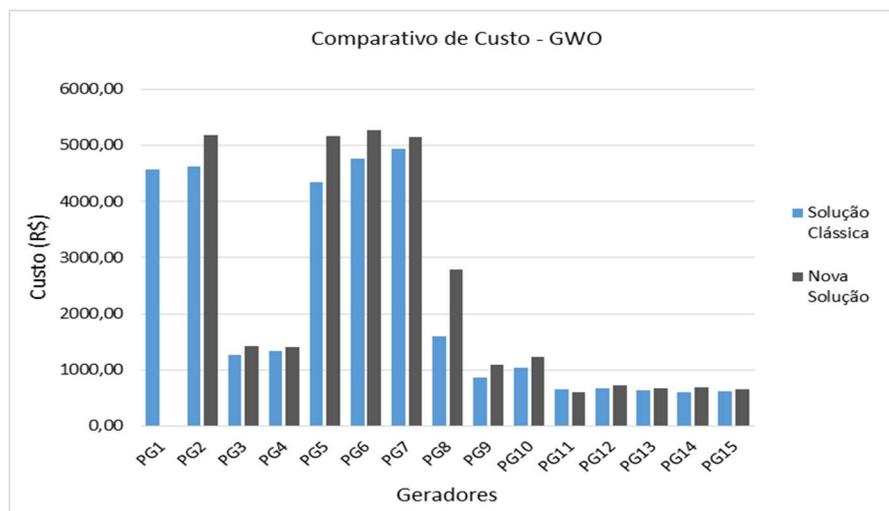
Figura 7.34 – Gráfico Comparativo de Potência, GWO - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.35, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com GWO para o Sistema de Teste.

Figura 7.35 – Gráfico Comparativo de Custo, GWO - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o GWO, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 1,57% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível.

### 7.3.9 Otimização do DE por Recozimento Simulado (RS) – Estudo de caso.

Na Tabela 7.22, são apresentados os resultados após a execução do RS, para o Estudo de Caso.

Tabela 7.22 - Relatório de saída do RS – Estudo de Caso.

Parâmetros do DE usando RS - SOLUÇÕES:	RS - Solução Clássica	RS - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0106 MW	0,0078 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	1,94	253,59	Desl.	0,00
<b>UGG2</b>	2,22	222,24	3,13	231,44
<b>UGG3</b>	2,14	238,23	Desl.	0,00
<b>UGG4</b>	1,89	220,87	2,81	230,93
<b>UGG5</b>	2,08	241,88	Desl.	0,00
<b>UGG6</b>	1,78	141,33	2,57	150,89
<b>UGG7</b>	2,04	158,55	2,89	170,47
<b>UGG8</b>	1,97	157,59	2,78	168,99
<b>UGG9</b>	2,29	162,08	3,32	176,53
<b>UGG10</b>	1,669	153,382	2,513	165,231
<b>Total</b>	<b>20,0106</b>	<b>1949,75</b>	<b>20,0078</b>	<b>1294,48</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 0,8474 segundos para solução clássica e 0,9596 segundos para a nova solução.

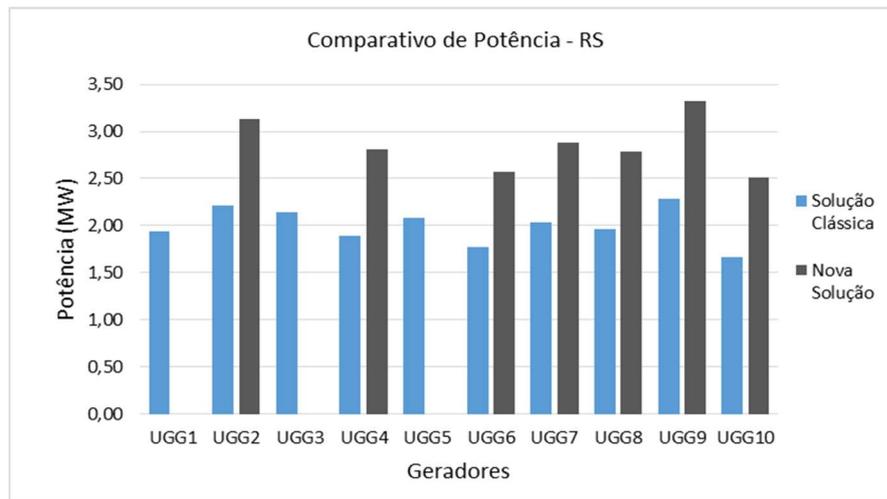
O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de

cada unidade geradora é especificada. Os geradores com o maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização.

Na figura 7.36, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com RS para o Estudo de Caso.

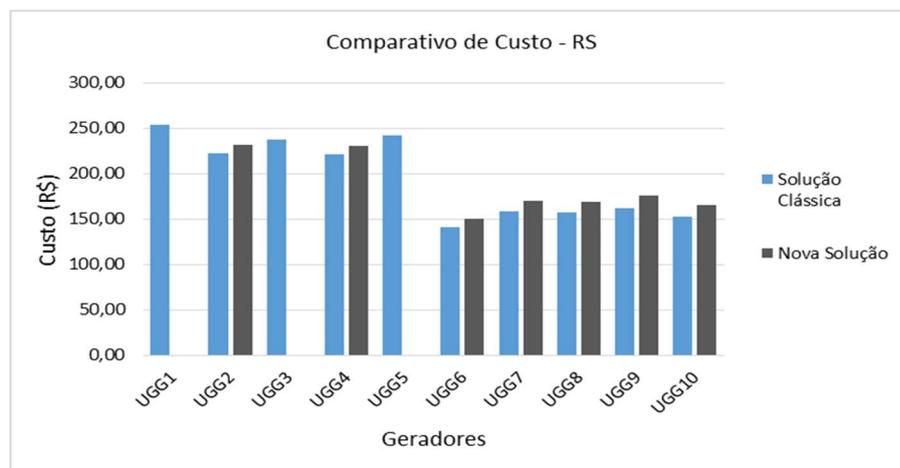
Figura 7.36 – Gráfico Comparativo de Potência, RS – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.37, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com RS para o Estudo de Caso.

Figura 7.37 – Gráfico Comparativo de Custo, RS – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o RS, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 33,61% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível.

### 7.3.10 RS comparativo com o Sistema de Teste.

Na Tabela 7.23, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com maior custo de combustível implementada com o RS.

Tabela 7.23 - Comparação dos resultados de cada método para o Sistema de Teste.

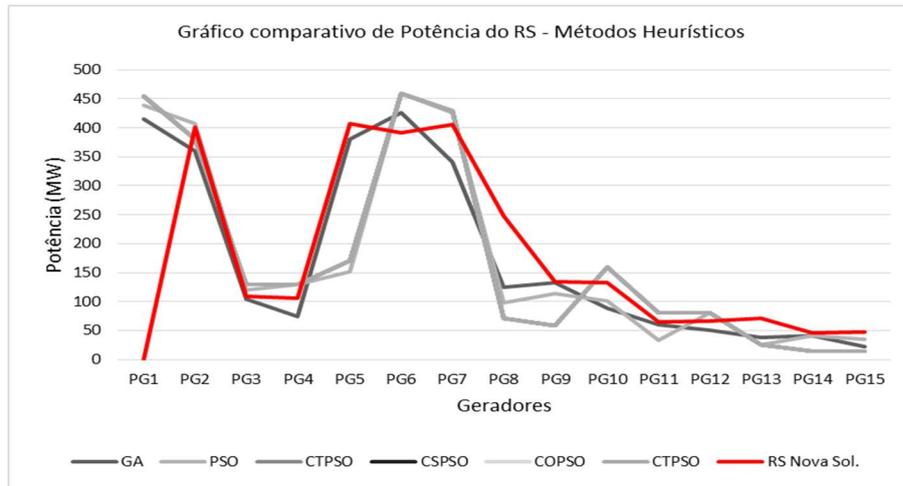
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	RS nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	400,75
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	109,47
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	106,12
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	407,14
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	390,97
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	404,96
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	247,32
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	133,83
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	132,68
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	65,66
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	66,96
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	70,51
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	46,74
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	46,971
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2630,08</b>
$P_L$ (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>0,08</b>
TC(MW)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.345,93</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 1,09% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.23, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com RS.

Na figura 7.38 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.38 - Gráfico Comparativo de Potência RS vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.24, são apresentados os resultados após a execução do RS, para o Sistema de Teste:

Tabela 7.24 - Relatório de saída do RS – Sistema de Teste.

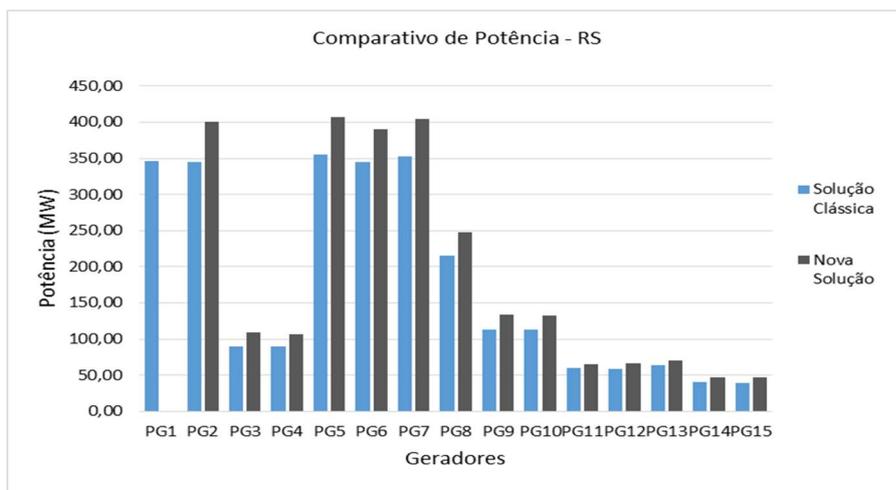
Parâmetros do DE usando RS - SOLUÇÕES:	RS - Solução Clássica	RS - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	0,08 MW	0,08 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>PG1</b>	346,70	4208,64	Desl.	0,00
<b>PG2</b>	345,53	4120,31	400,75	4691,06
<b>PG3</b>	89,69	1172,30	109,47	1350,86
<b>PG4</b>	90,21	1177,02	106,12	1320,53
<b>PG5</b>	355,57	4184,85	407,14	4729,19
<b>PG6</b>	345,22	4152,61	390,97	4624,76
<b>PG7</b>	353,07	4053,45	404,96	4576,30
<b>PG8</b>	215,33	2654,36	247,32	3017,65
<b>PG9</b>	113,08	1449,77	133,83	1686,30
<b>PG10</b>	113,44	1404,28	132,68	1615,89
<b>PG11</b>	60,01	811,00	65,66	871,16
<b>PG12</b>	58,61	829,17	66,96	917,65
<b>PG13</b>	63,94	1064,15	70,51	1150,55
<b>PG14</b>	39,91	795,01	46,74	878,78
<b>PG15</b>	39,770	823,178	46,971	915,256
<b>Total</b>	<b>2630,08</b>	<b>32900,10</b>	<b>2630,08</b>	<b>32345,93</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 1,1316 segundos para solução clássica e 1,5211 segundos para a nova solução. O relatório de soluções apresenta: os parâmetros de entrada para executar o RS; total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (PG1) são desligados no momento da otimização. Na figura 7.39, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com RS para o Sistema de Teste.

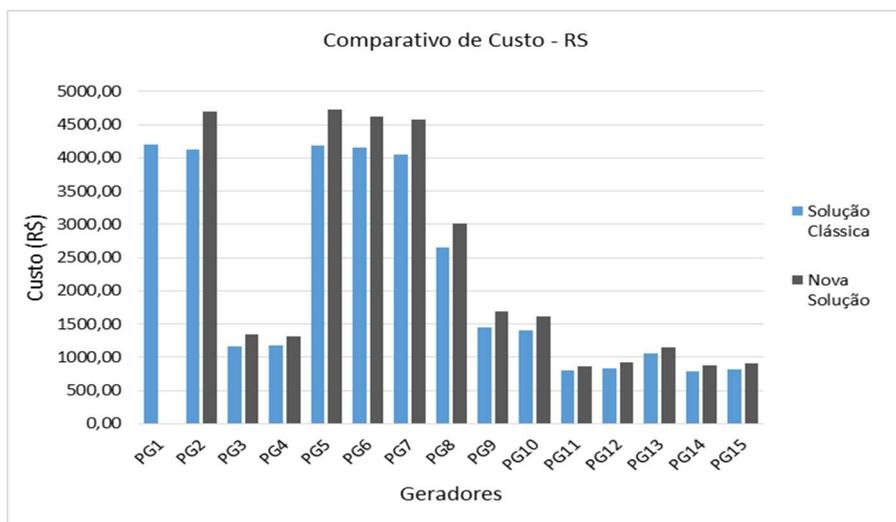
Figura 7.39 – Gráfico Comparativo de Potência, RS - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.40, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com RS para o Sistema de Teste.

Figura 7.40 – Gráfico Comparativo de Custo, RS - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o RS, contemplando o desligamento dos geradores com maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 1,71% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

### 7.3.11 Otimização do DE por Colônias de Abelhas Artificial (ABC) – Estudo de caso.

Na Tabela 7.25, são apresentados os resultados após a execução do ABC, para o Estudo de Caso.

Tabela 7.25 - Relatório de saída do ABC – Estudo de Caso.

Parâmetros do DE usando ABC - SOLUÇÕES:	ABC - Solução Clássica	ABC - Nova solução desligando os Geradores		
Total de $P^D$ :	20 MW	20 MW		
Potência Mínima:	0,56 MW	0,56 MW		
Potência Máxima:	3,9 MW	3,7 MW		
Total de $P_L$ :	0,0147 MW	0,0091 MW		
Potência de saída e Custo dos Geradores:				
	Potência $P_i$ (MW)	Custo (R\$)	Potência $P_i$ (MW)	Custo (R\$)
<b>UGG1</b>	3,35	263,53	Desl.	0,00
<b>UGG2</b>	3,70	237,13	3,65	236,65
<b>UGG3</b>	3,60	250,72	Desl.	0,00
<b>UGG4</b>	1,40	215,39	2,47	227,23
<b>UGG5</b>	1,35	234,18	Desl.	0,00
<b>UGG6</b>	1,33	135,94	2,22	146,69
<b>UGG7</b>	1,49	150,94	3,30	176,27
<b>UGG8</b>	1,38	149,27	2,70	167,89
<b>UGG9</b>	1,48	150,78	3,75	182,55
<b>UGG10</b>	0,938	143,144	1,918	156,881
<b>Total</b>	<b>20,0147</b>	<b>1931,01</b>	<b>20,0091</b>	<b>1294,15</b>

Fonte: O Autor, (2016).

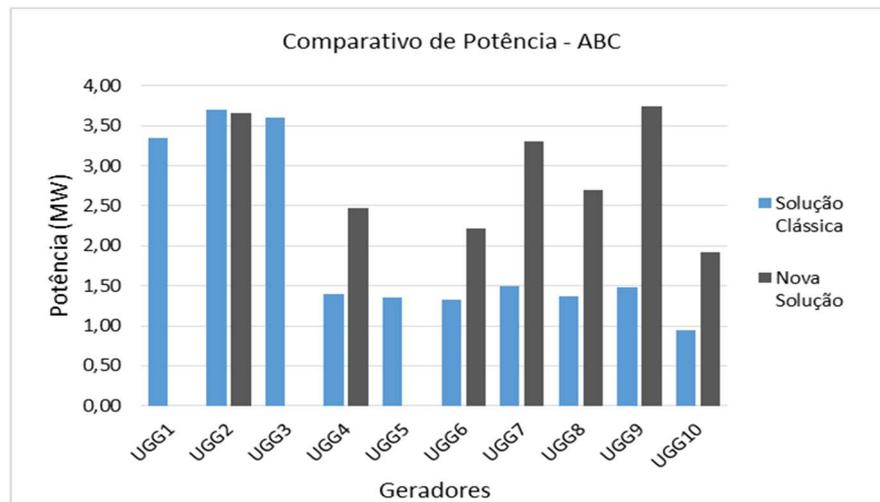
Tempo Médio de Execução: 1,1812 segundos para solução clássica e 0,9345 segundos para a nova solução.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização.

Na figura 7.41, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com ABC para o Estudo de Caso.

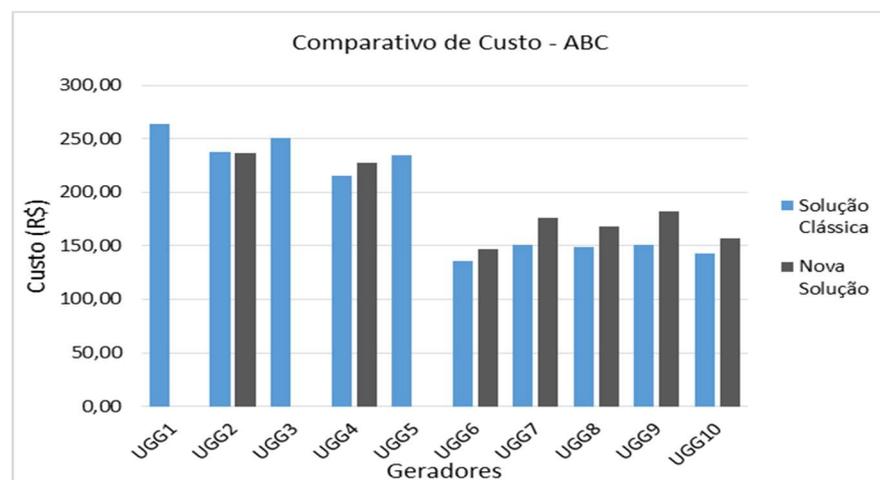
Figura 7.41 – Gráfico Comparativo de Potência, ABC – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.42, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com ABC para o Estudo de Caso.

Figura 7.42 – Gráfico Comparativo de Custo, ABC – Estudo de Caso.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o ABC, contemplando o desligamento dos geradores com o maior custo de combustível. Os resultados, com a nova solução, apresentaram uma redução de 32,98% no custo total do combustível, em relação a solução clássica que distribui a

geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível.

### 7.3.12 ABC comparativo com o Sistema de Teste.

Na Tabela 7.26, são apresentados os resultados de diversas técnicas heurísticas para o problema de otimização do DE (PARK *et al.*, 2010), e comparado com a nova solução que contempla o desligamento dos geradores com o maior custo de combustível implementada com o ABC.

Tabela 7.26 - Comparação dos resultados de cada método para o Sistema de Teste.

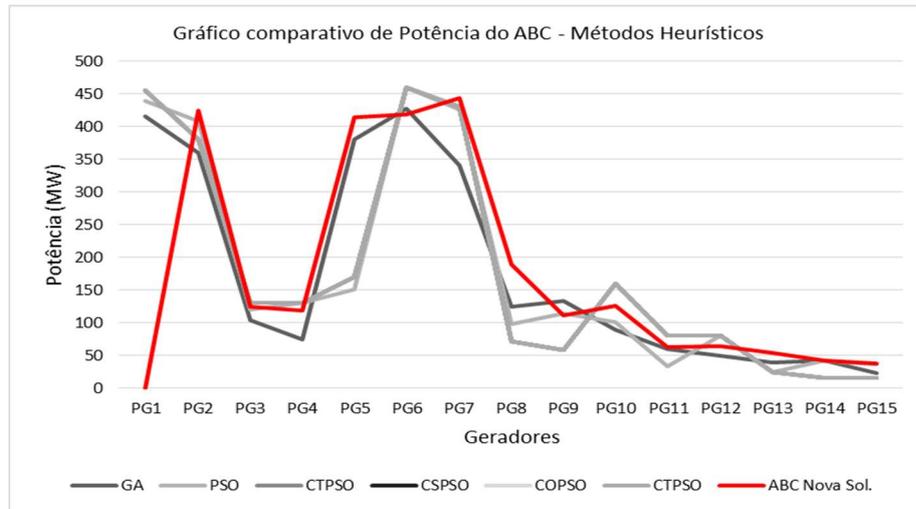
Gerador	GA (ZWE- LEE, 2003)	PSO (ZWE- LEE, 2003)	CTPSO (PARK <i>et al.</i> , 2010)	CSPSO (PARK <i>et al.</i> , 2010)	COPSO (PARK <i>et al.</i> , 2010)	CTPSO (PARK <i>et al.</i> , 2010)	ABC nova Solução
PG1	415,3108	439,1162	455,0000	455,0000	455,0000	455,0000	Desl.
PG2	359,7206	407,9727	380,0000	380,0000	380,0000	380,0000	423,93
PG3	104,4250	119,6324	130,0000	130,0000	130,0000	130,0000	125,06
PG4	74,9853	129,9925	130,0000	130,0000	130,0000	130,0000	118,94
PG5	380,2844	151,0681	170,0000	170,0000	170,0000	170,0000	414,32
PG6	426,7902	459,9978	460,0000	460,0000	460,0000	460,0000	418,44
PG7	341,3164	425,5601	430,0000	430,0000	430,0000	430,0000	443,76
PG8	124,7867	98,5699	71,7430	71,7408	71,7427	71,7526	189,10
PG9	133,1445	113,4936	58,9186	58,9207	58,9189	58,9090	111,72
PG10	89,2567	101,1142	160,0000	160,0000	160,0000	160,0000	125,93
PG11	60,0572	33,9116	80,0000	80,0000	80,0000	80,0000	62,54
PG12	49,9998	79,9583	80,0000	80,0000	80,0000	80,0000	64,48
PG13	38,7713	25,0042	25,0000	25,0000	25,0000	25,0000	53,53
PG14	41,9425	41,4140	15,0000	15,0000	15,0000	15,0000	41,82
PG15	22,6445	35,6149	15,0000	15,0000	15,0000	15,0000	37,491
TP(MW)	2668,4	2662,4	2660,6615	2660,6615	2660,6615	2660,6616	<b>2631,08</b>
P <sub>L</sub> (MW)	38,2782	32,4306	30,6615	30,6615	30,6615	30,6616	<b>1,08</b>
TC(R\$)	33.113	32.858	32.704	32.704	32.704	32.704	<b>32.144,43</b>

Fonte: O Autor, (2016).

A nova solução obtém uma economia de 1,71% em relação ao menor resultado encontrado por outros métodos. É relevante salientar que os resultados dos outros métodos apresentados na tabela 7.26, não levam em conta o valor adicional dos custos incrementais considerados na nova solução implementada com ABC.

Na figura 7.43 é visualizado o gráfico de Potência de saída de cada gerador para cada método heurístico utilizado.

Figura 7.43 - Gráfico Comparativo de Potência ABC vs Métodos Heurísticos.



Fonte: O Autor, (2016).

Na Tabela 7.27, são apresentados os resultados após a execução do ABC, para o Sistema de Teste:

Tabela 7.27 - Relatório de saída do ABC – Sistema de Teste.

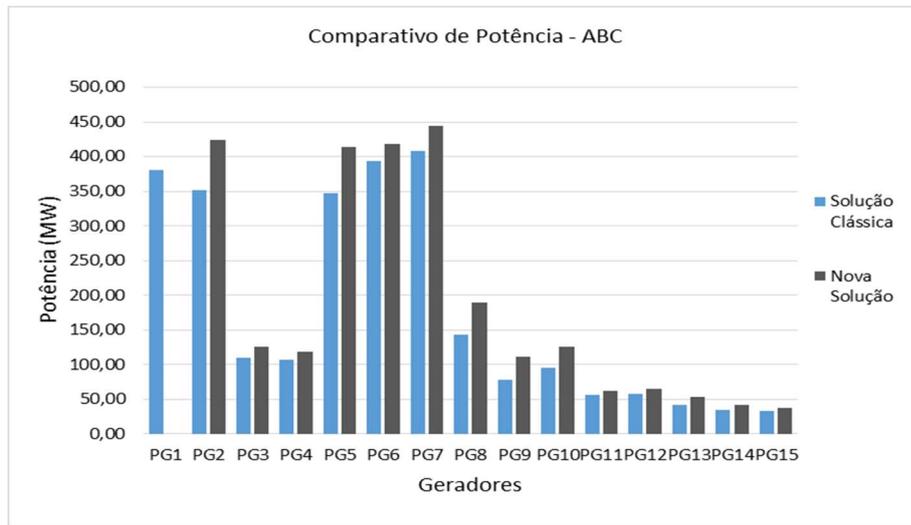
Parâmetros do DE usando ABC - SOLUÇÕES:	ABC - Solução Clássica	ABC - Nova solução desligando os Geradores		
Total de $P^D$ :	2630 MW	2630 MW		
Potência Mínima:	15 MW	15 MW		
Potência Máxima:	470 MW	470 MW		
Total de $P_L$ :	0,83 MW	1,08 MW		
Potência e Custos de saída dos Geradores:				
	Potência $P_i(MW)$	Custo (R\$)	Potência $P_i(MW)$	Custo (R\$)
<b>PG1</b>	379,98	4551,95	Desl.	0,00
<b>PG2</b>	351,16	4178,38	423,93	4930,93
<b>PG3</b>	109,17	1348,15	125,06	1492,16
<b>PG4</b>	107,29	1331,14	118,94	1436,60
<b>PG5</b>	347,48	4099,50	414,32	4805,16
<b>PG6</b>	393,10	4646,78	418,44	4908,97
<b>PG7</b>	407,43	4601,21	443,76	4968,55
<b>PG8</b>	142,29	1827,55	189,10	2356,97
<b>PG9</b>	77,95	1050,90	111,72	1434,38
<b>PG10</b>	94,54	1197,37	125,93	1541,56
<b>PG11</b>	55,56	763,75	62,54	837,98
<b>PG12</b>	56,84	810,53	64,48	891,27
<b>PG13</b>	41,66	771,40	53,53	927,35
<b>PG14</b>	34,04	723,09	41,82	818,43
<b>PG15</b>	32,349	728,787	37,491	794,134
<b>Total</b>	<b>2630,83</b>	<b>32630,47</b>	<b>2631,08</b>	<b>32144,43</b>

Fonte: O Autor, (2016).

Tempo Médio de Execução: 3,3149 segundos para solução clássica e 3,3499 segundos para a nova solução. O relatório de soluções apresenta: os parâmetros de entrada para executar o ABC; total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com a menor eficiência (PG1) são desligados no momento da otimização. Na figura 7.44, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta implementada com ABC para o Sistema de Teste.

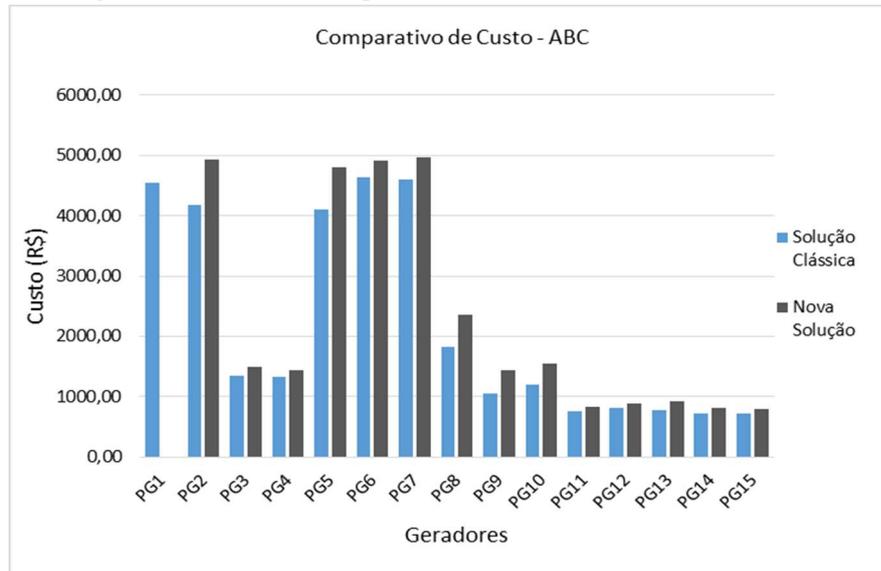
Figura 7.44 – Gráfico Comparativo de Potência, ABC - Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.45 é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta implementada com ABC para o Sistema de Teste.

Figura 7.45 – Gráfico Comparativo de Custo, ABC - Sistema de Teste.



Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DE, foi resolvido considerando o custo incremental e implementado com o ABC, contemplando o desligamento dos geradores com o maior custo de combustível.

Os resultados, com a nova solução, apresentaram uma redução de 1,49% no custo total do combustível, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com maior custo de combustível.

Todas as técnicas aplicadas neste trabalho para o problema de otimização do DE (mono-objetivo), podem ser convertidas para resolução de problemas de otimização DEA (multiobjetivo), utilizando a abordagem clássica, que atribui um peso  $w_i$  para cada função objetivo  $F_i$ , convertendo o problema de otimização multiobjetivo em um único objetivo com uma função objetivo escalar de acordo com a Eq. (6.30).

$$\min f = w_1 F_1(x) + w_2 F_2(x) + \dots + w_n F_n(x) \quad (6.30)$$

Onde  $f$  é a função a ser otimizada.

Outra solução, é adotar uma função como função objetivo a ser otimizada e as outras funções objetivo como restrições do problema. Para este trabalho foram utilizados o NSGA II e o NSGA III, para resolução do problema de otimização do DEA como descrito na próxima seção.

#### **7.4 Aplicação dos Métodos Heurísticos Multiobjetivos**

Nesta seção serão apresentados os resultados da aplicação dos métodos de otimização Heurísticos Multiobjetivo para resolução do DEA, tendo como referência os parâmetros de funcionamento e a formulação matemática descrita na seção 6.2, comparando a solução clássica com a nova solução que contempla o desligamento dos geradores com o maior consumo de combustível.

##### **7.4.1 Otimização do DEA por NSGA II – Estudo de caso.**

Na Tabela 7.28, são apresentados os resultados, de um ponto da Fronteira de Pareto, após a execução do NSGA II, para o Estudo de Caso.

Tabela 7.28 - Resultados de saída do NSGA II – Estudo de Caso.

Parâmetros do DEA usando NSGA II - SOLUÇÕES:									
NSGA II - Solução Clássica			NSGA II - Solução Desligando os geradores de Maior Custo			NSGA II - Solução Desligando os geradores Mais Poluentes			
Total de $P^D$ :	20 MW		20 MW			20 MW			
Potência Mínima:	0,56 MW		0,56 MW			0,66 MW			
Potência Máxima:	3,9 MW		3,9 MW			3,9 MW			
Total de $P_L$ :	0,053 MW		0,223 MW			0,329 MW			
	Potência $P_i$ (MW)	Custo (R\$)	Emissões ( $g/m^3$ )	Potência $P_i$ (MW)	Custo (R\$)	Emissões ( $g/m^3$ )	Potência $P_i$ (MW)	Custo (R\$)	Emissões ( $g/m^3$ )
UGG1	3,07	261,59	109371,98	Desl.	0,00	0,00	Desl.	0,00	0,00
UGG2	3,02	230,26	102929,52	3,59	236,02	102450,31	Desl.	0,00	0,00
UGG3	2,30	239,60	95475,82	Desl.	0,00	0,00	3,49	249,78	94807,97
UGG4	1,08	211,88	85981,52	2,19	224,11	85692,67	2,53	227,88	85603,90
UGG5	1,19	232,46	83897,59	Desl.	0,00	0,00	2,25	243,62	83687,73
UGG6	1,62	139,52	91848,81	2,62	151,51	91413,73	2,83	154,02	91323,40
UGG7	1,33	148,60	87929,15	2,37	163,27	87615,81	2,53	165,44	87569,62
UGG8	2,19	160,76	101191,42	3,10	173,51	100610,82	3,03	172,50	100656,69
UGG9	2,42	163,90	102924,45	3,60	180,43	102110,63	3,68	181,56	102055,67
UGG10	1,830	155,651	103591,973	2,752	168,583	102945,624	Desl.	0,000	0,000
<b>Total</b>	<b>20,053</b>	<b>1944,22</b>	<b>965142,23</b>	<b>20,223</b>	<b>1297,44</b>	<b>672839,59</b>	<b>20,329</b>	<b>1394,79</b>	<b>645704,97</b>

Fonte: O Autor, (2016).

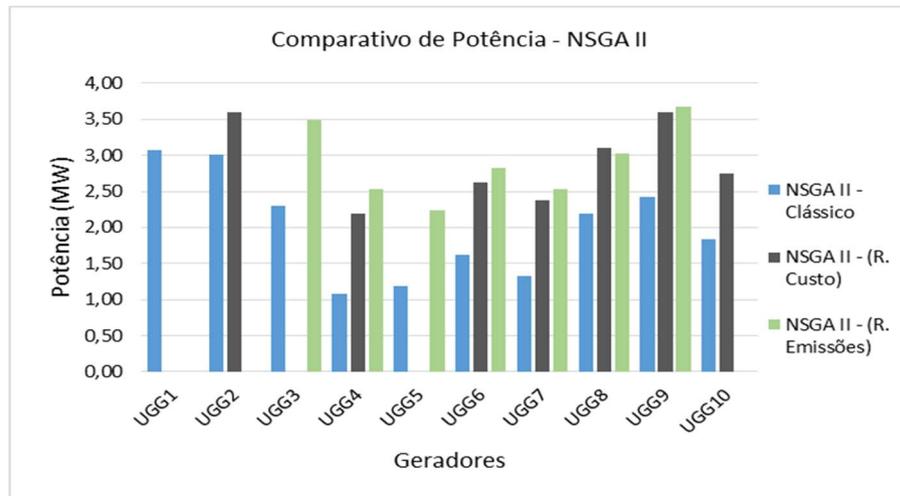
Tempo Médio de Execução: 8,41459 segundos para solução clássica, 13,39859 segundos para a nova solução que desliga os geradores com maior custo de combustível e 13,23760 segundos para a nova solução que desliga os geradores mais poluentes.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada. Os geradores com o maior custo de combustível (UGG1, UGG3 e UGG5) são desligados no momento da otimização.

Na figura 7.46, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Estudo de Caso.

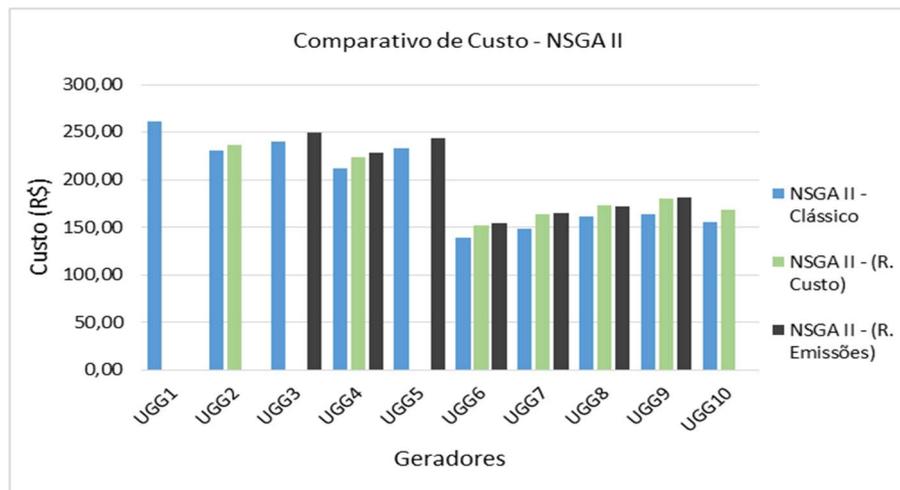
Figura 7.46 – Gráfico Comparativo de Potência, NSGA II – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.47, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Estudo de Caso.

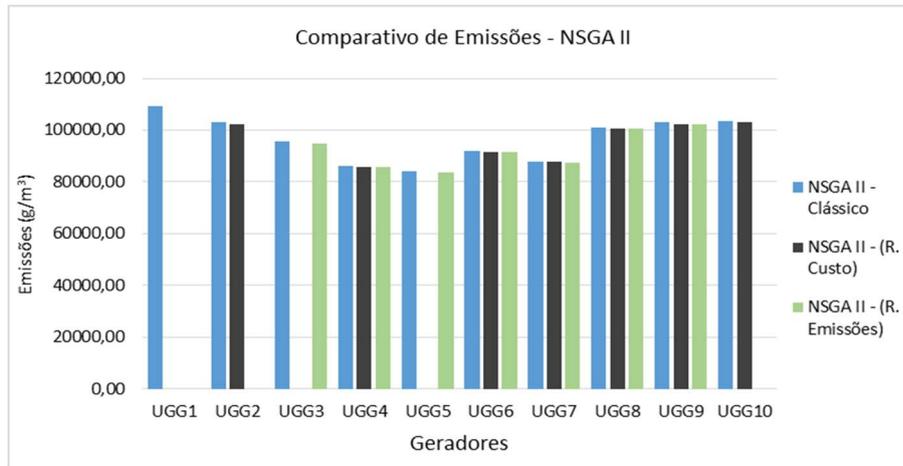
Figura 7.47 – Gráfico Comparativo de Custo, NSGA II – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.48, é visualizado o gráfico comparativo de emissões de cada gerador, entre a solução clássica e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Estudo de Caso.

Figura 7.48 – Gráfico Comparativo de Emissões, NSGA II – Estudo de Caso.

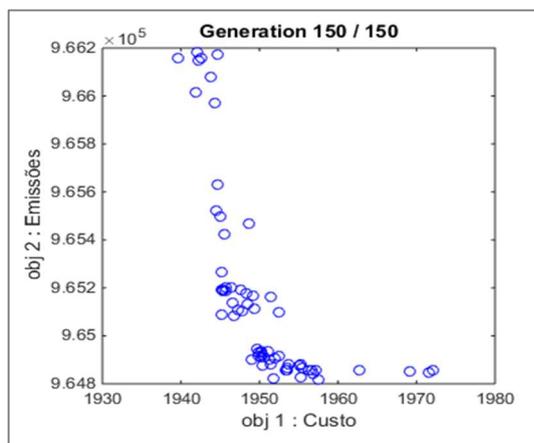


Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DEA, foi resolvido considerando o custo incremental e implementado com o NSGA II, contemplando o desligamento dos geradores com o maior custo de combustível. Os resultados, com a nova solução desligando os geradores com maior custo de combustível, apresentaram uma redução de 32,27% no custo total do combustível e uma redução de 30,29% nas emissões, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível. Optando-se pelo desligamento dos geradores mais poluentes, obtém-se uma redução de 28,26% no custo total de combustível e uma redução de 33,10% nas emissões em relação a solução clássica.

Na figura 7.49, é visualizado o gráfico da Frente de Pareto para a solução clássica implementada com NSGA II para o Estudo de Caso.

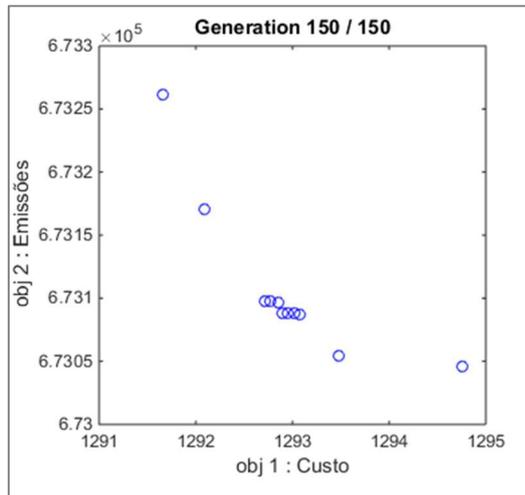
Figura 7.49 – Frente de Pareto da Solução Clássica, NSGA II – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.50, é visualizado o gráfico da Frente de Pareto para a nova solução que desliga os geradores com maior custo de combustível, implementada com NSGA II para o Estudo de Caso.

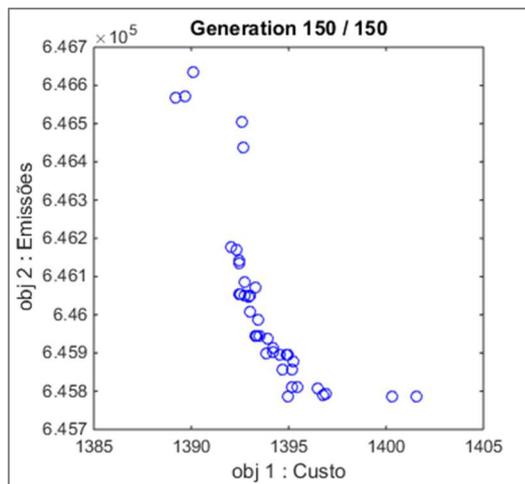
Figura 7.50 – Frente de Pareto da Redução de Custos, NSGA II – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.51, é visualizado o gráfico da Frente de Pareto para a nova solução que desliga os geradores com maior índice de emissões, implementada com NSGA II para o Estudo de Caso.

Figura 7.51 – Frente de Pareto da Redução de Emissões, NSGA II – Estudo de Caso.



Fonte: O Autor, (2016).

#### 7.4.2 NSGA II comparativo com o Sistema de Teste.

Na Tabela 7.29, são apresentados os resultados comparativos com o sistema de teste de (BASU, 2008), para o problema de otimização do DEA, e comparado com a nova solução que contempla o desligamento dos geradores com maior custo de combustível implementada com o NSGA II.

Tabela 7.29 - Comparação dos resultados para o Sistema de Teste - NSGA II.

Parâmetros do DEA usando NSGA II - SOLUÇÕES:									
NSGA II - Solução Clássica (BASU, 2008)			NSGA II - Solução Desligando os geradores de maior Custo			NSGA II - Solução Desligando os geradores mais Poluentes			
Total de $P^D$ :	1036 MW		1036 MW			1036 MW			
Potência Mínima:	10 MW		10 MW			10 MW			
Potência Máxima:	470 MW		470 MW			470 MW			
Total de $P_L$ :	26,38 MW		0,08 MW			0,02 MW			
	Potência $P_i$ (MW)	Custo (R\$)	Emissões (lb)/h	Potência $P_i$ (MW)	Custo (R\$)	Emissões (lb)/h	Potência $P_i$ (MW)	Custo (R\$)	Emissões (lb)/h
<b>PG1</b>	174,81	12563,63	1034452,88	Desl.	0,00	0,00	334,29	31130,79	1037087,00
<b>PG2</b>	188,65	13485,95	1034582,24	Desl.	0,00	0,00	368,36	32323,34	1038272,87
<b>PG3</b>	101,99	5693,28	3004028,29	199,87	10370,62	3005158,21	333,36	17898,91	3008627,52
<b>PG4</b>	132,36	7085,21	3004270,30	190,04	9921,18	3004997,93	Desl.	0,00	0,00
<b>PG5</b>	95,29	5588,08	3199958,35	237,73	11715,74	3201101,41	Desl.	0,00	0,00
<b>PG6</b>	81,91	4899,71	3199927,01	159,22	8208,17	3200282,97	Desl.	0,00	0,00
<b>PG7</b>	101,82	5498,71	3300145,30	129,46	6383,57	3300338,43	Desl.	0,00	0,00
<b>PG8</b>	59,00	3929,91	3299989,45	119,75	6102,54	3300262,21	Desl.	0,00	0,00
<b>PG9</b>	65,57	4781,17	3499999,30	Desl.	0,00	0,00	Desl.	0,00	0,00
<b>PG10</b>	55,00	4427,38	3599936,90	Desl.	0,00	0,00	Desl.	0,00	0,00
<b>Total</b>	<b>1.056,38</b>	<b>67.953,04</b>	<b>28.177.290,01</b>	<b>1.036,08</b>	<b>52.701,82</b>	<b>19.012.141,15</b>	<b>1.036,02</b>	<b>81.353,04</b>	<b>5.083.987,40</b>

Fonte: O Autor, (2016).

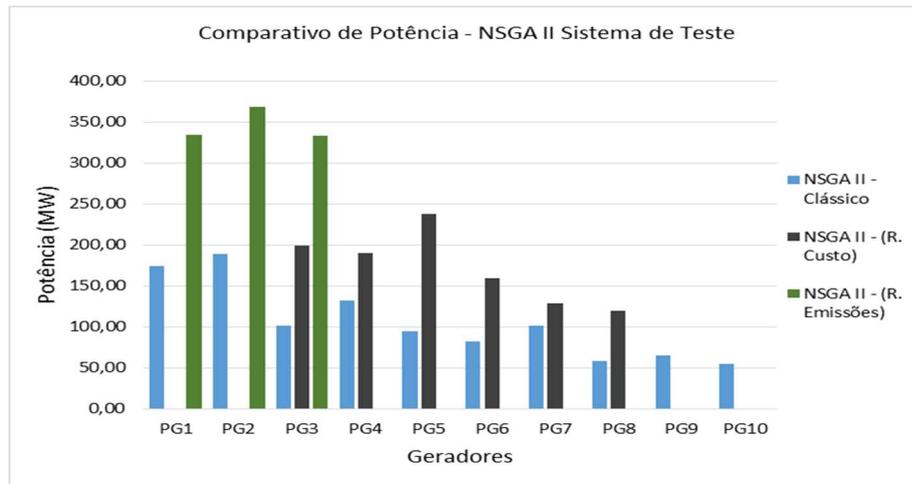
O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à necessidade total de demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora é especificada.

Os geradores com o maior custo de combustível (PG1, PG2, PG9 e PG10) são desligados no momento da otimização.

Na figura 7.52, é visualizado o gráfico comparativo de potência ótima de saída de cada gerador, entre a solução clássica de (BASU, 2008) e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Sistema de Teste.

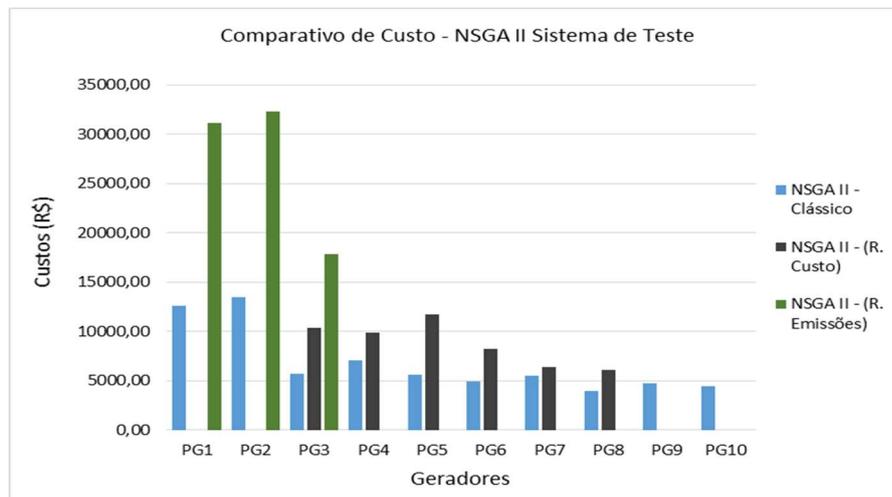
Figura 7.52 – Gráfico Comparativo de Potência, NSGA II – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.53, é visualizado o gráfico comparativo de custo de combustível de cada gerador, entre a solução clássica de (BASU, 2008) e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Sistema de Teste.

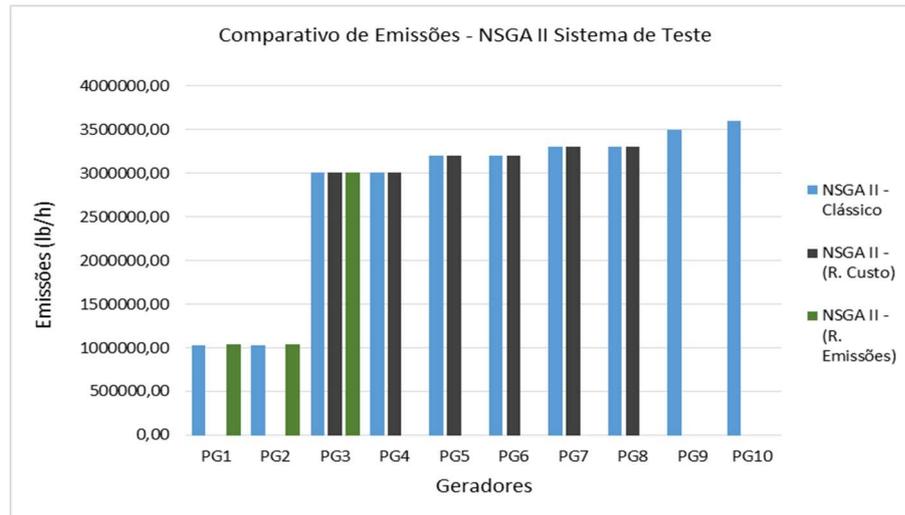
Figura 7.53 – Gráfico Comparativo de Custo, NSGA II – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.54, é visualizado o gráfico comparativo de emissões de cada gerador, entre a solução clássica de (BASU, 2008) e a nova solução proposta, desligando os geradores com maior custo de combustível (R. Custo) ou desligando os geradores mais poluentes (R. Emissões), implementadas com NSGA II para o Sistema de Teste.

Figura 7.54 – Gráfico Comparativo de Emissões, NSGA II – Sistema de Teste.

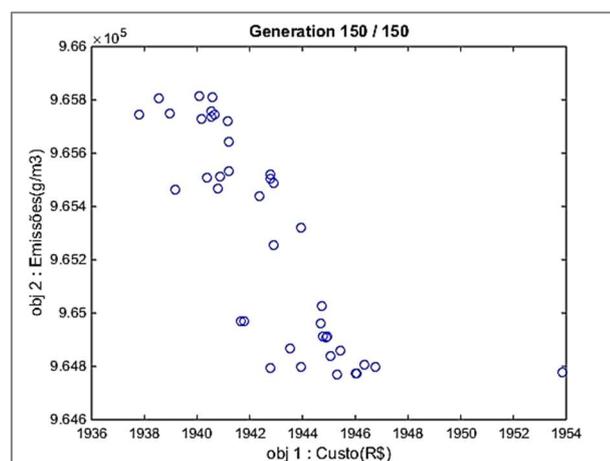


Fonte: O Autor, (2016).

Nesta análise, o problema de otimização operacional do DEA, foi resolvido considerando o custo incremental e implementado com o NSGA II, contemplando o desligamento dos geradores com o maior custo de combustível. Os resultados, com a nova solução desligando os geradores com maior custo de combustível, apresentaram uma redução de 22,44% no custo total do combustível e uma redução de 32,53% nas emissões, em relação a solução clássica que distribui a geração de potência entre todos os geradores, não contemplando o desligamento dos mesmos com o maior custo de combustível.

Optando-se pelo desligamento dos geradores mais poluentes, obtém-se um aumento de 19,72% no custo total de combustível e uma redução de 81,96% nas emissões em relação a solução clássica. Na figura 7.55, é visualizado o gráfico da Frente de Pareto para a solução clássica implementada com NSGA II para o Sistema de Teste.

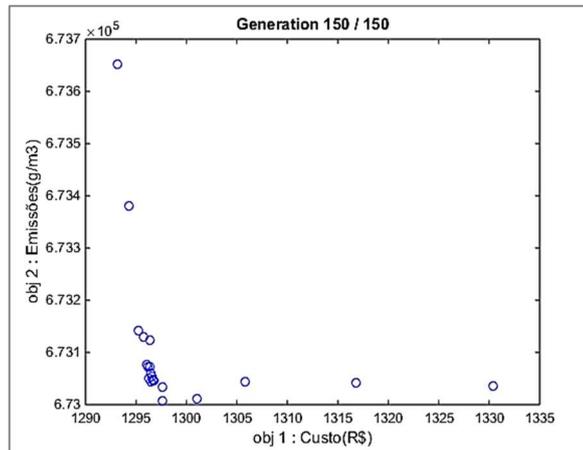
Figura 7.55 – Frente de Pareto da Solução Clássica, NSGA II – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.56, é visualizado o gráfico da Frente de Pareto para a nova solução que desliga os geradores com maior custo de combustível, implementada com NSGA II para o Sistema de Teste.

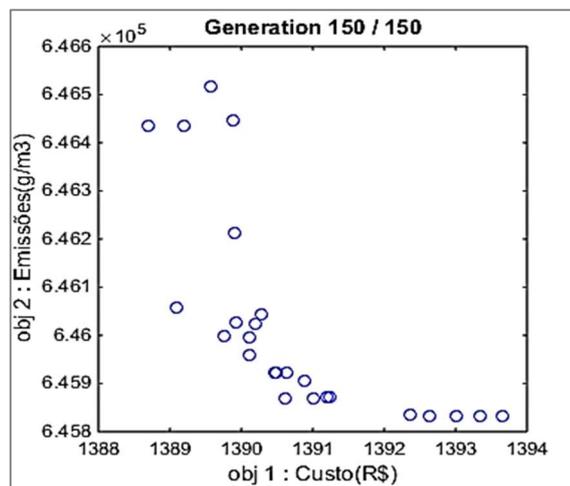
Figura 7.56 – Frente de Pareto da Redução de Custos, NSGA II – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.57, é visualizado o gráfico da Frente de Pareto para a nova solução que desliga os geradores com maior índice de emissões, implementada com NSGA II para o Sistema de Teste.

Figura 7.57 – Frente de Pareto da Redução de Emissões, NSGA II – Sistema de Teste.



Fonte: O Autor, (2016).

### 7.4.3 Otimização do DEA por NSGA III – Estudo de caso.

Na Tabela 7.30, são apresentados os parâmetros de funcionamento do NSGA III, para o Estudo de Caso.

Tabela 7.30 – Parâmetros do DEA. NSGA III – Estudo de Caso.

Parâmetros do DEA usando NSGA III:				
Soluções:	$P^D$	$P_{imin}(M)$	$P_{imax}(M)$	$P_L$
Clássica	20 MW	0,56 MW	3,9 MW	0,3 MW
Desligando os geradores com maior Custo (R\$)	20 MW	0,56 MW	3,9 MW	0,19 MW
Desligando os geradores com maior Emissões de NO <sub>x</sub> .	20 MW	0,56 MW	3,7 MW	0,21 MW
Desligando os geradores com maior Emissões de CO <sub>2</sub> .	20 MW	0,66 MW	3,9 MW	0,28 MW

Fonte: O Autor, (2016).

Tempo Médio de Execução: 15,4435 segundos para solução clássica, 12,8941 segundos para a nova solução que desliga os geradores com maior custo de combustível, 12,6606 para a nova solução que desliga os geradores com maior índice de emissões de NO<sub>x</sub> e 14,1847 segundos para a nova solução que desliga os geradores com maior índice de emissões de CO<sub>2</sub>.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

Na Tabela 7.31, são apresentados os resultados de Potência ótima de saída  $P_i$  de cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de NO<sub>x</sub> (R. NO<sub>x</sub>) ou com maior índice de emissões de CO<sub>2</sub> (R. CO<sub>2</sub>), após a execução do NSGA III para o Estudo de Caso.

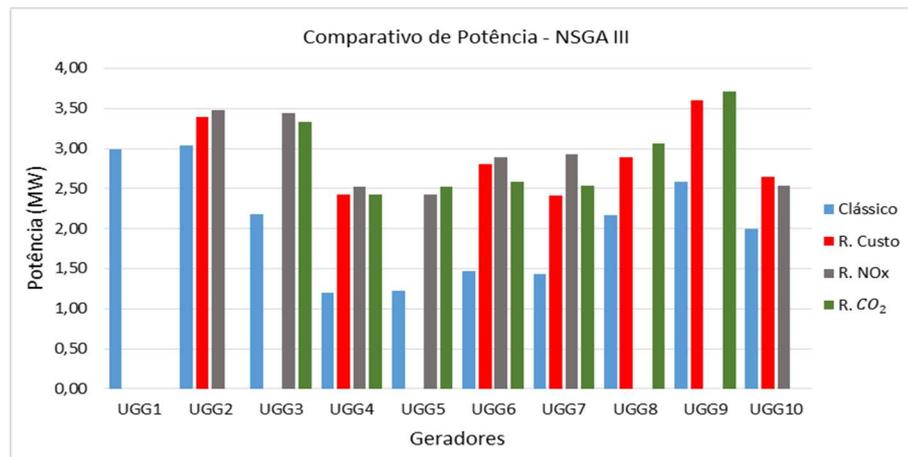
Tabela 7.31 - Resultados de saída de potência ótima. NSGA III – Estudo de Caso.

Potência ótima de saída de cada unidade geradora.				
	Soluções:			
	Clássica	R. Custo	R. NO <sub>x</sub>	R. CO <sub>2</sub>
	$P_i(MW)$	$P_i(MW)$	$P_i(MW)$	$P_i(MW)$
UGG1	2,99	Desl.	Desl.	Desl.
UGG2	3,03	3,40	3,48	Desl.
UGG3	2,18	Desl.	3,44	3,33
UGG4	1,20	2,42	2,52	2,42
UGG5	1,22	Desl.	2,42	2,53
UGG6	1,47	2,80	2,89	2,58
UGG7	1,43	2,42	2,93	2,53
UGG8	2,16	2,90	Desl.	3,07
UGG9	2,59	3,61	Desl.	3,71
UGG10	2,00	2,64	2,54	Desl.
<b>Total</b>	<b>20,2800</b>	<b>20,1919</b>	<b>20,2199</b>	<b>20,1691</b>

Fonte: O Autor, (2016).

A solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ , foi a que apresentou a maior perda de potência. Na figura 7.58, é visualizado o gráfico comparativo de potência ótima de saída  $P_i$  de cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Estudo de Caso.

Figura 7.58 – Gráfico Comparativo de Potência, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na Tabela 7.32, são apresentados os resultados de Custos Totais (R\$) para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $\text{NO}_x$  (R.  $\text{NO}_x$ ) ou com maior índice de emissões de  $\text{CO}_2$  (R.  $\text{CO}_2$ ), após a execução do NSGA III para o Estudo de Caso.

Tabela 7.32 - Resultados de custos totais (R\$). NSGA III – Estudo de Caso.

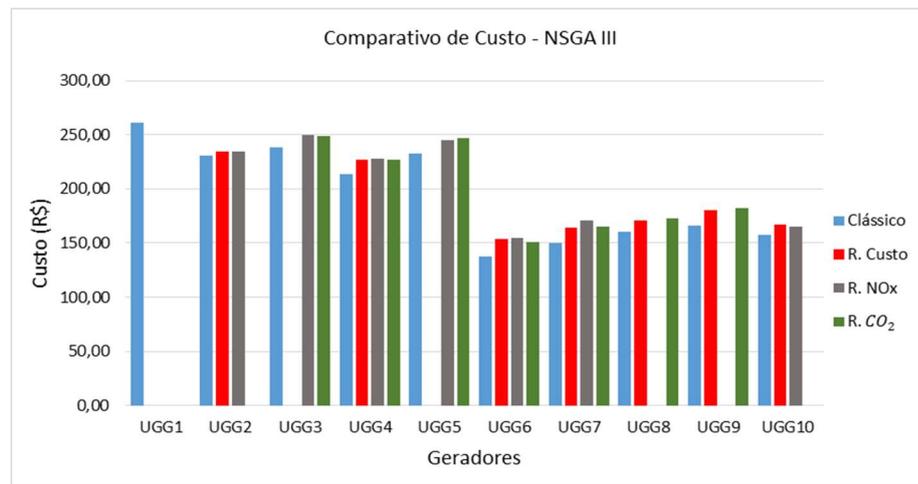
	Custos Totais (R\$) de cada unidade geradora.			
	Soluções:			
	Clássica	R. Custo	R. $\text{NO}_x$	R. $\text{CO}_2$
	(R\$)	(R\$)	(R\$)	(R\$)
UGG1	261,01	0,00	0,00	0,00
UGG2	230,42	234,09	234,93	0,00
UGG3	238,57	0,00	249,35	248,44
UGG4	213,26	226,72	227,78	226,67
UGG5	232,85	0,00	245,45	246,59
UGG6	137,66	153,69	154,74	151,07
UGG7	150,00	163,89	171,05	165,46
UGG8	160,33	170,62	0,00	172,98
UGG9	166,32	180,61	0,00	182,02
UGG10	157,97	167,06	165,60	0,00
<b>Total</b>	<b>1948,39</b>	<b>1296,69</b>	<b>1448,92</b>	<b>1393,23</b>

Fonte: O Autor, (2016).

É selecionada a quantidade mínima de geradores com menor custo de combustível, para atender à demanda de potência ativa  $P^D$  e a potência ótima de saída  $P_i$  de cada unidade geradora

é especificada. Os geradores com os maiores custos (UGG1, UGG3 e UGG5) são desligados no momento da otimização. A solução que desliga os geradores com os maiores custos de combustível, apresentou uma redução de 33,45%, em relação a solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ . Na figura 7.59, é visualizado o gráfico comparativo de custo de combustível para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Estudo de Caso.

Figura 7.59 – Gráfico Comparativo de Custo de Combustível, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na Tabela 7.33, são apresentados os resultados de emissões totais de  $\text{NO}_x$  para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $\text{NO}_x$  (R.  $\text{NO}_x$ ) ou com maior índice de emissões de  $\text{CO}_2$  (R.  $\text{CO}_2$ ), após a execução do NSGA III para o Estudo de Caso.

Tabela 7.33 - Resultados de emissões de  $\text{NO}_x$ . NSGA III – Estudo de Caso.

	Emissões de $\text{NO}_x$ de cada unidade geradora.			
	Clássica	Soluções:		
		R. Custo	R. $\text{NO}_x$	R. $\text{CO}_2$
	( $\text{g}/\text{m}^3$ )	( $\text{g}/\text{m}^3$ )	( $\text{g}/\text{m}^3$ )	( $\text{g}/\text{m}^3$ )
UGG1	484,93	0,00	0,00	0,00
UGG2	260,37	259,25	259,00	0,00
UGG3	175,88	0,00	172,95	173,20
UGG4	310,19	305,50	305,13	305,51
UGG5	230,02	0,00	227,28	227,04
UGG6	171,94	170,84	170,77	171,02
UGG7	328,27	322,48	319,53	321,83
UGG8	328,35	323,56	0,00	322,47
UGG9	411,41	402,54	0,00	401,67
UGG10	189,04	187,80	188,00	0,00
<b>Total</b>	<b>2890,41</b>	<b>1971,97</b>	<b>1642,66</b>	<b>1922,74</b>

Fonte: O Autor, (2016).

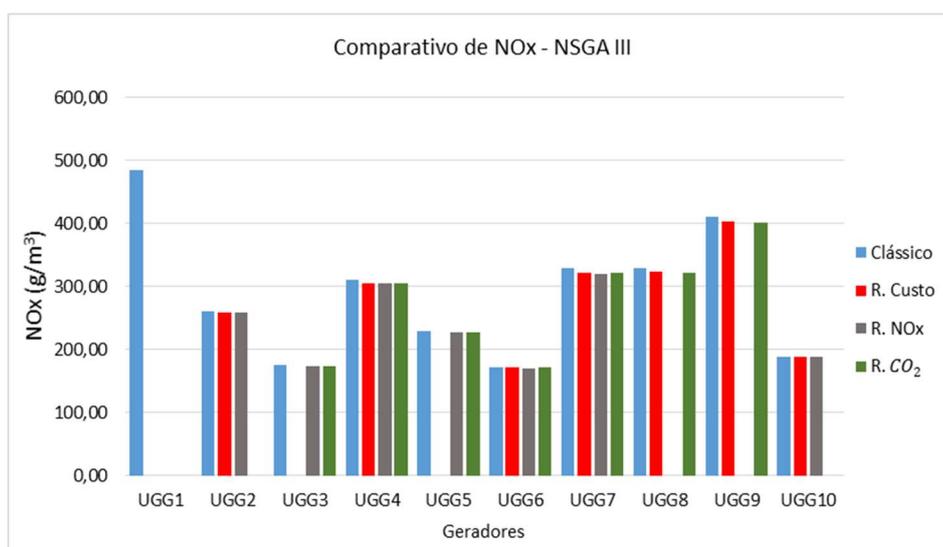
É selecionada a quantidade mínima de geradores com os menores índices de emissões de  $\text{NO}_x$ , para atender à necessidade total de demanda de potência ativa  $P^D$ .

Os geradores com os maiores índices de emissões de  $\text{NO}_x$  (UGG1, UGG8 e UGG9) são desligados no momento da otimização.

A solução que desliga os geradores com os maiores índices de emissões de  $\text{NO}_x$ , apresentou uma redução de 43,17%, em relação a solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ .

Na figura 7.60, é visualizado o gráfico comparativo de emissões de  $\text{NO}_x$  para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Estudo de Caso.

Figura 7.60 – Gráfico Comparativo de emissões de  $\text{NO}_x$ , NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na Tabela 7.34, são apresentados os resultados de emissões totais de  $\text{CO}_2$  para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $\text{NO}_x$  (R.  $\text{NO}_x$ ) ou com maior índice de emissões de  $\text{CO}_2$  (R.  $\text{CO}_2$ ), após a execução do NSGA III para o Estudo de Caso.

Tabela 7.34 - Resultados de emissões de CO<sub>2</sub>. NSGA III – Estudo de Caso.

	Emissões de CO <sub>2</sub> de cada unidade geradora.			
	Clássica (g/m <sup>3</sup> )	Soluções:		
		R. Custo	R. NO <sub>x</sub>	R. CO <sub>2</sub>
		Emissões de CO <sub>2</sub> : (g/m <sup>3</sup> )		
UGG1	108958,09	0,00	0,00	0,00
UGG2	102935,57	102628,49	102558,39	0,00
UGG3	95368,80	0,00	94662,42	94721,83
UGG4	85638,73	85325,69	85301,14	85326,83
UGG5	85633,98	0,00	85326,93	85299,45
UGG6	91744,77	91164,68	91126,91	91259,17
UGG7	87570,79	87280,08	87130,95	87247,32
UGG8	100882,60	100418,17	0,00	100312,30
UGG9	102705,28	102001,58	0,00	101932,72
UGG10	103119,60	102668,77	102741,04	0,00
<b>Total</b>	<b>964558,21</b>	<b>671487,46</b>	<b>648847,78</b>	<b>646099,64</b>

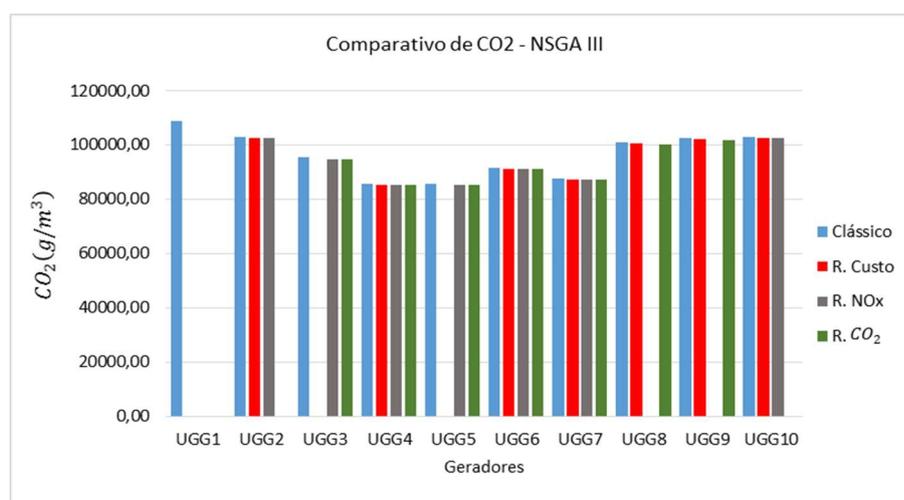
Fonte: O Autor, (2016).

É selecionada a quantidade mínima de geradores com os menores índices de emissões de CO<sub>2</sub>, para atender à necessidade total de demanda de potência ativa  $P^D$ . Os geradores com os maiores índices de emissões de CO<sub>2</sub> (UGG1, UGG2 e UGG10) são desligados no momento da otimização.

A solução que desliga os geradores com os maiores índices de emissões de CO<sub>2</sub>, apresentou uma redução de 33,02%, em relação a solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ .

Na figura 7.61, é visualizado o gráfico comparativo de emissões de CO<sub>2</sub> para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Estudo de Caso.

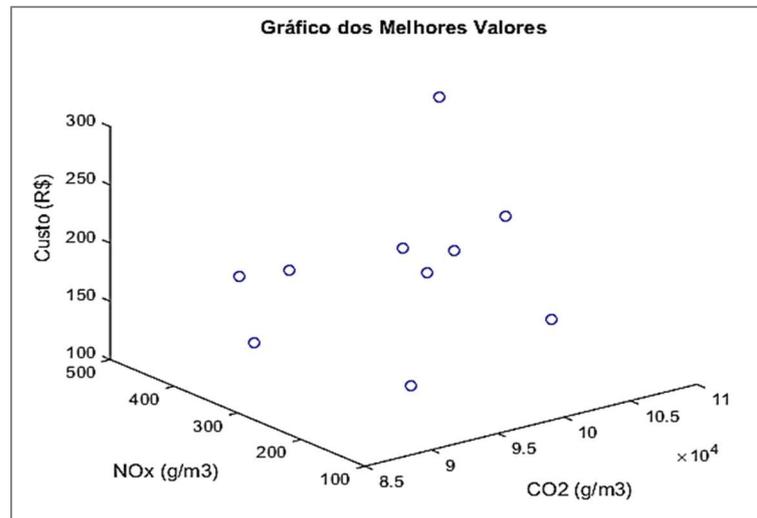
Figura 7.61 – Gráfico Comparativo de emissões de CO<sub>2</sub>, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.62, é visualizado o gráfico dos melhores indivíduos para solução clássica implementada com NSGA III para o Estudo de Caso.

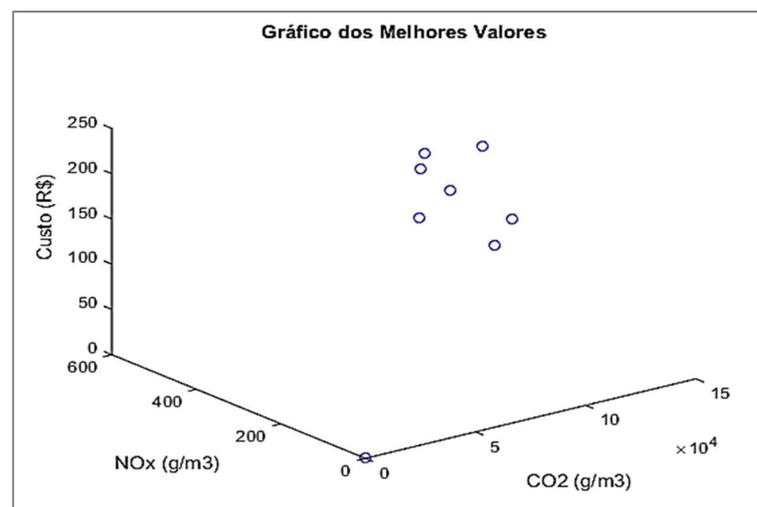
Figura 7.62 – Melhores indivíduos para solução Clássica, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.63, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior custo de combustível, implementada com NSGA III para o Estudo de Caso.

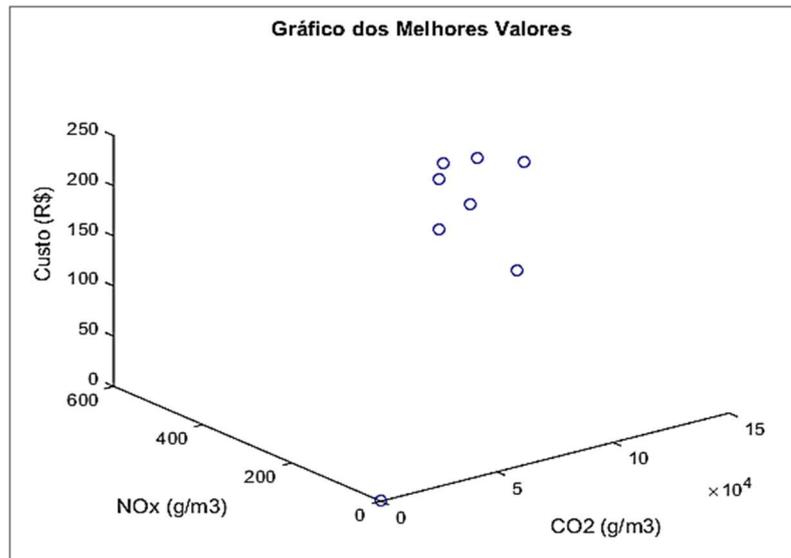
Figura 7.63 – Melhores indivíduos para Redução de Custo, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.64, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior índice de emissão de CO<sub>2</sub>, implementada com NSGA III para o Estudo de Caso.

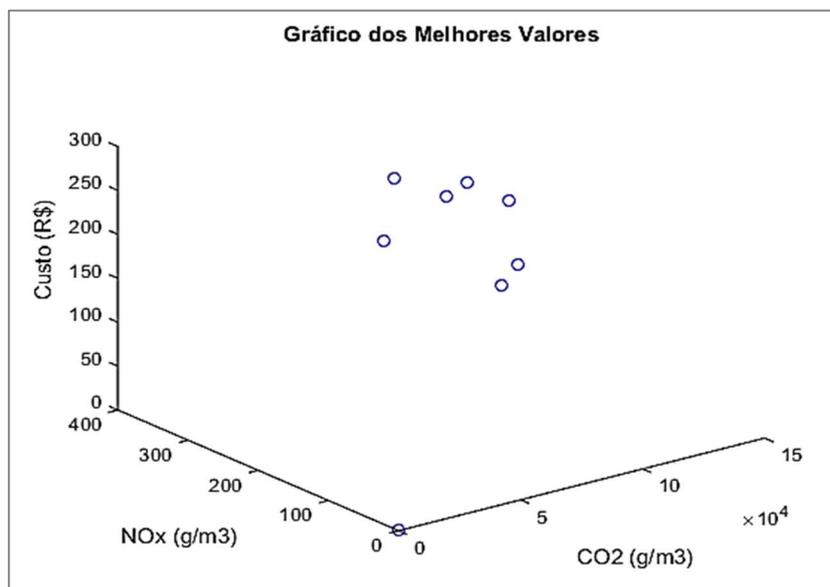
Figura 7.64 – Melhores indivíduos para Redução de CO<sub>2</sub>, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

Na figura 7.65, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior índice de emissão de NO<sub>x</sub>, implementada com NSGA III para o Estudo de Caso.

Figura 7.65 – Melhores indivíduos para Redução de NO<sub>x</sub>, NSGA III – Estudo de Caso.



Fonte: O Autor, (2016).

#### 7.4.4 NSGA III comparativo com o Sistema de Teste.

Na Tabela 7.35, são apresentados os parâmetros de funcionamento do NSGA III, para o Sistema de Teste.

Tabela 7.35 – Parâmetros do DEA. NSGA III – Sistema de Teste.

Parâmetros do DEA usando NSGA III:				
Soluções:	$P^D$	$P_{imin}(M)$	$P_{imax}(M)$	$P_L$
Clássica -	1500 MW	50 MW	500 MW	0,72 MW
Desligando os geradores com maior Custo (R\$)	1500 MW	50 MW	500 MW	1,05 MW
Desligando os geradores com maior Emissões de NO <sub>x</sub> .	1500 MW	50 MW	500 MW	0,78 MW
Desligando os geradores com maior Emissões de CO <sub>2</sub> .	1500 MW	50 MW	500 MW	0,20 MW

Fonte: O Autor, (2016).

Tempo Médio de Execução: 10,312 segundos para solução clássica, 14,4588 segundos para a nova solução que desliga os geradores com maior custo de combustível, 15,6611 para a nova solução que desliga os geradores com maior índice de emissões de NO<sub>x</sub> e 9,1874 segundos para a nova solução que desliga os geradores com maior índice de emissões de CO<sub>2</sub>.

O relatório de soluções apresenta os parâmetros de entrada para executar o algoritmo, como: total de demanda de potência  $P^D$ ; capacidade de potência mínima e máxima da UTE; custos de combustível total e de cada unidade geradora e o total de perdas de potência  $P_L$ .

Na Tabela 7.36, são apresentados os resultados de potência ótima de saída  $P_i$  de cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de NO<sub>x</sub> (R. NO<sub>x</sub>) ou com maior índice de emissões de CO<sub>x</sub> (R. CO<sub>x</sub>), após a execução do NSGA III para o Sistema de Teste.

Tabela 7.36 - Resultado de saída de potência ótima. NSGA III – Sistema de Teste.

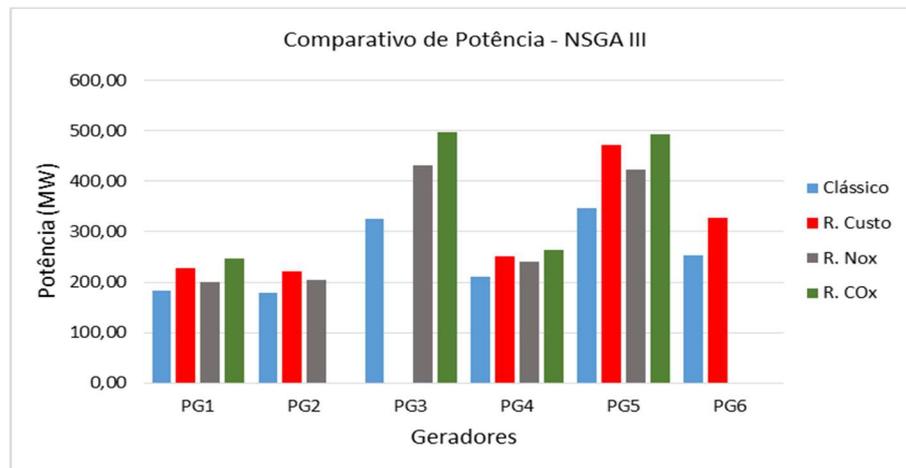
	Potência ótima de saída de cada unidade geradora.			
	Clássica	Soluções:		
		R. Custo	R. NO <sub>x</sub>	R. CO <sub>x</sub>
	Potência:			
	$P_i(MW)$	$P_i(MW)$	$P_i(MW)$	$P_i(MW)$
<b>PG1</b>	183,91	226,90	199,77	246,76
<b>PG2</b>	179,89	221,35	204,86	0,00
<b>PG3</b>	326,16	Desl.	432,42	496,95
<b>PG4</b>	209,67	252,01	240,35	262,93
<b>PG5</b>	346,81	472,19	423,37	493,57
<b>PG6</b>	254,29	328,60	Desl.	Desl.
<b>Total</b>	<b>1500,7295</b>	<b>1501,0481</b>	<b>1500,7760</b>	<b>1500,2018</b>

Fonte: O Autor, (2016).

A nova solução, que contempla o desligamento dos geradores com maior consumo de combustível, foi a que apresentou a maior perda de potência.

Na figura 7.66, é visualizado o gráfico comparativo de potência ótima de saída  $P_i$  de cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Sistema de Teste.

Figura 7.66 – Gráfico Comparativo de Potência, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na Tabela 7.37, são apresentados os resultados de custos totais (R\$) para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $\text{NO}_x$  (R.  $\text{NO}_x$ ) ou com maior índice de emissões de  $\text{CO}_x$  (R.  $\text{CO}_x$ ), após a execução do NSGA III para o Sistema de Teste.

Tabela 7.37 - Resultados de custos totais (R\$). NSGA III – Sistema de Teste.

	Custos Totais (R\$) de cada unidade geradora.			
	Clássica	Soluções:		
		R. Custo	R. $\text{NO}_x$	R. $\text{CO}_2$
	(R\$)	(R\$)	(R\$)	(R\$)
<b>PG1</b>	1705,20	2103,64	1851,33	2290,25
<b>PG2</b>	1582,02	1912,12	1779,26	0,00
<b>PG3</b>	3502,32	0,00	4467,59	5077,77
<b>PG4</b>	2076,84	2455,17	2350,55	2553,54
<b>PG5</b>	3681,52	4834,20	4377,28	5037,53
<b>PG6</b>	2346,14	3118,39	0,00	0,00
<b>Total</b>	<b>14894,05</b>	<b>14423,52</b>	<b>14826,00</b>	<b>14959,10</b>

Fonte: O Autor, (2016).

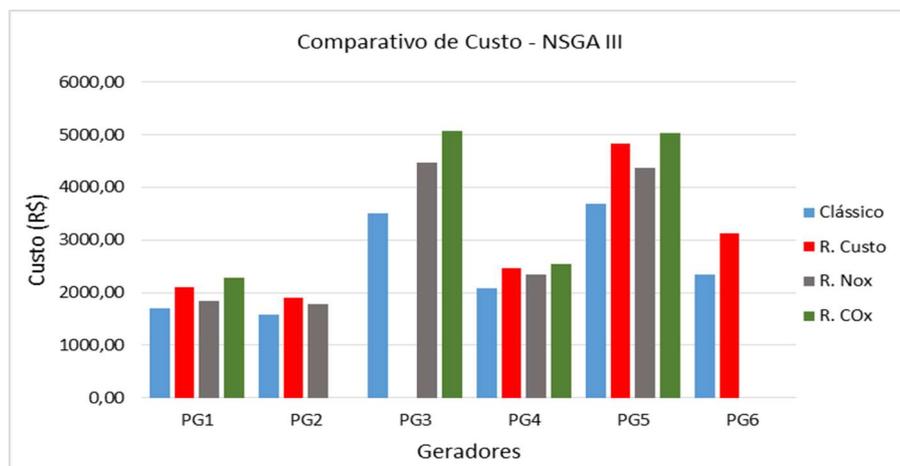
É selecionada a quantidade mínima de geradores com os menores custos de combustíveis, para atender à necessidade total de demanda de potência ativa  $P^D$ . Os geradores com os maiores custos (PG3) são desligados no momento da otimização.

A solução que desliga os geradores com os maiores custos de combustível, apresentou uma redução de 3,16%, em relação a solução clássica que utiliza todos os geradores para atender

a necessidade de demanda de potência ativa  $P^D$ . Em seu trabalho Dhillon e Jain (2011), obtém um custo total de combustível de \$ 17520,30 utilizando NSGA II. A nova solução proposta nesta tese, apresenta uma redução de 17,68% no custo total de combustível em comparação a este resultado (DHILLON e JAIN, 2011).

Na figura 7.67, é visualizado o gráfico comparativo de custo de combustível para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Sistema de Teste.

Figura 7.67 – Gráfico Comparativo de Custo de Combustível, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na Tabela 7.38, são apresentados os resultados de emissões totais de  $NO_x$  para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $NO_x$  (R.  $NO_x$ ) ou com maior índice de emissões de  $CO_x$  (R.  $CO_x$ ), após a execução do NSGA III para o Sistema de Teste.

Tabela 7.38 - Resultados de emissões de  $NO_x$ . NSGA III – Sistema de Teste.

	Emissões de $NO_x$ de cada unidade geradora.			
	Clássica	Soluções:		
		R. Custo	R. $NO_x$	R. $CO_x$
	Emissões de $NO_x$ :			
	(Kg/hr)	(Kg/hr)	(Kg/hr)	(Kg/hr)
<b>PG1</b>	224,64	319,92	1851,33	371,83
<b>PG2</b>	96,45	171,54	1779,26	0,00
<b>PG3</b>	218,06	0,00	4467,59	431,87
<b>PG4</b>	403,15	433,15	2350,55	444,80
<b>PG5</b>	234,06	389,39	4377,28	425,84
<b>PG6</b>	350,69	589,39	0,00	0,00
<b>Total</b>	<b>1527,05</b>	<b>1903,40</b>	<b>14826,00</b>	<b>1674,34</b>

Fonte: O Autor, (2016).

É selecionada a quantidade mínima de geradores com os menores índices de emissões de  $\text{NO}_x$ , para atender à necessidade total de demanda de potência ativa  $P^D$ .

Os geradores com os maiores índices de emissões de  $\text{NO}_x$  (PG3) são desligados no momento da otimização.

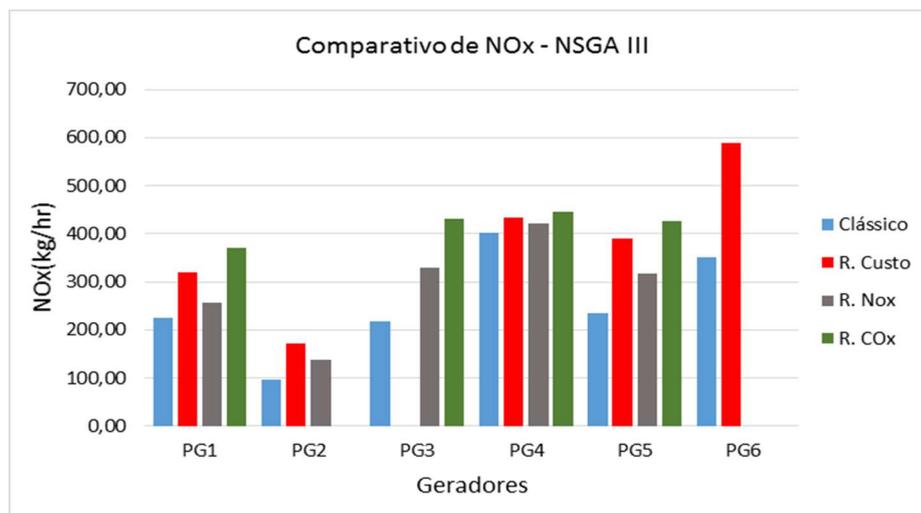
A solução que desliga os geradores com os maiores índices de emissões de  $\text{NO}_x$ , apresentou uma redução de 4,07%, em relação a solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ .

Em seu trabalho Dhillon e Jain (2011), obtém um total de emissões de  $\text{NO}_x$  de 1805,34 kg utilizando NSGA II (DHILLON e JAIN, 2011).

A nova solução proposta nesta tese, apresenta uma redução de 18,86% no total de emissões de  $\text{NO}_x$  em relação a este resultado.

Na figura 7.68, é visualizado o gráfico comparativo de emissões de  $\text{NO}_x$  para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Sistema de Teste.

Figura 7.68 – Gráfico Comparativo de emissões de  $\text{NO}_x$ , NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na Tabela 7.39, são apresentados os resultados de emissões totais de  $\text{CO}_x$  para cada unidade geradora, comparando a solução clássica, com a nova solução que desliga os geradores com maior consumo de combustível (R. Custo) ou com maior índice de emissões de  $\text{NO}_x$  (R.  $\text{NO}_x$ ) ou com maior índice de emissões de  $\text{CO}_x$  (R.  $\text{CO}_x$ ), após a execução do NSGA III para o Sistema de Teste.

Tabela 7.39 - Resultados de emissões de CO<sub>x</sub>. NSGA III – Sistema de Teste.

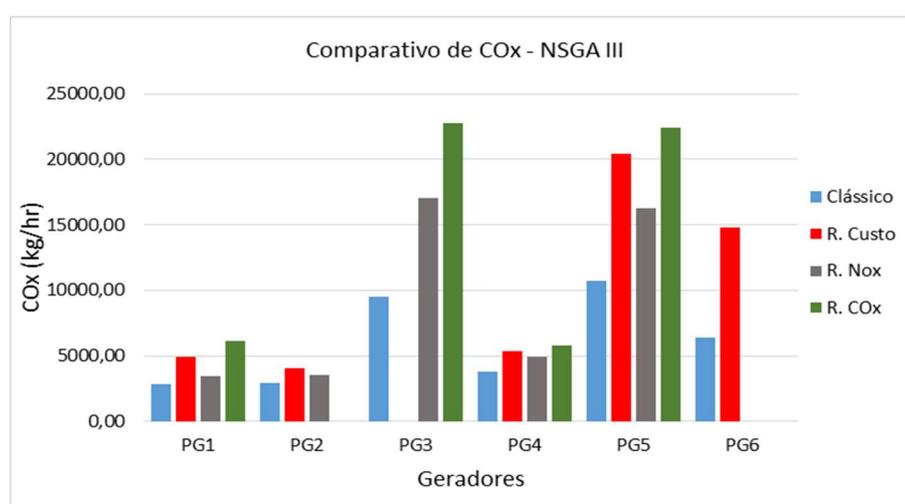
	Emissões de CO <sub>x</sub> de cada unidade geradora.			
	Clássica	Soluções:		
		R. Custo	R. NO <sub>x</sub>	R. CO <sub>x</sub>
	Emissões de CO <sub>x</sub> : (Kg/hr)	Emissões de CO <sub>x</sub> : (Kg/hr)	Emissões de CO <sub>x</sub> : (Kg/hr)	Emissões de CO <sub>x</sub> : (Kg/hr)
<b>PG1</b>	2824,84	4883,65	3470,36	6165,76
<b>PG2</b>	2968,80	4056,88	3566,50	0,00
<b>PG3</b>	9496,17	0,00	17019,61	22755,42
<b>PG4</b>	3827,07	5367,70	4905,56	5826,98
<b>PG5</b>	10770,72	20450,29	16285,27	22433,13
<b>PG6</b>	6430,82	14829,08	0,00	0,00
<b>Total</b>	<b>36318,43</b>	<b>49587,60</b>	<b>45247,31</b>	<b>57181,28</b>

Fonte: O Autor, (2016).

É selecionada a quantidade mínima de geradores com os menores índices de emissões de CO<sub>x</sub>, para atender à necessidade total de demanda de potência ativa  $P^D$ . Os geradores com os maiores índices de emissões de CO<sub>x</sub> (PG3 e PG6) são desligados no momento da otimização.

A solução que desliga os geradores com os maiores índices de emissões de CO<sub>x</sub>, não apresentou reduções nos índices de emissões, em relação a solução clássica que utiliza todos os geradores para atender a necessidade de demanda de potência ativa  $P^D$ , este fenômeno ocorre pelas características dos geradores da usina, tornando a solução clássica a com o menor índice total de emissões de CO<sub>x</sub>. Na figura 7.69, é visualizado o gráfico comparativo de emissões de CO<sub>x</sub> para cada gerador, entre a solução clássica e a nova solução proposta implementada com NSGA III para o Sistema de Teste.

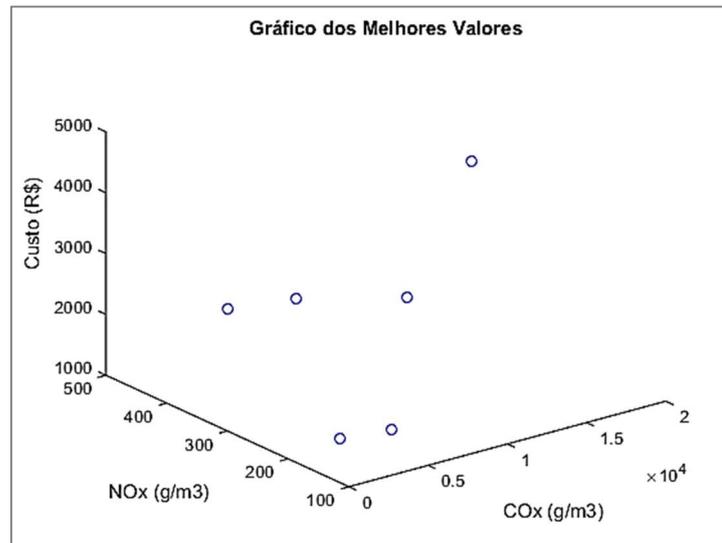
Figura 7.69 – Gráfico Comparativo de emissões de CO<sub>x</sub>, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.70, é visualizado o gráfico dos melhores indivíduos para solução clássica, implementada com NSGA III para o Sistema de Teste.

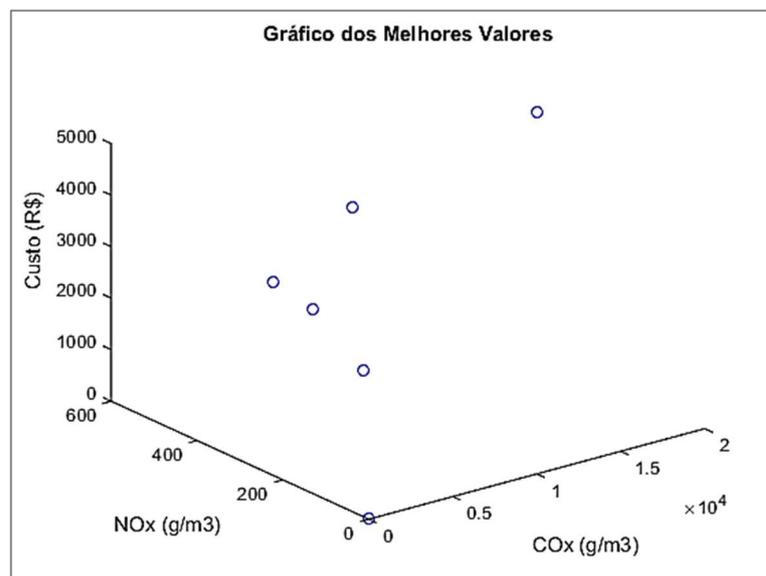
Figura 7.70 – Melhores indivíduos para solução Clássica, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.71, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior custo de combustível, implementada com NSGA III para o Sistema de Teste.

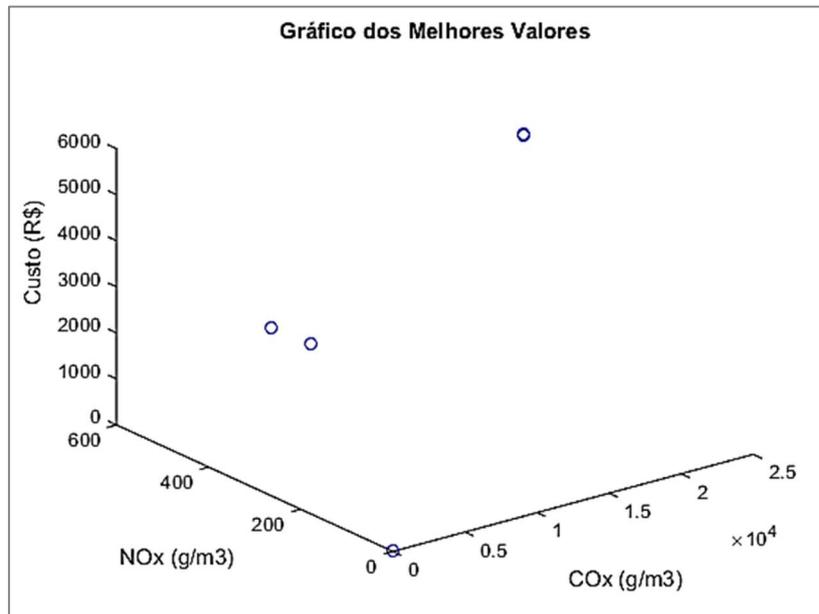
Figura 7.71 – Melhores indivíduos para Redução de Custo, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.72, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior índice de emissão de CO<sub>x</sub>, implementada com NSGA III para o Sistema de Teste.

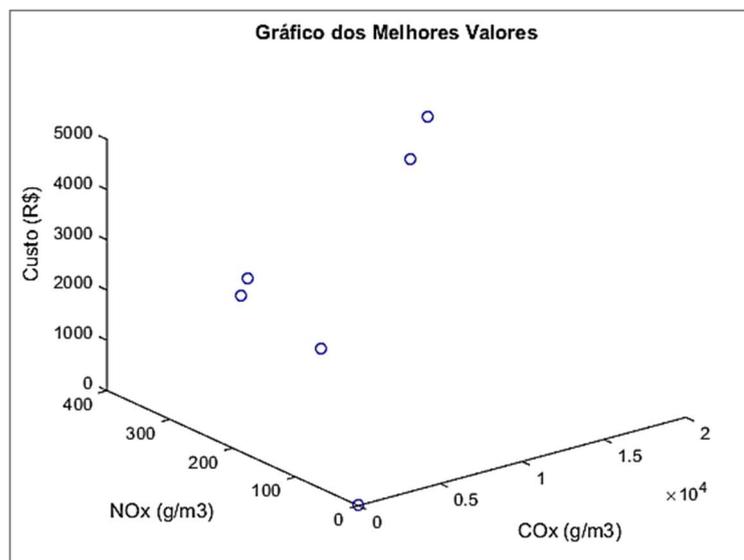
Figura 7.72 – Melhores indivíduos para Redução de CO<sub>2</sub>, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na figura 7.73, é visualizado o gráfico dos melhores indivíduos para solução que desliga os geradores com o maior índice de emissão de NO<sub>x</sub>, implementada com NSGA III para o Sistema de Teste.

Figura 7.73 – Melhores indivíduos para Redução de NO<sub>x</sub>, NSGA III – Sistema de Teste.



Fonte: O Autor, (2016).

Na tabela 7.40 é apresentado um resumo comparativo de custos para o problema do DE, entre os métodos determinísticos e heurísticos usados nesta tese para o Estudo de Caso.

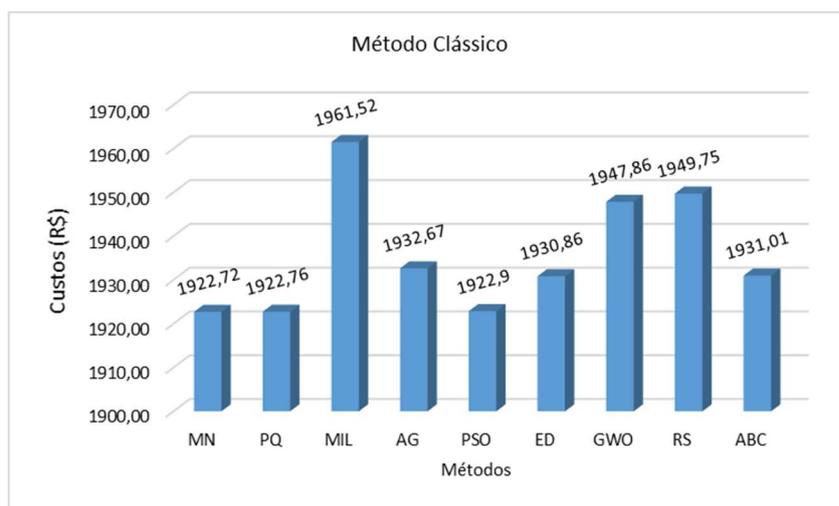
Tabela 7.40 – Consolidado de Custo Métodos Propostos – Estudo de Caso.

	MN (R\$)	PQ (R\$)	MIL (R\$)	AG (R\$)	PSO (R\$)	ED (R\$)	GWO (R\$)	RS (R\$)	ABC (R\$)
<b>Σ Clássico</b>	1922,72	1922,76	1961,52	1932,67	1922,9	1930,86	1947,86	1949,75	1931,01
<b>Σ Nova Solução</b>	1289,86	1289,90	1300,21	1290,49	1294,04	1290,04	1293,74	1294,48	1294,15
<b>Redução</b>	32,91%	32,91%	33,71%	33,23%	32,70%	33,19%	33,58%	33,61%	32,98%
<b>Tempo Nova Sol. (Seg)</b>	0,0599	0,0312	0,2629	4,6649	3,7447	83,8331	65,2970	0,9596	0,9345

Fonte: O Autor, (2016).

Na figura 7.74, são visualizados o total de custos para cada método, mono-objetivo, utilizado na otimização do DE – Estudo de caso.

Figura 7.74 – Consolidado de Custos DE – Estudo de Caso.



Fonte: O Autor, (2016).

Na tabela 7.41 é apresentado um resumo comparativo de custos para o problema do DE, entre os métodos determinísticos e heurísticos usados nesta tese para o Sistema de Teste.

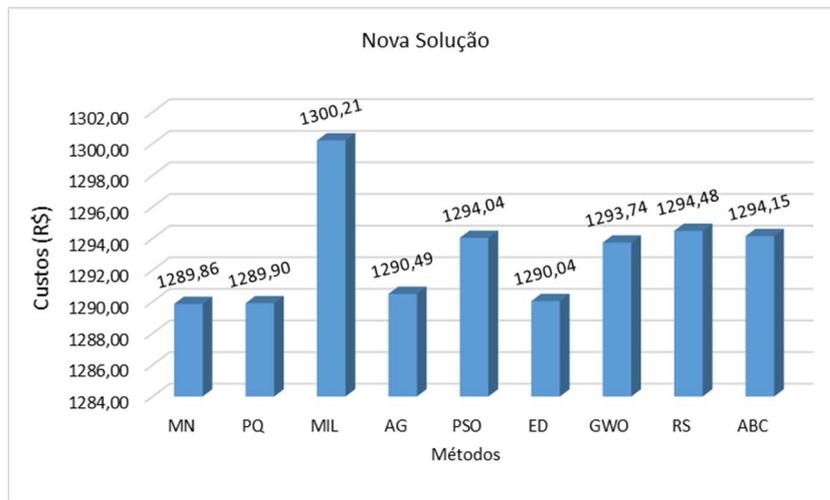
Tabela 7.41 – Consolidado de Custo Métodos Propostos – Sistema de Teste.

	MN (R\$)	PQ (R\$)	MIL (R\$)	AG (R\$)	PSO (R\$)	ED (R\$)	GWO (R\$)	RS (R\$)	ABC (R\$)
<b>Σ Clássico</b>	32.449,65	32.440,39	33318,42	33121,82	32688,23	32705,09	32565,01	32900,1	32630,47
<b>Σ Nova Solução</b>	31836,47	31836,50	32532,14	32414,37	32242,33	31995,57	32052,55	32345,9	32144,43
<b>Redução</b>	1,89%	1,86%	2,36%	2,14%	1,36%	2,17%	1,57%	1,68%	1,49%
<b>Tempo Nova Sol. (Seg)</b>	0,0681	0,0518	8,7930	10,1626	2,2206	108,5940	130,5813	1,5211	3,3499

Fonte: O Autor, (2016).

Na figura 7.75, são visualizados o total de custos para cada método, mono-objetivo, utilizado na otimização do DE – Sistema de Teste.

Figura 7.75 – Consolidado de Custos DE – Sistema de Teste.



Fonte: O Autor, (2016).

## 7.5 Conclusões do capítulo

Neste capítulo pode-se observar que a nova solução proposta para o problema de otimização dos DE e do DEA, que contempla o desligamento dos geradores com maior custo de combustível no momento da otimização para determinada demanda de potência, demonstrou ser eficiente com uma redução do custo total de combustível na geração de energia nas UTE's em comparação com os outros métodos convencionais que distribuem a geração de energia entre todos os geradores, incluindo os com maiores custos de geração.

---

## CAPÍTULO VIII

---

### CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

#### 8.1 Conclusões

Esta tese se propôs a apresentar uma nova solução para a otimização dos problemas de DE e DEA, baseados em meta-heurística Bio Inspirada. Neste contexto foram definidas questões relacionadas com a otimização multi-objetivo e os conflitos que podem existir dentro da mesma, além da apresentação de vários métodos baseados em análises convencionais e não convencionais, por exemplo Inteligência Computacional, para a solução do problema proposto.

A partir dos resultados apresentados no capítulo anterior, pode-se destacar algumas importantes conclusões.

Um dos aspectos iniciais que se pode destacar é o fato da formulação do problema do DE testado por diversos métodos determinísticos e heurísticos, mostrar-se viável e de fácil implementação computacional, com custos computacionais baixos diante da complexidade dos problemas tratados para poucos geradores.

Outra questão importante foi a facilidade e viabilidade da implementação computacional da modelagem do problema de otimização do DEA, por meio da utilização do Algoritmo Genético de Classificação Não-dominado, NSGA-II e NSGA-III. Estes algoritmos mostraram que o problema multiobjetivo do DEA pode ser resolvido pelo uso do NSGA (II e III) com um custo computacional razoável para o problema proposto.

A solução do problema Mono-objetivo de otimização do DE, foi aprimorada, reduzindo os custos totais de combustíveis quando se contempla o desligamento dos geradores com os maiores custos de combustível e que não são necessários para atender a parcela de demanda de potência ativa  $P^D$  no momento da otimização, como foi demonstrado na consolidação das técnicas propostas neste trabalho, apresentada nas tabelas 6.54 e 6.55.

Para a solução do problema de otimização Multiobjetivo do DEA, também encontrou-se melhores resultados, ao se contemplar o desligamento dos geradores com os maiores custos de combustível e que não são necessários para atender a parcela de demanda de potência ativa  $P^D$  no momento da otimização. A proposta neste caso se mostrou eficiente tanto para aplicação do método heurístico NSGA II, contemplando duas funções objetivo (Custo de Combustível e

Emissões Totais), quanto para o método heurístico NSGA III, contemplando três funções objetivo (Custo de Combustível, Emissões de NO<sub>x</sub> e Emissões de CO<sub>2</sub>). Em ambos os casos se obteve uma redução significativa de mais de 30% nos custos de combustíveis.

A nova solução do DE/DEA modificada para o desligamento dos geradores com maiores custos de combustível no momento da otimização, possibilita aos especialistas da UTE a realização de uma manutenção preditiva nestas máquinas que não estão sendo utilizadas no momento da otimização, a fim de melhorar a eficiência não só dos geradores, mas do planejamento da geração da UTE.

Os métodos da computação Bio-Inspirada com base em técnicas de otimização, não garantem encontrar uma solução ótima global, mas produzem soluções factíveis a um custo (tempo) computacional aceitável, que é a razão pela qual tais técnicas têm sido amplamente aplicadas para resolver o problema de DE/DEA.

Os métodos Heurísticos provaram ser eficientes e com resultados muito próximos aos métodos determinísticos, demonstrando sua robustez em lidar com problemas de otimização do DE, sendo que em todos os resultados demonstrou-se uma redução média de 30% no custo total de combustível para o Estudo de Caso e de 1,84% para o Sistema de Teste. É importante ressaltar que existe um custo ao se desligar os geradores, mas este não foi considerado para esta proposta, que teve como foco a redução do custo de geração de energia com a minimização dos gastos de combustíveis.

No problema multiobjetivo do DEA, é possível estender os estudos para o desligamento dos geradores com maiores índices de emissões, reduzindo significativamente tais índices.

Os resultados positivos deste trabalho, a partir da análise da aplicação de diversos métodos em vários exemplos práticos, mostraram os benefícios da nova solução proposta.

## **8.2 Algumas sugestões para Futuros Trabalhos**

A partir dos resultados obtidos até o presente momento, pode-se considerar as seguintes pesquisas para o futuro:

- 1) A nova solução para o DE e para o DEA, contemplando a estabilidade do sistema elétrico de potência;
- 2) Desenvolver uma aplicação para determinar dinamicamente as potências de cada unidade geradora;
- 3) Avaliar a nova solução para Sistemas de geração Híbridos;

- 4) Avaliar o desligamento dos geradores não apenas os de maiores custos de combustíveis, mas também os de maiores perdas de transmissão, os com menor capacidade máxima de geração, de acordo com as características da usina;
- 5) Aplicar a nova proposta de soluções para outras técnicas meta-heurísticas, mais aprimoradas.
- 6) Avaliar o custo do desligamento dos geradores no momento da otimização, considerando os desgastes de peças, etc.

## REFERÊNCIAS

- ABEDIN, M. J. N., H. H. MASJUKI, M. A. KALAM, A. SANJID, S. M. A. RAHMAN e B. M. MASUM. **Energy balance of internal combustion engines using alternative fuels.** *Centre for Energy Sciences, Faculty of Engineering, University of Malaya, 50603 Kuala Lumpur, Malaysia*, 2013.
- ABUSOGLU, A. e M. KANOGLU. **Exergetic and thermoeconomic analyses of diesel engine powered cogeneration: Part 1 – Formulations.** *Applied Thermal Engineering*, 29, 234-241, 2009.
- ALBERTO, I., C. A. C. COELLO e P. M. MATEO. **A comparative study of variation operators used for evolutionary multi-objective optimization.** *Information Sciences*, 273, 33-48, 2014.
- ANTCZAK, T. **A new characterization of (weak) Pareto optimality for differentiable vector optimization problems with -invex functions.** *Mathematical and Computer Modelling*, 54, 59-68, 2011.
- ARAGÓN, V. S., S. C. ESQUIVEL e C. A. COELLO COELLO. **An immune algorithm with power redistribution for solving economic dispatch problems.** *Information Sciences*, 295, 609-632, 2015.
- ARUL, R., S. VELUSAMI e G. RAVI. **A new algorithm for combined dynamic economic emission dispatch with security constraints.** *Energy*, 79, 496-511, 2015.
- ARYA, L. D., L. S. TITARE e D. P. KOTHARI. **An approach to mitigate the risk of voltage collapse accounting uncertainties using improved particle swarm optimization.** *Applied Soft Computing*, 9, 1197-1207, 2009.
- ATASHKARI, K., N. NARIMAN-ZADEH, M. GÖLCÜ, A. KHALKHALI e A. JAMALI. **Modelling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms.** *Energy Conversion and Management* 48 (2007) 1029–1041, Elsevier Ltd. All rights reserved, 2007.
- AYDIN, D., S. ÖZYÖN, C. YAŞAR e T. LIAO. **Artificial bee colony algorithm with dynamic population size to combined economic and emission dispatch problem.** *International Journal of Electrical Power & Energy Systems*, 54, 144-153, 2014.
- AZEVEDO, R. E. d. S. **Otimização Multicritério Para Despacho Econômico e Ambiental de Usinas Térmicas Utilizando Enxame de Partículas.** *Universidade Federal do Pará Instituto de Tecnologia Programa de Pós-Graduação em Engenharia Elétrica*, 105, 2015.
- BANHARNSAKUN, A., T. ACHALAKUL e B. SIRINAOVAKUL. **Artificial bee colony algorithm on distributed environments.** In *Nature and Biologically Inspired Computing (NaBIC), 2010 Second World Congress on*, 13-18. 2010.
- BARISAL, A. K. e R. C. PRUSTY. **Large scale economic dispatch of power systems using oppositional invasive weed optimization.** *Applied Soft Computing*, 29, 122-137, 2015.
- BASU, M. **Dynamic economic emission dispatch using nondominated sorting genetic algorithm-II.** *International Journal of Electrical Power & Energy Systems* 30(2): 140-149, 2008.
- **Economic environmental dispatch using multi-objective differential evolution.** *Applied Soft Computing*, 11, 2845-2853, 2011.
- **Fuel constrained economic emission dispatch using nondominated sorting genetic algorithm-II.** *Energy*, 78, 649-664, 2014a.
- **Improved differential evolution for economic dispatch.** *International Journal of Electrical Power & Energy Systems*, 63, 855-861, 2014b.
- **Kinetic gas molecule optimization for nonconvex economic dispatch problem.** *International Journal of Electrical Power & Energy Systems*, 80, 325-332, 2016.

----- **A simulated annealing-based goal-attainment method for economic emission load dispatch of fixed head hydrothermal power systems.** *Int J Electr Power Energy Syst* 27, 147–153, 2005.

BAZGAN, C., L. GOURVÈS e J. MONNOT. **Approximation with a fixed number of solutions of some multiobjective maximization problems.** *Journal of Discrete Algorithms*, 22, 19-29, 2013.

BEHERA, S., S. SAHOO e B. B. PATI. **A review on optimization algorithms and application to wind energy integration to grid.** *Renewable and Sustainable Energy Reviews*, 48, 214-227, 2015.

BENHAMIDA, F., I. ZIANE, S. SOUAG, A. GRAA e B. DEHIBA. **Solving dynamic economic load dispatch with ramp rate limit using quadratic programming.** In *North American Power Symposium (NAPS)*, 2013, 1-5. 2013.

BOGGS, P. T. e J. W. TOLLE. **Sequential quadratic programming for large scale nonlinear optimization.** *Journal of Computational and Applied Mathematics*, Vol. 124, No. 1-2, pp. 123-137, 2000.

BRODSKY, S. F. J. e R. W. HAHN. **Assessing the Influence of Power Pools on Emission Constrained Economic Dispatch.** *Power Systems, IEEE Transactions on*, 1, 57-62, 1986.

CARAMIA, M. e P. DELL'OLMO. **Multi-objective Management in Freight Logistics.** *Hardcover*, ISBN 978-1-84800-382-8, 2008.

CASTRO, A. d. O. **Otimização do Processo de Montagem de Componentes Eletrônicos de Superfície Utilizando Ferramenta Multicritério.** *Universidade Federal do Pará - Instituto de Tecnologia - Programa de Pós-Graduação em Engenharia Elétrica*, 2015.

CHANG, C. S., K. P. WONG e B. FAN. **Security-constrained multiobjective generation dispatch using bicriterion global optimisation.** *Generation, Transmission and Distribution, IEE Proceedings-*, 142, 406-414, 1995.

CHU, K. T. **A direct matrix method for computing analytical Jacobians of discretized nonlinear integro-differential equations.** *Journal of Computational Physics*, 228, 5526-5538, 2009.

COELHO, L. d. S., T. C. BORA e V. C. MARIANI. **Differential evolution based on truncated Lévy-type flights and population diversity measure to solve economic load dispatch problems.** *International Journal of Electrical Power & Energy Systems*, 57, 178-188, 2014.

COELLO COELLO, C. A. **An updated survey of evolutionary multiobjective optimization techniques: state of the art and future trends.** In *Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on*, 13 Vol. 1. 1999.

CONAMA. **RESOLUÇÃO CONAMA no 382.** *Publicada no DOU nº 1, de 2 de janeiro de 2007, Seção 1, página 131-137*, Dezembro de 2006.

DEB, K. e H. JAIN. **An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point-Based Nondominated Sorting Approach, Part I: Solving Problems With Box Constraints.** *Evolutionary Computation, IEEE Transactions on*, 18, 577-601, 2014.

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

DELIGIANNIS, V. F. e S. A. MANESIS. **Modeling Internal Combustion Engines Using a Hyper-Class of Hybrid Automata: A Case Study.** *Proceedings of the 2006 IEEE. Conference on Computer Aided Control Systems Design. Munich, Germany, October 4-6, 2006.*

DESTEK, M. A. **Renewable energy consumption and economic growth in newly industrialized countries: Evidence from asymmetric causality test.** *Renewable Energy*, 95, 478-484, 2016.

- DEVENDRA BISEN, H. M. D., Manjaree Pandit, B. K. Panigrahi. **Solution of Large Scale Economic Load Dispatch Problem using Quadratic Programming and GAMS: A Comparative Analysis.** *Journal of Information and Computing Science*, Vol. 7, No. 3, 200-211, 2012.
- DHAMANDA, A., A. DUTT, S. PRAKASH e A. K. BHARDWAJ. **A Traditional Approach to Solve Economic Load Dispatch Problem of Thermal Generating Unit Using MATLAB Programming.** *International Journal of Engineering Research & Technology (IJERT)*, 2 2013.
- DHANRAJ, R. M. S. e F. GAJENDRAN. **Quadratic programming solution to Emission and Economic Dispatch Problem.** *Journal of the Institution of engineers (India), pt EL, Vol. 86 pp.129-132, 2005, 2005.*
- DHILLON, J. e S. K. JAIN. **Multi-Objective Generation and Emission Dispatch Using NSGA-II.** *IACSIT International Journal of Engineering and Technology.*, 3, No. 52011.
- DIKE, D. O., M. I. ADINFONO e G. OGU. **Economic Dispatch of Generated Power Using Modified Lambda Iteration Method.** *IOSR Journal of Electrical and Electronics Engineering (IOSR-JEEE)*, 7, PP 49-54, 2013.
- DINCER, I. e Y. CENGEL. **Energy, Entropy and Exergy Concepts and Their Roles in Thermal Engineering.** *Entropy*, 3, 116, 2001.
- DU, Q., H. DIAO, Z. NIU, G. ZHANG, G. SHU e K. JIAO. **Effect of cooling design on the characteristics and performance of thermoelectric generator used for internal combustion engine.** *Energy Conversion and Management*, 101, 9-18, 2015.
- DUBEY, H. M., M. PANDIT e B. K. PANIGRAHI. **Ant lion optimization for short-term wind integrated hydrothermal power generation scheduling.** *International Journal of Electrical Power & Energy Systems*, 83, 158-174, 2016.
- EL-KEIB, A. A., H. MA e J. L. HART. **Economic dispatch in view of the Clean Air Act of 1990.** *Power Systems, IEEE Transactions on*, 9, 972-978, 1994.
- ELATTAR, E. E. **A hybrid genetic algorithm and bacterial foraging approach for dynamic economic dispatch problem.** *International Journal of Electrical Power & Energy Systems*, 69, 18-26, 2015.
- FARAG, A., S. AL-BAIYAT e T. C. CHENG. **Economic load dispatch multiobjective optimization procedures using linear programming techniques.** *Power Systems, IEEE Transactions on*, 10, 731-738, 1995.
- FLETCHER, R. **Practical methods of optimization.** 2nd edition, John Wiley & Sons, New York, NY, 1987.
- FONSECA, C. e P. FLEMING. **An Overview of Evolutionary Algorithms in Multiobjective Optimization.** *Evolutionary Computation*, 3, 1-16, 1995.
- GENT, M. R. e J. W. LAMONT. **Minimum-Emission Dispatch.** *Power Apparatus and Systems, IEEE Transactions on*, PAS-90, 2650-2660, 1971.
- GHANE-KANAFI, A. e E. KHORRAM. **A new scalarization method for finding the efficient frontier in non-convex multi-objective problems.** *Applied Mathematical Modelling*, 2015.
- GHASEMI, M., S. GHAVIDEL, M. M. GHANBARIAN e M. GITIZADEH. **Multi-objective optimal electric power planning in the power system using Gaussian bare-bones imperialist competitive algorithm.** *Information Sciences*, 294, 286-304, 2015.
- GITIZADEH, M. e J. AGHAEI. **Dynamic security consideration in multiobjective electricity markets.** *Applied Soft Computing* 16 (2014) 1–9, Elsevier B.V. All rights reserved, 2013.

- GOLCHHA, A. e S. G. QURESHI. **Non-Dominated Sorting Genetic Algorithm-II – A Succinct Survey**. *International Journal of Computer Science and Information Technologies - (IJCSIT)*, Vol. 6 (1), 252-255, 2015.
- GOPALAKRISHNAN, R. e A. KRISHNAN. **An Advanced Genetic Optimization Algorithm to Solve Combined Economic and Emission Dispatch Problem**. *Bonfring International Journal of Man Machine Interface*, Vol. 2, No. 1, 2012.
- GRANELLI, G. P., M. MONTAGNA, G. L. PASINI e P. MARANNINO. **Emission constrained dynamic dispatch**. *Electric Power Systems Research*, 24, 55-64, 1992.
- HESLIN, J. S. e B. F. HOBBS. **A multiobjective production costing model for analyzing emissions dispatching and fuel switching [of power stations]**. *Power Systems, IEEE Transactions on*, 4, 836-842, 1989.
- HOUNTALAS, D. T., R. G. PAPAGIANNAKIS, G. ZOVANOS e A. ANTONOPOULOS. **Avaliação comparativa de várias metodologias para contabilizar o efeito da variação de carga durante a medição da pressão do cilindro de motores a diesel de grande porte de dois tempos**. *Applied Energy*, 113, 1027-1042, 2014.
- I.G. DAMOUSIS, A. G. B., S. Dokopoulos. **Network-constrained economic dispatch using real-coded genetic algorithm**, . *IEEE Trans. Power Syst.* , 18, 198–205, 2003.
- IDOUMGHAR, L., N. CHÉRIN, P. SIARRY, R. ROCHE e A. MIRAOUI. **Hybrid ICA–PSO algorithm for continuous optimization**. *Applied Mathematics and Computation*, 219, 11149-11170, 2013.
- IRANDOUST, M. **The renewable energy-growth nexus with carbon emissions and technological innovation: Evidence from the Nordic countries**. *Ecological Indicators*, 69, 118-125, 2016.
- JIANG, S., Z. JI e Y. SHEN. **A novel hybrid particle swarm optimization and gravitational search algorithm for solving economic emission load dispatch problems with various practical constraints**. *International Journal of Electrical Power & Energy Systems*, 55, 628-644, 2014.
- KALAIVANI, L., P. SUBBURAJ e M. WILLJUICE IRUTHAYARAJAN. **Speed control of switched reluctance motor with torque ripple reduction using non-dominated sorting genetic algorithm (NSGA-II)**. *International Journal of Electrical Power & Energy Systems*, 53, 69-77, 2013.
- KARABOGA, D. **An Idea Based on Honey Bee Swarm for Numerical Optimization**. (*TECHNICAL REPORT-TR06*) *Erciyes University, Engineering Faculty Computer Engineering Department Kayseri/Türkiye*, 2005.
- KERMANSHAHI, B. S., Y. WU, K. YASUDA e R. YOKOYAMA. **Environmental marginal cost evaluation by non-inferiority surface [power systems]**. *Power Systems, IEEE Transactions on*, 5, 1151-1159, 1990.
- KING, T. D., M. E. EL-HAWARY e F. EL-HAWARY. **Optimal environmental dispatching of electric power systems via an improved Hopfield neural network model**. *Power Systems, IEEE Transactions on*, 10, 1559-1565, 1995.
- KIRKPATRICK, S., C. D. GELATT e M. P. VECCHI. **Optimization by Simulated Annealing**. *Science, New Series*, 220, No. 4598, 671-680, 1983.
- KIT PO, W. e J. YURYEVICH. **Evolutionary-programming-based algorithm for environmentally-constrained economic dispatch**. *Power Systems, IEEE Transactions on*, 13, 301-306, 1998.
- KNOLL, D. A. e D. E. KEYES. **Jacobian-free Newton–Krylov methods: a survey of approaches and applications**. *Journal of Computational Physics*, 193, 357-397, 2004.

- KOCHENBERGER, G. A., J.-K. HAO, Z. LÜ, H. WANG e F. GLOVER. **Solving large scale Max Cut problems via tabu search.** *Journal of Heuristics*, 19, 565-571, 2013.
- LIU, T., X. GAO e L. WANG. **Multi-objective optimization method using an improved NSGA-II algorithm for oil-gas production process.** *Journal of the Taiwan Institute of Chemical Engineers*, 2015.
- LORA, E. E. S. e M. A. R. NASCIMENTO. **Geração Termelétrica – Planejamento, Projeto e Operação.** Editora Interciência, Rio de Janeiro, Volume I e II, 1ª edição 2004.
- LU, P., J. ZHOU, H. ZHANG, R. ZHANG e C. WANG. **Chaotic differential bee colony optimization algorithm for dynamic economic dispatch problem with valve-point effects.** *International Journal of Electrical Power & Energy Systems*, 62, 130-143, 2014.
- MAGHBOULI, A., W. YANG, U. HUI, J. LI, S. K. CHOU e K. J. CHUA. **Um modelo de combustão avançado, juntamente com o mecanismo de reação química detalhada para DI simulação motor diesel.** *Applied Energy*, 111, 758-770, 2013.
- MEDEIROS, G. F. d. e M. KRIPKA. **Algumas Aplicações de Métodos Heurísticos na Otimização de Estruturas.** *Revista CIATEC – Universidade de Passo Fundo (UPF)*, vol.4 (1), 19-32, 2012.
- MENG, X.-B., X. Z. GAO, Y. LIU e H. ZHANG. **A novel bat algorithm with habitat selection and Doppler effect in echoes for optimization.** *Expert Systems with Applications*, 42, 6350-6364, 2015.
- MEYBODI, M. A. e M. BEHNIA. **Impact of carbon tax on internal combustion engine size selection in a medium scale CHP system.** *Applied Energy*, 88, 5153-5163, 2011.
- MIRJALILI, S. e A. LEWIS. **Novel frameworks for creating robust multi-objective benchmark problems.** *Information Sciences*, 300, 158-192, 2015.
- MIRJALILI, S., S. M. MIRJALILI e A. LEWIS. **Grey Wolf Optimizer.** *Advances in Engineering Software*, 69, 46-61, 2014.
- MUCCILLO, M. e A. GIMELLI. **Experimental development, 1D CFD simulation and energetic analysis of a 15 kw micro-CHP unit based on reciprocating internal combustion engine.** *Applied Thermal Engineering*, 71, 760-770, 2014.
- NANDA, J., D. P. KOTHARI e K. S. LINGAMURTHY. **Economic-emission load dispatch through goal programming techniques.** *Energy Conversion, IEEE Transactions on*, 3, 26-32, 1988.
- NASCIMENTO, M. H. R., M. V. A. NUNES, J. L. M. RODRÍGUEZ e J. C. LEITE. **A new solution to the economical load dispatch of power plants and optimization using differential evolution.** *Electrical Engineering*, 1-11, 2016.
- NEVES, D. e C. A. SILVA. **Optimal electricity dispatch on isolated mini-grids using a demand response strategy for thermal storage backup with genetic algorithms.** *Energy*, 82, 436-445, 2015.
- NGUYEN, T. T., D. N. VO e B. H. DINH. **Cuckoo search algorithm for combined heat and power economic dispatch.** *International Journal of Electrical Power & Energy Systems*, 81, 204-214, 2016.
- NIKHIL, R., M. J. ROELLE, H.-H. LIAO, A. F. JUNGKUNZ, C.-F. CHANG, S. PARK e J. C. GERDES. **Model-Based Control of HCCI Engines Using Exhaust Recompression.** 2010.
- NWULU, N. I. e X. XIA. **Multi-objective dynamic economic emission dispatch of electric power generation integrated with game theory based demand response programs.** *Energy Conversion and Management*, 89, 963-974, 2015.
- OSÓRIO, G. J., J. M. LUJANO-ROJAS, J. C. O. MATIAS e J. P. S. CATALÃO. **A probabilistic approach to solve the economic dispatch problem with intermittent renewable energy sources.** *Energy*, 82, 949-959, 2015.

- PANIGRAHI, B. K., P. V. RAVIKUMAR, D. SANJOY e D. SWAGATAM. **Multiobjective fuzzy dominance based bacterial foraging algorithm to solve economic emission dispatch problem.** *Elsevier Ltd. All rights reserved, Energy*, 2010.
- PARK, J. B., Y. W. JEONG, J. R. SHIN e K. Y. LEE. **An Improved Particle Swarm Optimization for Nonconvex Economic Dispatch Problems.** *IEEE Transactions on Power Systems*, 25, 156-166, 2010.
- PURKAYASTHA, B. e N. SINHA. **Optimal Combined Economic and Emission Load Dispatch using Modified NSGA-II with Adaptive Crowding Distance.** *International Journal of Information Technology and Knowledge Management*, 2, No. 2, 553-559, 2010.
- RAHUL DOGRA, N. G., Harsha Saroa. **Economic Load Dispatch Problem and Matlab Programming of Different Methods.** *International Conference of Advance Research and Innovation (ICARI-2014)*, 2014.
- RAJAN, A. e T. MALAKAR. **Optimal reactive power dispatch using hybrid Nelder–Mead simplex based firefly algorithm.** *International Journal of Electrical Power & Energy Systems*, 66, 9-24, 2015.
- RAMOS, D. S. e G. L. SUSTERAS. **Utilização de Algoritmos Genéticos para Previsão da Contratação de Energia pelas Distribuidoras.** *IEEE LATIN AMERICA TRANSACTIONS*, 4, 268-278, 2006.
- RODRÍGUEZ-TORAL, M. A., W. MORTON e D. R. MITCHELL. **The use of new SQP methods for the optimization of utility systems.** *Computers and Chemical Engineering, Vol. 25, No. 2-3, pp. 287-300*, 2001.
- ROQUE, C. M. C. e P. A. L. S. MARTINS. **Differential evolution for optimization of functionally graded beams.** *Composite Structures*, 133, 1191-1197, 2015.
- SAHOO, S., K. MAHESH DASH, R. C. PRUSTY e A. K. BARISAL. **Comparative analysis of optimal load dispatch through evolutionary algorithms.** *Ain Shams Engineering Journal*, 6, 107-120, 2015.
- SÁNCHEZ, A. S., E. A. TORRES e R. A. KALID. **Renewable energy generation for the rural electrification of isolated communities in the Amazon Region.** *Renewable and Sustainable Energy Reviews*, 49, 278-290, 2015.
- SHARMA, Y. e L. C. SAIKIA. **Automatic generation control of a multi-area ST – Thermal power system using Grey Wolf Optimizer algorithm based classical controllers.** *International Journal of Electrical Power & Energy Systems*, 73, 853-862, 2015.
- SILVA, L. R. B. d. e R. P. d. SILVA. **Uma estratégia de implementação paralela eficiente de uma heurística de particionamento de grafos aplicados à simulação de escoamento multifásico.** *Latin American Journal of Energy Research (Lajer)*, 1, 91-100, 2014.
- SINGH, H. P., Y. S. BRAR e D. P. KOTHARI. **Multiobjective load dispatch using Particle Swarm Optimization.** In *Industrial Electronics and Applications (ICIEA), 2013 8th IEEE Conference on*, 272-277. 2013.
- SONG, X., L. TANG, S. ZHAO, X. ZHANG, L. LI, J. HUANG e W. CAI. **Grey Wolf Optimizer for parameter estimation in surface waves.** *Soil Dynamics and Earthquake Engineering*, 75, 147-157, 2015.
- SRINIVAS, N. e K. DEB. **Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms.** *Journal of Evolutionary Computation*, 2, No 3, 221-248, 1993.
- STORN, R. **Differential evolution ? a simple and efficient heuristic for global optimization over continuous spaces.** *Journal of Global Optimization, Vol. 11, No. 4, pp. 341-359*, 1997.

- SUKSONGHONG, K., K. BOONLONG e K.-L. GOH. **Multi-objective genetic algorithms for solving portfolio optimization problems in the electricity Market.** *Electrical Power and Energy Systems, Elsevier Ltd. All rights reserved*, 2014.
- SULAIMAN, M. H., Z. MUSTAFFA, M. R. MOHAMED e O. ALIMAN. **Using the gray wolf optimizer for solving optimal reactive power dispatch problem.** *Applied Soft Computing*, 32, 286-292, 2015.
- TAGHDISIAN, H., M. R. PISHVAIE e F. FARHADI. **Multi-objective optimization approach for green design of methanol plant based on CO<sub>2</sub>-efficiency indicator.** *Journal of Cleaner Production*, 103, 640-650, 2015.
- TALAQ, J. H., F. EL-HAWARY e M. E. EL-HAWARY. **A summary of environmental/economic dispatch algorithms.** *Power Systems, IEEE Transactions on*, 9, 1508-1516, 1994.
- TANKASALA, G. R. **Artificial Bee Colony Optimisation for Economic Load Dispatch of a Modern Power system.** *International Journal of Scientific & Engineering Research*, 32012.
- TAVANA, M., Z. LI, M. MOBIN, M. KOMAKI e E. TEYMOURIAN. **Multi-objective control chart design optimization using NSGA-III and MOPSO enhanced with DEA and TOPSIS.** *Expert Systems with Applications*, 50, 17-39, 2016.
- TIAN, J., H. WEI e J. TAN. **Global optimization for power dispatch problems based on theory of moments.** *International Journal of Electrical Power & Energy Systems*, 71, 184-194, 2015.
- VAHIDINASAB, V. e S. JADID. **Multiobjective environmental/techno-economic approach for strategic bidding in energy markets.** *Elsevier Ltd. All rights reserved, Applied Energy*, 2008.
- WALL, G. e M. GONG. **On Exergy and Sustainable Development, Part I: Conditions and Concepts.** *Exergy An International Journal*, Vol. 1, No. 32001.
- WANG, L. e C. SINGH. **Environmental/economic power dispatch using a fuzzified multi-objective particle swarm optimization algorithm.** *Electric Power Systems Research*, 77, 1654-1664, 2007a.
- . **Environmental/economic power dispatch using a fuzzified multi-objective particle swarm optimization algorithm.** *Electric Power Systems Research 77 (2007) 1654–1664, Elsevier B.V. All rights reserved*, 2007b.
- WONG, K. P. e C. C. FUNG. **Simulated annealing based economic dispatch algorithm.** *IEE. Proc. C* 140, 507–513., 1993.
- WOOD, A. J. e B. F. WOLLENBERG. **Power generation operation and control.** New York: John Wiley & Sons; 1984, 1984.
- YALCINOZ, T. e H. ALTUN. **Environmentally constrained economic dispatch via a genetic algorithm with arithmetic crossover.** In *Africon Conference in Africa, 2002. IEEE AFRICON. 6th*, 923-928 vol.2. 2002.
- YING-TUNG, H., C. HSIAO-DONG, L. CHUN-CHANG e C. YUAN-LIN. **A computer package for optimal multi-objective VAR planning in large scale power systems.** *Power Systems, IEEE Transactions on*, 9, 668-676, 1994.
- YOKOYAMA, R., S. H. BAE, T. MORITA e H. SASAKI. **Multiobjective optimal generation dispatch based on probability security criteria.** *Power Systems, IEEE Transactions on*, 3, 317-324, 1988.
- ZAHAVI, J. e L. EISENBERG. **Economic-Environmental Power Dispatch.** *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-5, 485-489, 1975.

ZHOUA, A., Q. BO-YANG, H. L. Z. SHI-ZHENG, S. P. NAGARATNAM e Z. QINGFU. **Multiobjective evolutionary algorithms: A survey of the state of the art.** *Elsevier B.V. All rights reserved, Swarm and Evolutionary Computation*, 2011.

ZWE-LEE, G. **Particle swarm optimization to solving the economic dispatch considering the generator constraints.** *IEEE Transactions on Power Systems*, 18, 1187-1195, 2003.

## **ANEXOS**

## ANEXO I - DADOS CARACTERÍSTOS DOS GERADORES

Gerador 01									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	04.07.20 13	04.07.20 13	04.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13
Horário da Medição:	10:06	10:46	11:52	09:05	09:38	10:54	11:05	LIM.	LIM.
Temperatura Externa:	31.0	31.0	31.0	36.0	36.0	36.0	36.0		
Temperatura Admissão da Mistura:	39.1	39.8	38.9	34.2	34.8	35.6	36.2		
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m <sup>3</sup> /hor	805,3	717,5	640,8	575,6	502,6	431,6	359,6	0,0	0,0
Consumo de combustível em l/seg	223,7	199,3	178,0	159,9	139,6	119,9	99,9		
Potência Elétrica / Q (kW)	1331,00	1211,00	1016,00	741,00	713,00	467,00	505,00		
Potência de saída do motor em kW / P (kW)	<b>3.351</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 02									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	03.07.20 13	03.07.2 013	03.07.20 13						
Horário da Medição:	09:54	10:09	19:29	10:50	11:13	11:34	11:47	12:00	12:11
Temperatura Externa:	26.3	26.3	26.3	26.3	26.3	26.3	26.3	26.3	26.3
Temperatura Admissão da Mistura:	33.1	33.1	33.3	31.6	29.5	29.5	29.2	29.3	29.8
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m <sup>3</sup> /hor	771,5	694,8	618,8	542,9	472,0	398,9	331,6	271,1	209,2
Consumo de combustível em l/seg	214,3	193,0	171,9	150,8	131,1	110,8	92,1	75,3	58,1
Potência Elétrica / Q (kW)	841,00	811,00	776,00	609,00	215,00	370,00	318,00	316,00	565,00
Potência de saída do motor em kW / P (kW)	<b>3.701</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 03									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	03.07.20 13								
Horário da Medição:	09:52	10:05	10:26	10:47	11:06	11:31	11:56	12:07	12:21
Temperatura Externa:	26.3	26.3	26.3	26.3	26.3	26.3	26.3	26.3	26.3
Temperatura Admissão da Mistura:	27.2	27.2	27.2	27.3	25.1	24.	24.4	24.3	24.4
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	775,4	695,2	619,2	547,9	472,0	401,4	337,3	267,8	206,3
Consumo de combustível em l/seg	215,4	193,1	172,0	152,2	131,1	111,5	93,7	74,4	57,3
Potência Elétrica / Q (kW)	903,00	818,00	744,00	578,00	228,00	366,00	<b>-422,00</b>	<b>-326,00</b>	561,00
Potência de saída do motor em kW / P (kW)	<b>3.602</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 04									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	03.07.20 13								
Horário da Medição:	08:50	09:05	09:21	09:34	09:48	10:03	10:30	10:45	11:05
Temperatura Externa:	26.6	26.6	26.6	26.6	26.6	26.6	26.6	26.6	26.6
Temperatura Admissão da Mistura:	33.5	33.5	33.7	34.4	33.6	33.0	33.3	32.5	30.7
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	754,9	670,0	592,2	524,9	459,0	395,3	330,5	266,8	204,1
Consumo de combustível em l/seg	209,7	186,1	164,5	145,8	127,5	109,8	91,8	74,1	56,7
Potência Elétrica / Q (kW)	944,00	843,00	791,00	613,00	512,00	416,00	360,00	272,00	521,00
Potência de saída do motor em kW / P (kW)	<b>3.351</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 05									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	03.07.20 13	03.07.20 13	03.07.20 13	03.07.20 13	03.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13
Horário da Medição:	08:36	08:49	09:04	09:20	09:33	09:46	10:53	12:48	12:58
Temperatura Externa:	26.6	26.6	26.6	26.6	26.6	26.6	35.4	35.4	35.4
Temperatura Admissão da Mistura:	31.1	31	31.3	30.5	32.1	30.6	35.9	37.3	37.6
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	757,8	683,6	611,6	542,9	469,1	398,2	336,2	272,5	213,8
Consumo de combustível em l/seg	210,5	189,9	169,9	150,8	130,3	110,6	93,4	75,7	59,4
Potência Elétrica / Q (kW)	949,00	889,00	751,00	659,00	511,00	495,00	448,00	393,00	544,00
Potência de saída do motor em kW / P (kW)	<b>3.453</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 06									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	04.07.20 13	04.07.20 13	05.07.20 13						
Horário da Medição:	10:07	11:02	11:26	09:50	10:04	10:27	11:20	11:44	13:25
Temperatura Externa:			35.5	35.5	35.5	35.5	35.5	35.5	
Temperatura Admissão da Mistura:	36.7	37.8	37.9	37.1	37.4	37.4	37.9	38.5	38.8
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	740,9	668,2	596,5	528,5	458,6	392,0	329,0	261,7	218,2
Consumo de combustível em l/seg	205,8	185,6	165,7	146,8	127,4	108,9	91,4	72,7	60,6
Potência Elétrica / Q (kW)	1306,00	1157,00	1056,00	925,00	666,00	531,00	472,00	384,00	514,00
Potência de saída do motor em kW / P (kW)	<b>2.973</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 07									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	02.07.20 13	02.07.20 13	02.07.20 13	03.07.20 13	03.07.20 13	05.07.20 13	05.07.20 13		
Horário da Medição:	15:47	16:16	16:31	07:57	08:20	10:59	13:12		
Temperatura Externa:	30.7	30.7	30.7	26.1	26.1	26.1			
Temperatura Admissão da Mistura:	31.8	32.9	32.8	26.4	27.2	31.8	32.7		
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	756,0	689,4	609,8	520,6	469,1	398,9	396,0	0,0	0,0
Consumo de combustível em l/seg	210,0	191,5	169,4	144,6	130,3	110,8	110,0		
Potência Elétrica / Q (kW)	1154,00	1062,00	843,00	576,00	504,00	469,00	841,00		
Potência de saída do motor em kW / P (kW)	<b>3.503</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 08									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	02.07.20 13	02.07.20 13	02.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13	03.07.20 13	03.07.20 13
Horário da Medição:	15:31	15:43	15:51	10:06	10:26	11:12	12:51	16:31	16:19
Temperatura Externa:	30.6	30.6	30.6	35.0	35.0	35.0	35.7	26.0	26.0
Temperatura Admissão da Mistura:	32.9	32.6	32.9	31.8	31.9	32.8	34.2	28.2	28.2
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	752,0	681,5	612,0	526,3	452,2	401,0	326,2	263,9	207,0
Consumo de combustível em l/seg	208,9	189,3	170,0	146,2	125,6	111,4	90,6	73,3	57,5
Potência Elétrica / Q (kW)	1160,00	1024,00	933,00	791,00	668,00	626,00	544,00	315,00	577,00
Potência de saída do motor em kW / P (kW)	<b>3.333</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 09									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	02.07.20 13	02.07.20 13	02.07.20 13	03.07.20 13	03.07.20 13	03.07.20 13	05.07.20 13	05.07.20 13	05.07.20 13
Horário da Medição:	15:49	16:04	16:18	16:06	16:18	16:30	11:04	12:52	13:02
Temperatura Externa:	30.7	30.7	30.7	26.0	26.0	26.0			
Temperatura Admissão da Mistura:	32.7	33.0	33.7	28.6	28.5	28.3	31.9	33.8	34.0
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	761,4	672,1	613,8	522,0	460,4	385,9	325,4	265,3	196,6
Consumo de combustível em l/seg	211,5	186,7	170,5	145,0	127,9	107,2	90,4	73,7	54,6
Potência Elétrica / Q (kW)	1161	1075	923,00	753,00	671,00	533,00	365,00	442,00	534,00
Potência de saída do motor em kW / P (kW)	<b>3.903</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

Gerador 10									
CONSUMOS REAIS E EFICIÊNCIAS DE CADA MÁQUINA									
Data da Medição:	03.07.20 13								
Horário da Medição:	08:05	08:16	08:34	08:46	09:03	09:19	15:49	15:36	15:21
Temperatura Externa:	26.1	26.6	26.6	26.6	26.6	26.6	23.7	23.7	23.7
Temperatura Admissão da Mistura:	31.9	32	32.4	32.5	32.5	32.6	32.8	32.7	32.3
<b>VARIÁVEIS</b>	100%	90%	80%	70%	60%	50%	40%	30%	20%
Consumo de combustível em m3/hor	752,4	675,7	603,0	535,7	467,3	396,0	332,3	267,8	209,9
Consumo de combustível em l/seg	209,0	187,7	167,5	148,8	129,8	110,0	92,3	74,4	58,3
Potência Elétrica / Q (kW)	857,00	845,00	706,00	660,00	579,00	488,00	452,00	324,00	552,00
Potência de saída do motor em kW / P (kW)	<b>2.953</b>	<b>2.980</b>	<b>2.640</b>	<b>2.310</b>	<b>1.980</b>	<b>1.650</b>	<b>1.320</b>	<b>990</b>	<b>660</b>

## ANEXO II - DADOS DE EMISSÕES DOS GERADORES

<b>Medições de Emissões</b>							
<b>UGGN01</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,45	10,17	9,91	9,63	9,30	8,85	8,48
ppm CO	362	324	352	384	431	498	580
ppm NO <sub>x</sub>	232,8	199,9	194,1	198,7	220,6	242,8	263,2
ppm NO	123	106	119	137	164	196	217
ppm NO <sub>2</sub>	109,6	93,7	74,8	61,8	56,3	46,7	46,1
% CO <sub>2</sub> IR	7,05	6,78	7,02	7,237	7,61	8,01	8,28
ppm CxHy	1734	2449	2398	2332	2120	1909	1272
°C Tstack	386,2	399,2	418,5	432,1	446,5	479	493,4
l/min Pump	0,94	0,96	0,96	0,96	0,98	0,97	0,98
°C Tamb	32,2	40	39,3	42,3	35,7	34,2	31,1

<b>Medições de Emissões</b>							
<b>UGGN02</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,41	10,32	10,17	9,94	9,73	9,39	8,93
ppm CO	367	391	418	454	483	437	490
ppm NO <sub>x</sub>	232,5	205,5	191,5	182,4	177,2	185,4	182,3
ppm NO	123	119	127	141	155	105	111
ppm NO <sub>2</sub>	109,6	86,6	64,1	41,2	22,6	0,6	0,9
% CO <sub>2</sub> IR	7,05	7,02	6,99	7,02	7,05	7,62	7,88
ppm CxHy	1734	2144	2373	2560	2684	2341	2332
°C Tstack	386,2	391	407,5	432,5	446,4	448,2	474,1
l/min Pump	0,94	0,94	0,95	0,96	0,97	0,98	0,98
°C Tamb	32,2	34,7	38,6	41,6	39,8	38,4	39,5

<b>Medições de Emissões</b>							
<b>UGGN03</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,44	10,40	10,23	10,04	9,71	9,39	8,93
ppm CO	403	372	369	385	419	437	490
ppm NO <sub>x</sub>	111,3	108,4	98,6	96,5	97	105,4	112,3
ppm NO	111	108	98	96	97	105	111
ppm NO <sub>2</sub>	0	0,2	0,1	0,2	0,1	0,6	0,9
% CO <sub>2</sub> IR	7,28	7,18	7,19	7,28	7,42	7,62	7,88
ppm CxHy	1283	1820	2074	2203	2304	2341	2332
°C Tstack	381.5	377.7	396.0	410.7	425.6	448.2	474.1
l/min Pump	0,94	0,98	0,98	0,98	0,98	0,98	0,98
°C Tamb	31,9	34	36,4	36,3	38	38,4	39,5

<b>Medições de Emissões</b>							
<b>UGGN4</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,31	10,22	9,99	9,86	9,61	9,29	8,96
ppm CO	358	386	420	445	483	533	601
ppm NO <sub>x</sub>	290,9	258,8	223,1	218	216,2	213,1	210,2
ppm NO	146	135	139	171	176	185	194
ppm NO <sub>2</sub>	145,4	123,3	83,9	46,5	40	28,3	15,9
% CO <sub>2</sub> IR	6,82	6,94	7,09	7,16	7,33	7,5	7,7
ppm CxHy	1392	1537	1688	1706	1739	1771	1780
°C Tstack	390,3	406,1	426,2	439,4	462	478,8	510,4
l/min Pump	0,94	0,96	0,97	0,97	0,97	0,98	0,98
°C Tamb	27,2	27	27,8	28,2	28,1	29,1	28,6

<b>Medições de Emissões</b>							
<b>UGGN5</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,70	10,48	10,24	9,97	9,65	9,31	8,93
ppm CO	301	326	350	375	405	441	497
ppm NO <sub>x</sub>	136,2	130,8	128,9	136,4	143,3	153,8	158,1
ppm NO	73	82	122	111	129	144	151
ppm NO <sub>2</sub>	62,7	48,4	7	25,5	14,8	9,6	7,6
% CO <sub>2</sub> IR	6,65	6,78	6,96	7,11	7,3	7,47	7,63
ppm C <sub>x</sub> H <sub>y</sub>	1645	1741	1687	1727	1657	1551	1249
°C Tstack	381,3	396,1	418,3	444	472	493,5	495,7
l/min Pump	0,96	0,96	0,97	0,97	0,97	0,97	0,98
°C Tamb	27,5	29	27,4	27,3	27	26	27,2

<b>Medições de Emissões</b>							
<b>UGGN6</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,47	10,33	10,20	10,01	9,76	9,47	9,05
ppm CO	333	363	385	413	440	480	546
ppm NO <sub>x</sub>	198,2	186,5	177,4	168,2	162,2	157,6	158,3
ppm NO	93	102	114	127	133	153	155
ppm NO <sub>2</sub>	105,6	84,2	63,5	41,6	29	4,8	3,5
% CO <sub>2</sub> IR	6,66	6,78	6,89	7,06	7,24	7,47	7,78
ppm C <sub>x</sub> H <sub>y</sub>	1728	1745	1753	1674	1772	1712	1659
°C Tstack	383,1	400,4	419,3	434,5	437,4	477	419,7
l/min Pump	0,96	0,97	0,97	0,97	0,98	0,98	0,98
°C Tamb	38,4	36,6	36,3	34	34,4	32,4	31,5

<b>Medições de Emissões</b>							
<b>UGGN7</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,47	10,48	10,20	10,04	9,76	9,47	9,05
ppm CO	333	326	385	385	440	480	546
ppm NO <sub>x</sub>	228,2	130,8	177,4	96,5	162,2	157,6	168,3
ppm NO	93	82	114	96	133	153	155
ppm NO <sub>2</sub>	105,6	48,4	63,5	0,2	29	4,8	3,5
% CO <sub>2</sub> IR	6,66	6,78	6,89	7,28	7,24	7,47	7,78
ppm CxHy	1728	1741	1753	2203	1772	1712	1659
°C Tstack	383,1	396,1	419,3	410,7	437,4	477	419,7
l/min Pump	0,96	0,96	0,97	0,98	0,98	0,98	0,98
°C Tamb	38,4	29	36,3	36,3	34,4	32,4	31,5

<b>Medições de Emissões</b>							
<b>UGGN8</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,45	10,48	10,17	10,04	9,76	9,47	8,48
ppm CO	362	326	418	385	440	480	580
ppm NO <sub>x</sub>	232,8	193,8	191,5	96,5	162,2	157,6	153,2
ppm NO	123	82	127	96	133	153	217
ppm NO <sub>2</sub>	109,6	48,4	64,1	0,2	29	4,8	46,1
% CO <sub>2</sub> IR	6,57	6,78	6,99	7,28	7,24	7,47	8,28
ppm CxHy	1734	1741	2373	2203	1772	1712	1272
°C Tstack	386,2	396,1	407,5	410,7	437,4	477	493,4
l/min Pump	0,94	0,96	0,95	0,98	0,98	0,98	0,98
°C Tamb	32,2	29	38,6	36,3	34,4	32,4	31,1

<b>Medições de Emissões</b>							
<b>UGGN9</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,47	10,22	10,17	10,04	9,76	9,39	8,48
ppm CO	333	386	418	385	440	437	580
ppm NO <sub>x</sub>	198,2	197,8	191,5	166,5	162,2	105,4	153,2
ppm NO	93	135	127	96	133	105	217
ppm NO <sub>2</sub>	105,6	123,3	64,1	0,2	29	0,6	46,1
% CO <sub>2</sub> IR	6,66	6,94	6,99	7,28	7,24	7,62	8,28
ppm CxHy	1728	1537	2373	2203	1772	2341	1272
°C Tstack	383,1	406,1	407,5	410,7	437,4	448,2	493,4
l/min Pump	0,96	0,96	0,95	0,98	0,98	0,98	0,98
°C Tamb	38,4	27	38,6	36,3	34,4	38,4	31,1

<b>Medições de Emissões</b>							
<b>UGGN10</b>	100%	90%	80%	70%	60%	50%	40%
% O <sub>2</sub>	10,45	10,17	10,17	10,04	9,76	9,39	8,48
ppm CO	362	324	418	385	440	437	580
ppm NO <sub>x</sub>	232,8	199,9	191,5	166,5	162,2	145,4	153,2
ppm NO	123	106	127	96	133	105	217
ppm NO <sub>2</sub>	109,6	93,7	64,1	0,2	29	0,6	46,1
% CO <sub>2</sub> IR	6,65	6,78	6,99	7,28	7,24	7,62	8,28
ppm CxHy	1734	2449	2373	2203	1772	2341	1272
°C Tstack	386,2	399,2	407,5	410,7	437,4	448,2	493,4
l/min Pump	0,94	0,96	0,95	0,98	0,98	0,98	0,98
°C Tamb	32,2	40	38,6	36,3	34,4	38,4	31,1

### ANEXO III – COEFICIENTES DE PERDAS DE TRANSMISSÃO

$$B_{i,j} = \begin{bmatrix} 0.0014 & 0.0012 & 0.0007 & -0.0001 & -0.0003 & -0.0001 & -0.0001 & -0.0001 & -0.0003 & 0.0005 & -0.0003 & -0.0002 & 0.0004 & 0.0003 & -0.0001 \\ 0.0012 & 0.0015 & 0.0013 & 0.0000 & -0.0005 & -0.0002 & 0.0000 & 0.0001 & -0.0002 & -0.0004 & -0.0004 & -0.0000 & 0.0004 & 0.0010 & -0.0002 \\ 0.0007 & 0.0013 & 0.0076 & -0.0001 & -0.0013 & -0.0009 & -0.0001 & 0.0000 & -0.0008 & -0.0012 & -0.0017 & -0.0000 & -0.0026 & 0.0111 & -0.0028 \\ -0.0001 & 0.0000 & -0.0001 & 0.0034 & -0.0007 & -0.0004 & 0.0011 & 0.0050 & 0.0029 & 0.0032 & -0.0011 & -0.0000 & 0.0001 & 0.0001 & -0.0026 \\ -0.0003 & -0.0005 & -0.0013 & -0.0007 & 0.0090 & 0.0014 & -0.0003 & -0.0012 & -0.0010 & -0.0013 & 0.0007 & -0.0002 & -0.0002 & -0.0024 & -0.0003 \\ -0.0001 & -0.0002 & -0.0009 & -0.0004 & 0.0014 & 0.0016 & -0.0000 & -0.0006 & -0.0005 & -0.0008 & 0.0011 & -0.0001 & -0.0002 & -0.0017 & 0.0003 \\ -0.0001 & 0.0000 & -0.0001 & 0.0011 & -0.0003 & -0.0000 & 0.0015 & 0.0017 & 0.0015 & 0.0009 & -0.0005 & 0.0007 & -0.0000 & -0.0002 & -0.0008 \\ -0.0001 & 0.0001 & 0.0000 & 0.0050 & -0.0012 & -0.0006 & 0.0017 & 0.0168 & 0.0082 & 0.0079 & -0.0023 & -0.0036 & 0.0001 & 0.0005 & -0.0078 \\ -0.0003 & -0.0002 & -0.0008 & 0.0029 & -0.0010 & -0.0005 & 0.0015 & 0.0082 & 0.0129 & 0.0116 & -0.0021 & -0.0025 & 0.0007 & -0.0012 & -0.0072 \\ -0.0005 & -0.0004 & -0.0012 & 0.0032 & -0.0013 & -0.0008 & 0.0009 & 0.0079 & 0.0116 & 0.0200 & -0.0027 & -0.0034 & 0.0009 & -0.0011 & -0.0088 \\ -0.0003 & -0.0004 & -0.0017 & -0.0011 & 0.0007 & 0.0011 & -0.0005 & -0.0023 & -0.0021 & -0.0027 & 0.0140 & 0.0001 & 0.0004 & -0.0038 & 0.0168 \\ -0.0002 & -0.0000 & -0.0000 & -0.0000 & -0.0002 & -0.0001 & 0.0007 & -0.0036 & -0.0025 & -0.0034 & 0.0001 & 0.0054 & -0.0001 & -0.0004 & 0.0028 \\ 0.0004 & 0.0004 & -0.0026 & 0.0001 & -0.0002 & -0.0002 & -0.0000 & 0.0001 & 0.0007 & 0.0009 & 0.0004 & -0.0001 & 0.0103 & -0.0101 & 0.0028 \\ 0.0003 & 0.0010 & 0.0111 & 0.0001 & -0.0024 & -0.0017 & -0.0002 & 0.0005 & -0.0012 & -0.0011 & -0.0038 & -0.0004 & -0.0101 & 0.0578 & -0.0094 \\ -0.0001 & -0.0002 & -0.0028 & -0.0026 & -0.0003 & 0.0003 & -0.0008 & -0.0078 & -0.0072 & -0.0088 & 0.0168 & 0.0028 & 0.0028 & -0.0094 & 0.1283 \end{bmatrix}$$

$$B_{0i} = [-0.0001 \quad -0.0002 \quad 0.0028 \quad -0.0001 \quad 0.0001 \quad -0.0003 \quad -0.0002 \quad -0.0002 \quad 0.0006 \quad 0.0039 \quad -0.0017 \quad -0.0000 \quad -0.0032 \quad 0.0067 \quad -0.0064]$$

$$B_{00} = 0.0055;$$

## ANEXO IV – ALGORITMO DO PARA NOVA SOLUÇÃO NO MATLAB

```
clear;
clc;
global data B Pd emidtco emidtno F1 E1 E2 P

nt = 1;
for t = 1:nt

tic;

%Dados do Gerador
dataI = [0.002035    8.43205 85.6348 100 250    817.06193
         0.003866    6.41031 303.778  50  230    876.5862
         0.002182    7.4289  847.1484 200 500    1494.3699
         0.001345    8.3154  274.2241 85  265    990.75073
         0.002162    7.42289 847.1484 200 500    1493.7145
         0.005963    6.91559 202.0258 200 490    832.93363];

%NOx
emidtnoI =    [0.006323    -0.38128    80.9019    94.176775
               0.006483    -0.79027    28.8249    8.491625
               0.003174    -1.36061    324.1775   231.4578
               0.006732    -2.39928    610.2535   454.9534
               0.003174    -1.36061    324.1775   231.4578
               0.006181    -0.39077    50.3808    61.823075];

%CO2
emidtcoI =    [0.26511   -61.019    5080.148 1808.9145
               0.140053  -29.952    3824.77  2290.71508
               0.105929  -9.5528    1342.851 1296.20054
               0.106409  -12.736    1819.625 1505.83433
               0.105929  -9.5528    1342.851 1296.20054
               0.403144  -121.98    11381.07 3925.3834];

%Matriz de Perdas
BI = 1e-2*[0.000200  0.000010  0.000020  0.000010  0.00000  -0.00003
           0.000010  0.000300  -0.00002  0.000000  0.00001  0.00001
           0.000020  -0.00002  0.000100  -0.00001  0.00001  0.00001
           0.000010  0.000000  -0.00001  0.000150  0.00001  0.00005
           0.000000  0.000010  0.000010  0.000010  0.00025  0.00002
           -0.00003  0.000010  0.000010  0.000050  0.00002  0.00021];

%Ordenação dos Motores
Pm = [1 2 3 4 5 6];
%opm = 1, reduzir perdas de transm.
%opm = 2, reduzir emissões de NOx
%opm = 3, reduzir emissões de COx
%opm = 4, reduzir Custos totais
%opm = 5, reduzir Custos totais, usando os de maior Pw Max
opm = 3;
if opm == 1 %Reduzir Perdas de Trans
    for i = 1: length(dataI(:,1))-1
        for j = i+1: length(dataI(:,1))
            if sum(BI(i,:)) > sum(BI(j,:))
                aux = dataI(i,:);
                dataI(i,:) = dataI(j,:);
                dataI(j,:) = aux;
                Pmaux = Pm(i);
                Pm(i) = Pm(j);
                Pm(j) = Pmaux;
            end
        end
    end
end
```

```

        auxB = BI(i,:);
        BI(i,:) = BI(j,:);
        BI(j,:) = auxB;
        auxemidtno = emidtnoI(i,:);
        emidtnoI(i,:) = emidtnoI(j,:);
        emidtnoI(j,:) = auxemidtno;
        auxemidtco = emidtcoI(i,:);
        emidtcoI(i,:) = emidtcoI(j,:);
        emidtcoI(j,:) = auxemidtco;
    end
end
end
if opm == 2 %Reduzir NOx
    for i = 1: length(dataI(:,1))-1
        for j = i+1: length(dataI(:,1))
            if emidtnoI(i,4) > emidtnoI(j,4)
                aux = dataI(i,:);
                dataI(i,:) = dataI(j,:);
                dataI(j,:) = aux;
                Pmaux = Pm(i);
                Pm(i) = Pm(j);
                Pm(j) = Pmaux;
                auxB = BI(i,:);
                BI(i,:) = BI(j,:);
                BI(j,:) = auxB;
                auxemidtno = emidtnoI(i,:);
                emidtnoI(i,:) = emidtnoI(j,:);
                emidtnoI(j,:) = auxemidtno;
                auxemidtco = emidtcoI(i,:);
                emidtcoI(i,:) = emidtcoI(j,:);
                emidtcoI(j,:) = auxemidtco;
            end
        end
    end
end
if opm == 3 %Reduzir COx
    for i = 1: length(dataI(:,1))-1
        for j = i+1: length(dataI(:,1))
            if emidtcoI(i,4) > emidtcoI(j,4)
                aux = dataI(i,:);
                dataI(i,:) = dataI(j,:);
                dataI(j,:) = aux;
                Pmaux = Pm(i);
                Pm(i) = Pm(j);
                Pm(j) = Pmaux;
                auxB = BI(i,:);
                BI(i,:) = BI(j,:);
                BI(j,:) = auxB;
                auxemidtno = emidtnoI(i,:);
                emidtnoI(i,:) = emidtnoI(j,:);
                emidtnoI(j,:) = auxemidtno;
                auxemidtco = emidtcoI(i,:);
                emidtcoI(i,:) = emidtcoI(j,:);
                emidtcoI(j,:) = auxemidtco;
            end
        end
    end
end
if opm == 4 %Reduzir Custos Totais
    for i = 1: length(dataI(:,1))-1

```

```

        for j = i+1: length(dataI(:,1))
            if dataI(i,6) > dataI(j,6)
                aux = dataI(i,:);
                dataI(i,:) = dataI(j,:);
                dataI(j,:) = aux;
                Pmax = Pm(i);
                Pm(i) = Pm(j);
                Pm(j) = Pmax;
                auxB = BI(i,:);
                BI(i,:) = BI(j,:);
                BI(j,:) = auxB;
                auxemidtno = emidtnoI(i,:);
                emidtnoI(i,:) = emidtnoI(j,:);
                emidtnoI(j,:) = auxemidtno;
                auxemidtco = emidtcoI(i,:);
                emidtcoI(i,:) = emidtcoI(j,:);
                emidtcoI(j,:) = auxemidtco;
            end
        end
    end
end
if opm == 5 %Seleciona os com Pw Max Primeiro
    for i = 1: length(dataI(:,1))-1
        for j = i+1: length(dataI(:,1))
            if emidtcoI(i,2) > emidtcoI(j,2)
                aux = dataI(i,:);
                dataI(i,:) = dataI(j,:);
                dataI(j,:) = aux;
                Pmax = Pm(i);
                Pm(i) = Pm(j);
                Pm(j) = Pmax;

                auxB = BI(i,:);
                BI(i,:) = BI(j,:);
                BI(j,:) = auxB;
                auxemidtno = emidtnoI(i,:);
                emidtnoI(i,:) = emidtnoI(j,:);
                emidtnoI(j,:) = auxemidtno;
                auxemidtco = emidtcoI(i,:);
                emidtcoI(i,:) = emidtcoI(j,:);
                emidtcoI(j,:) = auxemidtco;
            end
        end
    end
end
%Demanda de Potencia (Mw)
Pd = 1500;

PMax = 0;
PdRef = Pd*1;
%seleciona os primeiro motores q atendam a demanda
for i=1:length(dataI(:,5))
    PMax = PMax + dataI(i,5);
    data(i,:) = dataI(i,:);
    emidtno(i,:) = emidtnoI(i,:);
    emidtco(i,:) = emidtcoI(i,:);

    if PMax > PdRef
        break;
    end
end

```

```

end

%numero de colunas datas
nl = length(data(:,5));
nc = length(data(1,:));

for i=1:nl
    for j=1:nl
        B(i,j) = BI(i,j);
    end
end

if sum(data(:,5)) < Pd

fprintf('=====
\n')
    fprintf('ERRO!, Não é possível satisfazer a demanda com a capacidade
atual.\n')
    fprintf('Capacidade atual: %2.2f mW < %2.2f mW.\n',sum(data(:,5)),Pd)

fprintf('=====
\n')

else
    if min(data(:,4)) > Pd

fprintf('=====
\n')
        fprintf('ERRO!, A potência demandada é menor que a potência
mínima.\n')
        fprintf('Capacidade atual: %2.2f mW > %2.2f mW.\n',min(data(:,4)),Pd)

fprintf('=====
\n')
        else
            options = nsgaopt();                % create default options
structure
            options.popsize = 50;                % population size
            options.maxGen = 150;                % max generation
            options.numObj = 3;                  % number of objectives
            options.numVar = length(data(:,1));  % number of design
variables
            options.numCons = 1;                % number of constraints
            options.lb = data(:,4)';            % lower bound of x
            options.ub = data(:,5)';            % upper bound of x
            options.objfun = @objfun_javed;      % objective function handle
            options.plotInterval = 5;           % interval between two
calls of "plotnsga".
            options.nameObj = {'Custo', 'COx', 'NOx'};

            result = nsga2(options);            % begin the optimization!

```